



Finanziert von der
Europäischen Union
NextGenerationEU

Gefördert durch:



Bundesministerium
für Wirtschaft
und Klimaschutz

aufgrund eines Beschlusses
des Deutschen Bundestages

BMWK-Verbundprojekt: progressivKI
Förderkennzeichen: 19A21006P
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: Schnittstellen- und KI-Module für
Schematic-, Layout- und Analysewerkzeuge**

Version: 1.0
Erstelldatum: 09.12.2024
Autoren: Dennis Choy, Bernd Stube

Zuwendungsempfänger: Technische Universität Berlin (Fkz: 19A21006P)

Ansprechpartner: Technische Universität Berlin
Bernd Stube
13355 Berlin
bernd.stube@tu-berlin.de

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

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

Inhalt

1 Zusammenfassung	5
2 Ziele	6
2.1 Problemstellung und allgemeine Ziele des Vorhabens	6
2.2 Wissenschaftliche und/oder technische Ziele des Vorhabens	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	22
2.2.7 Darstellung der wesentlichen Projektinnovationen	22
2.3 Ausgangssituation und Voraussetzungen, unter denen das Vorhaben durchgeführt wurde	25
2.3.1 Der Stand von Wissenschaft und Technik	25
2.3.2 Bisherige Arbeiten des Antragstellers	38
2.4 Abgrenzung und Zusammenarbeit mit anderen Projekten	39
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)	44
3.1.2 Teilaufgabe 1.2: Spezifikation KI-gestützter Entwurf	46
3.1.3 Teilaufgabe 1.3: KI-Module/KI-Algorithmen/Analyse Synergien	48
3.1.4 Teilaufgabe 1.4: KI-Module für KI-Plattformen der Anwendungsebenen #1 - #2 + Struktur der KI-Plattformen	50
3.2 Arbeitspaket 2: KI-Datenaufbereitung/-generierung	53
3.2.1 Teilaufgabe 2.1: Definition und Planung von Schnittstellenmodellen	55
3.2.2 Teilaufgabe 2.2: Test-/Lerndatenerzeugung	59
3.2.3 Teilaufgabe 2.3: Modellbildung + Klassifikation + Signalauswertung	60
3.2.4 Teilaufgabe 2.4: Entwicklung und Validierung eines Meta-Algorithmus	65
3.2.5 Teilaufgabe 2.5: Datenbasierte Trainings-/Lernmodule	69
3.3 Arbeitspaket 3: Verzahnte Entwicklung von Automobilkomponenten	70

3.3.1	Teilaufgabe 3.1: Framework KI-Module für AW-Ebenen #1 und #2 + Optimierung KI-Module	71
3.3.2	Teilaufgabe 3.2: Implementation Modul-Schnittstellen (Datenaustausch)	76
3.3.3	Teilaufgabe 3.3: Implementation spezifischer und vor-trainierter KI-Module für die Anwendungsebenen #1 und #2	82
3.3.4	Teilaufgabe 3.4: Implementation Domänenwissen	86
3.3.5	Teilaufgabe 3.5: Implementierung Meta-Algorithmen	91
3.3.6	Teilaufgabe 3.6: Validierung KI-Module/KI-Framework für Plattformen Anwendungsebenen #1 und #2	94
3.4	Arbeitspaket 4: Erstellung Teilplattformen (#1: PCB-Entwurf; #2: IC-Anwendung/Sensorik)	99
3.4.1	Teilaufgabe 4.1: KI-Plattform Anwendungsebene #1 PCB-Entwurf	102
3.4.2	Teilaufgabe 4.2: KI-Plattform Anwendungsebene #2 IC-Entwurf/Sensorik	107
3.5	Arbeitspaket 5: Projektmanagement & Dissemination	108
3.5.1	Teilaufgabe 5.1: Projektleitung/ProjektOffice + progressivKI Advisory Board	110
3.5.2	Teilaufgabe 5.2: F+E-Ergebnisverbreitung + F+E-Nutzungspotentiale	110
3.5.3	Teilaufgabe 5.3: Dokumentation Gesamtprojekt	112
4	Verwertung und voraussichtlicher Nutzen	112
5	Veröffentlichungen	114
6	Quellen	119

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 erforderlich. Die dabei erforderlichen F+E-Schritte sind so umfangreich, dass sie zukünftig nur mit Hilfe einer KI-basierten Plattform in ausreichend kurzer Zeit und mit vertretbarem Kostenaufwand erfolgreich umgesetzt werden können.

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

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

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

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

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

2 Ziele

2.1 Problemstellung und allgemeine Ziele des Vorhabens

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

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

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

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

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

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

Zur Bewältigung des Paradigmenwechsels in der Fahrzeugindustrie hin zu klimaneutralen, autonomen Mobilitätskonzepten steht die Automobilindustrie einschließlich aller an der 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 Begriffes „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 Reinforcements von elektronischen Bauteilen bzw. Herstellungsprozessen für die Medizinelektronik trainiert wurden, durch ihre Modularität, zum Beispiel, auch auf Prozesse aus der Automobilbranche oder Elektrotechnik angewandt werden.

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

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

2.2.3 Genutzte KI-Verfahren und Werkzeuge

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

In Anbetracht des großen durch die weltweite wissenschaftliche Community bereitgestellten Methodenspektrums war es nicht sinnvoll, in progressivKI eine Parallelentwicklung von Algorithmen vorzusehen. Vielmehr wurde im Projekt mit der Wertschöpfung bei der Nutzung

dieser Kompetenzen begonnen und im Bedarfsfall auch die Entwicklung/Anpassung von Algorithmen betrieben. Diesem Paradigma folgte progressivKI.

Die Vorgehensweise in progressivKI wurde durch die aktuelle Entwicklung im TensorFlow-Ökosystem unterstützt, da das Huskarl¹-Werkzeug als neues Werkzeug (Framework) einen neuen modularen Ansatz des Reinforcement erlaubt. Diesen Ansatz verfolgte progressivKI intrinsisch. Die unterschiedlichen Pfade durch die KI-System-Modullandschaft können 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 Datenpunkte mit maximalem Abstand trennt. Daten, deren räumlicher Abstand zur Trennebene gering ist, werden dabei mehr berücksichtigt als Datenpunkte, deren Abstand zur Trennebene groß ist.
Decision Trees - Decision Trees, oder auch Entscheidungsbäume sind geordnete, gerichtete Bäume, die der Erstellung und Darstellung von Entscheidungsregeln dienen. Besondere Bedeutung kommt Entscheidungsbäumen in Bereichen zu, in denen aus tacit knowledge/Erfahrungswissen formale Regeln abgeleitet werden können. 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 knowledge²) abgebildet werden kann und andererseits das Ergebnis des ML als Eingangsgröße für das nächste Segment dienen kann. Das bedeutet, man fängt mit der klassischen Feature Extraction an und kann diese – eventuell 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.

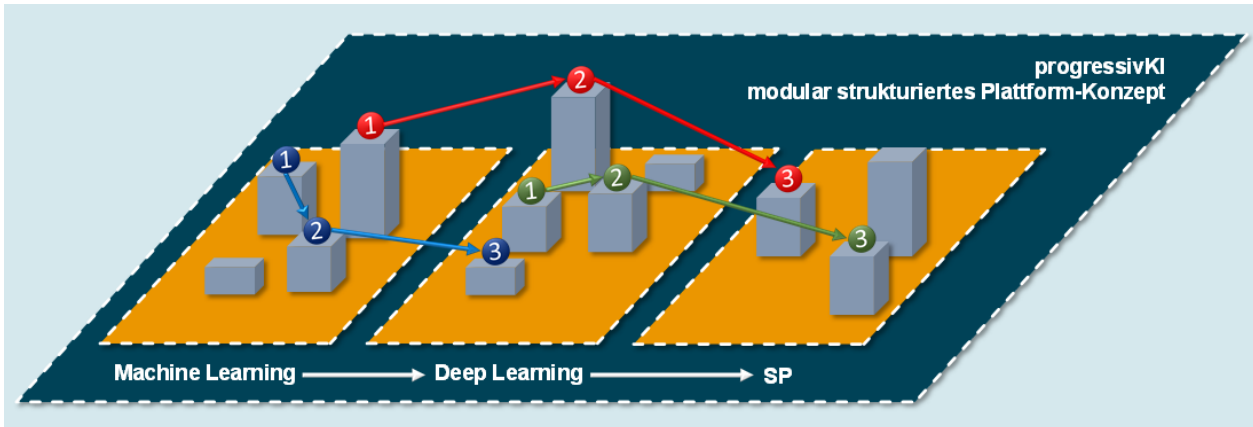


Abbildung 1: progressivKI modular, strukturierte KI-Plattform - Module aus den 3 Segmenten Machine Learning (ML) – Deep Learning (DL) – Selbstlernende Prozesse (SP)

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 Psychologie 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 Features³ für den DeepLearning-Prozess nach Möglichkeit eingesetzt.

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

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

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

- Python ist eine dynamische High-Level Programmiersprache, die schon knapp drei Jahrzehnte am Markt etabliert ist.
- Komplette Open Source
- 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 benötigte KI-Erweiterung von vorhandenen Entwurfsumgebungen realisiert werden (Abbildung 18).

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

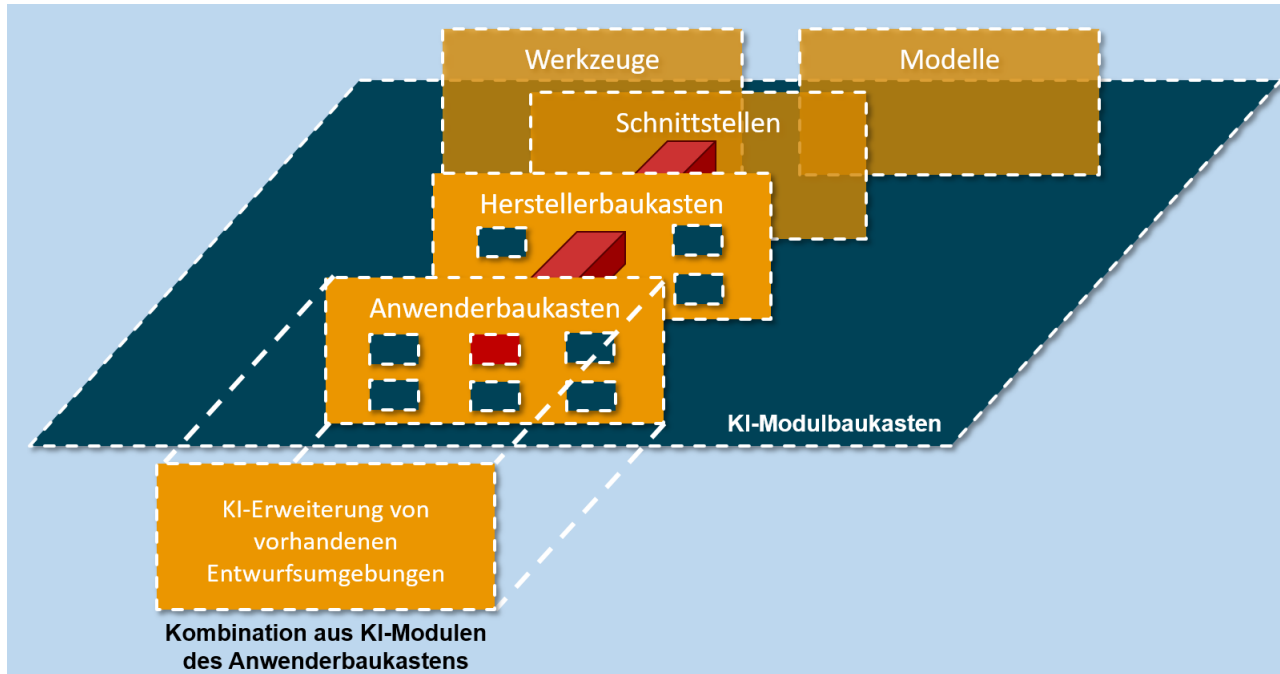


Abbildung 2: Prinzipieller Aufbau eines KI-Modulbaukastens

2.2.5 Entwurfsprozesse

Elektronische Systeme werden in immer stärkerem Maße durch hohe Komplexitäten und Anforderungen an die Systemsicherheit geprägt. Dazu kommt ein durch wirtschaftliche Zwänge motivierter Trend zur Integration von Komponenten und Subsystemen zu hochkompakten

Systemen. Dieser Trend ist in allen Industriebereichen, wie z.B. Automobilindustrie, Medizintechnik, Automatisierungstechnik, Robotik, Logistik und Telekommunikation zu verzeichnen.

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

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

Mit der Zielsetzung einer zufriedenstellenden Gesamtfunktion liefern z.B. eine messtechnische Validierung und ein abschließender Test sowie eine anschließende Dokumentation der Systemeigenschaften im Entwurfsprozess bereits eine erhebliche Datenmenge. Das darin steckende Entwurfswissen gilt es zukünftig mittels KI-Modulen, die für jede Entwurfsebene eine andere Ausprägung haben müssen, effizient nutzbar zu machen. Dazu muss allerdings der systematische Entwurf des ganzheitlich betrachteten Systems auch unter dem Aspekt der funktionalen Sicherheit umgesetzt werden. Allerdings dürfen auch Faktoren wie Kosten und Marktanforderungen nicht vernachlässigt werden.

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

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

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

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

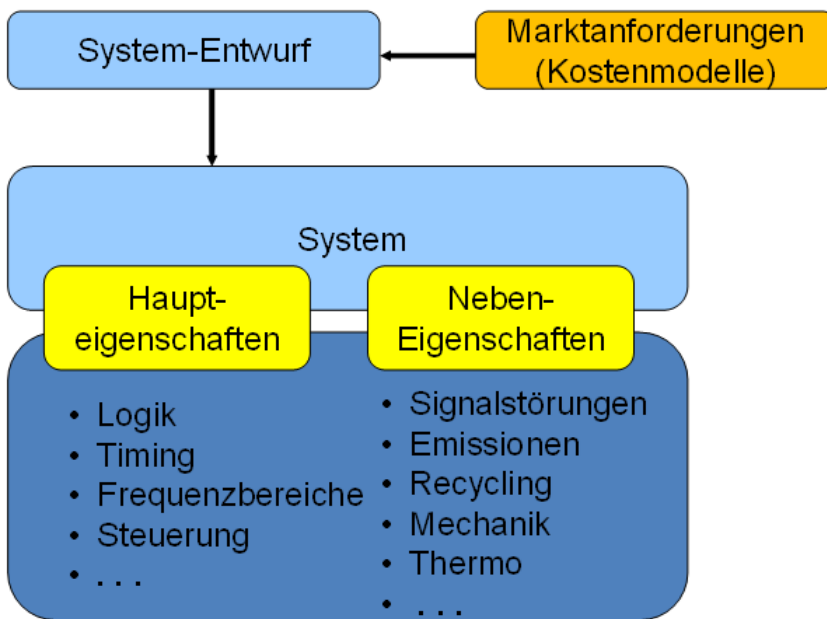


Abbildung 3: Gliederung eines mikroelektronischen Systems in Haupt- und Nebeneigenschaften

2.2.5.1 Allgemeiner Entwurfsprozess

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

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

Abbildung 20 zeigt ein weiterentwickeltes Prozessmodell für den Entwurf elektronischer Systeme. Die jeweiligen Phasen dienen der Strukturierung der zu beschreibenden Entwicklungsprozesse und müssen evtl. auch zeitlich überlappend abgearbeitet werden. Beginnend mit der |Anforderungsbeschreibung| werden die darauffolgenden Phasen bis zum |Test| auf der Systemebene durchlaufen. Die Definition der angedeuteten Systemhierarchie ergibt sich zwangsläufig aus der geforderten Funktionalität. Entsprechende Abläufe müssen deshalb auch für die Ebenen Subsysteme und Komponenten betrachtet werden. Es wird auch deutlich, dass eine Optimierung des Zielsystems auf den unterschiedlichen Entwurfsebenen üblicherweise nach dem sog. JoJo-Prinzip erfolgt. Allerdings muss zusätzlich eine Optimierung der Subsysteme und Komponenten auf horizontalen Ebenen erfolgen. Bei allen Schritten zur Entwurfsoptimierung fallen erhebliche Datenmengen unterschiedlicher Natur an (z.B. Spezifikationsdokumente; Simulationsergebnisse; Messergebnisse; Berichte aus dem Feld; ...). Da die allermeisten Entwürfe in sog.

Wertschöpfungsketten (z.B. Systemhaus - Tier1 - Tier2) erfolgen, wird deutlich, dass eine zukünftige KI-Unterstützung wertschöpfungsketten-übergreifend erfolgen muss.

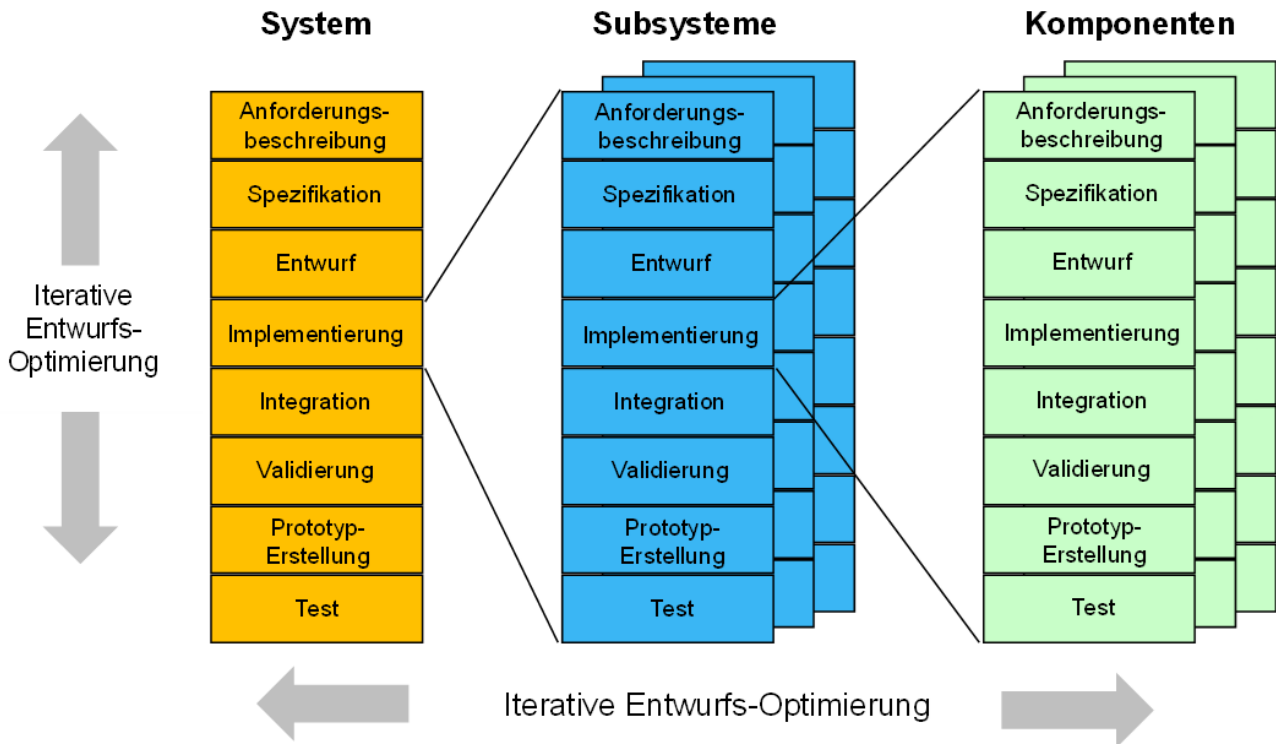


Abbildung 4: Verallgemeinerter Entwurfsprozess als Grundlage für die Analyse des Einsatzes von KI-Modulen im industriellen Umfeld

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

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

2.2.5.2 Funktionale Sicherheit

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

Mit der Komplexität elektronischer Systeme steigt auch die Vielfalt der Fehlermöglichkeiten. Entsprechend fordert die Normenreihe IEC 61508 (Funktionale Sicherheit) sicherheitsbezogener elektronischer Systeme die Anwendung diverser Methoden zur Vermeidung systematischer Fehler

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).

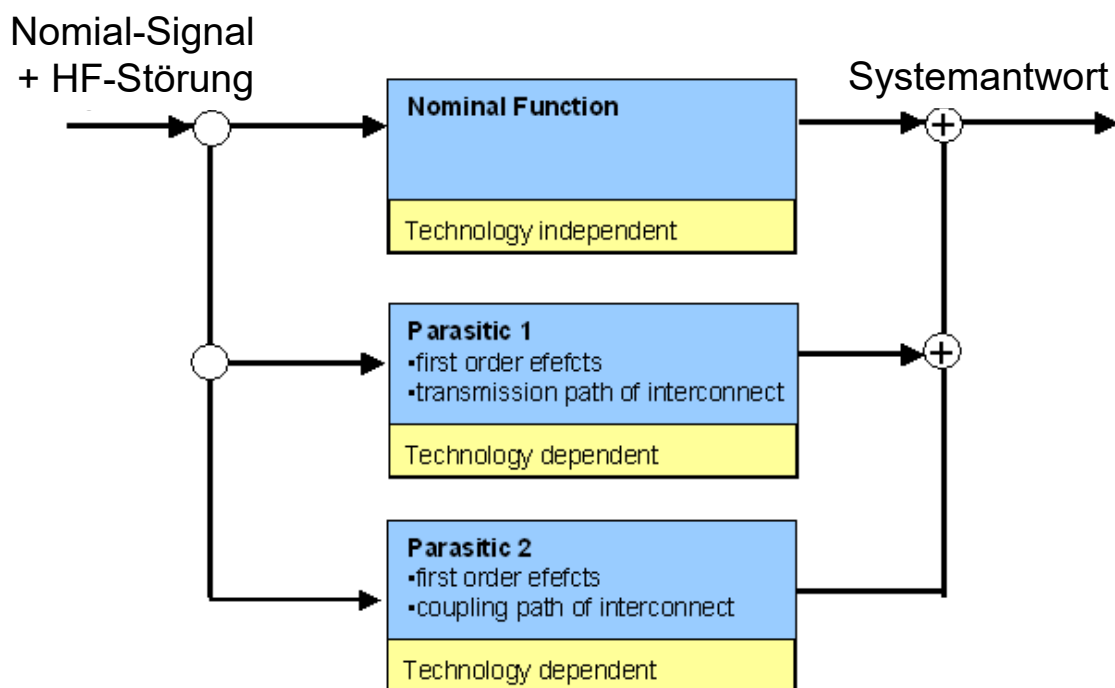


Abbildung 6: Ansatz zur Einführung von Modellhierarchien für eine Fehleranalyse durch Simulation

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).

Cost Saving: Virtual Prototypes - Error Prevention



Time Saving: Concurrent Design – Reduced Number/Shorter Cycles

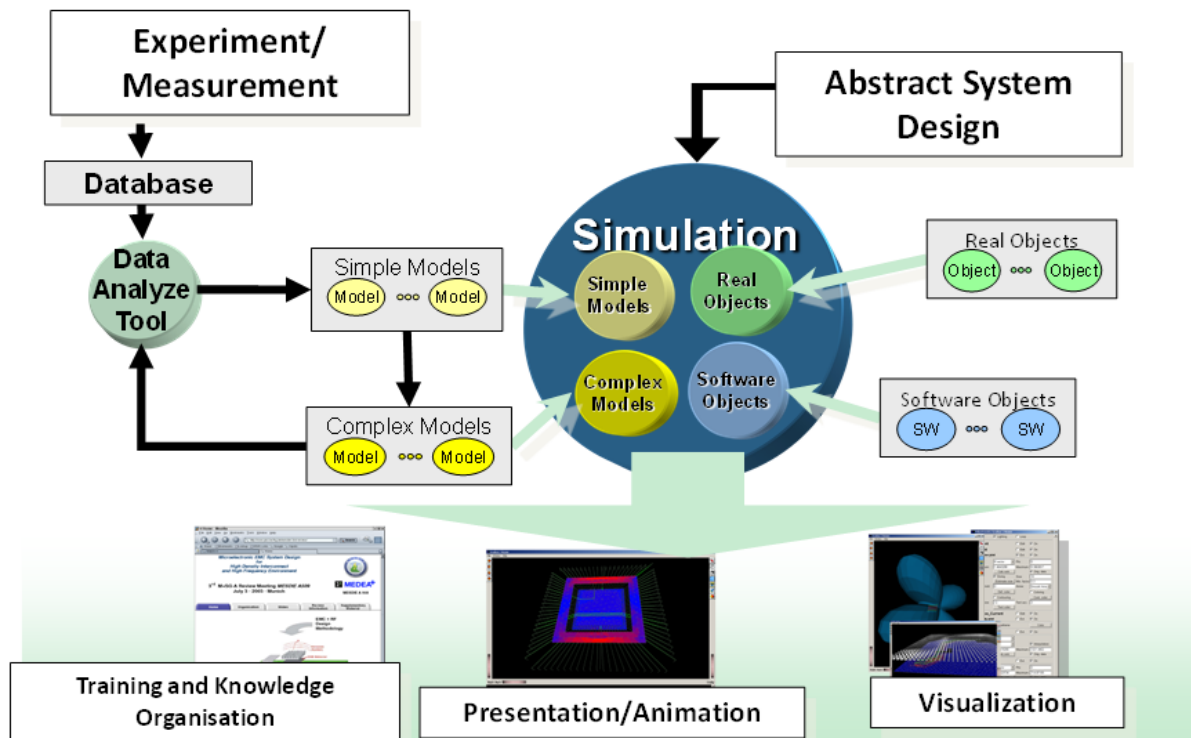


Abbildung 7: Virtuelle Entwicklung: Einsatz von Simulationsverfahren und –prinzipien

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

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

2.2.6 IP-Schutz und Interoperabilität

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

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

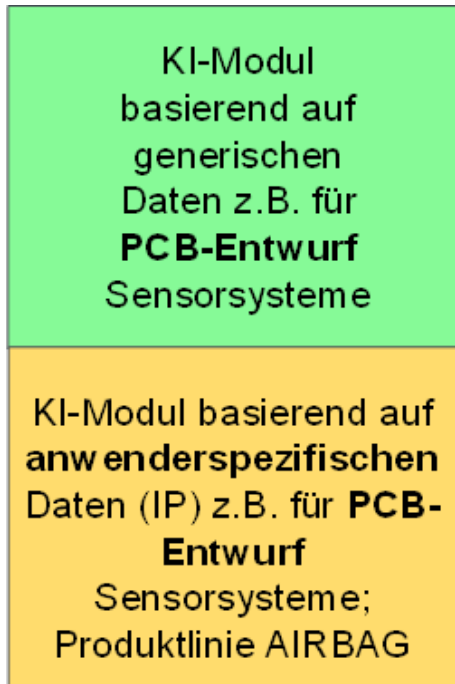


Abbildung 8: progressivKI-Ansatz zur Sicherstellung eines umfassenden IP-Schutz und Herstellung der Interoperabilität (Beispiel Anwender Ebene #2 PCB-Entwurf)

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

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

2.2.7 Darstellung der wesentlichen Projektinnovationen

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

#	Vorwettbewerbliches Innovationselement	edaKI-Einsatzgebiet
IE.1	KI-Einsatz zur 20%igen Reduktion der zukünftig aufzuwendenden Ressourcen (Zeit, Personal, Kosten) für den Entwurf funktional-sicherer elektronischer KFZ-Systeme.	Entwurfsprozess; Objekt 1 bis Objekt 8; siehe auch Abbildung 10.
IE.2	Entwicklung einer neuartigen, modular aufgebauten sowie flexibel einsetzbaren KI-Plattform zur direkten Abdeckung der System-Entwurfsebenen PCB-Entwurf und IC-Entwurf/Intelligente Sensorik .	Entwurfsprozess; Objekt 1 bis Objekt 8; siehe auch Abbildung 10.
IE.3	Entwicklung von sicheren, verschlüsselten und intelligenten Konnektoren zu den einzelnen (verteilten) Modulen und Subsystemen der modularen KI-Plattform.	IP-Schutz/Interoperabilität/KI-Interaktionsmodelle; siehe Abbildung 11; Abbildung 24.
IE.4	Portabilität und Übertragbarkeit der technischen Lösungen auf die individuellen Entwurfsprozesse durch Anordnung domänen- und applikationsspezifischer Konnektoren um einen leistungsfähigen KI-Kern.	KI-Module aus den 3 Segmenten Machine Learning (ML) – Deep Learning (DL) – Selbstlernende Prozesse (SP); siehe Abbildung 17.
IE.5	Erforschung neuartiger Konzepte für den kooperativen Betrieb von KI-Systemen in industriellen Entwurfsabläufen.	<ul style="list-style-type: none"> <input type="checkbox"/> Anwendungsebene #1: PCB-Entwurf; siehe Abbildung 11 + Abbildung 12. <input type="checkbox"/> Anwendungsebene #2: IC-Entwurf/Sensorik; siehe Abbildung 15. <input type="checkbox"/> Neuartige KI-basierte Unterstützung des Prinzips der Variantenkonstruktion.
IE.6	Innovations-Sprung und gesteigerte Wertschöpfung durch Einsatz und Adaption von OpenSource KI-Software. Vermeidung von zeitaufwendigen Parallelentwicklungen durch Nutzung des weltweit ausgereiften informationstheoretischen Knowhow mittels Open-Source KI-Software zur Entwicklung einer modular strukturierten KI-Plattform.	KI-Module aus den 3 Segmenten Machine Learning (ML) – Deep Learning (DL) – Selbstlernende Prozesse (SP); siehe Abbildung 17.
IE.7	KI-Zugang für KMU; es wird eine für jede Domain allgemein zugängliche KI-basierte Fähigkeiten-Basis aufgebaut und kontinuierlich weiterentwickelt (2-stufiger Ansatz zum IP-Schutz). Diese kann für die zukünftig notwendige Wettbewerbssteigerung durch KMU optimal genutzt werden.	KI-Modulbaukasten; adaptierbar auf spezifische KMU-Randbedingungen (keine durchgängige Werkzeugkette; OpenSource Simulationswerkzeuge; Beauftragung an externe Dienstleister;...; siehe Abbildung 18.
IE.8	Definition und Umsetzung eines reichhaltigen Anwenderökosystems mit komplexen Anforderungen, die in den entsprechenden Workstream des aktuellen GAIA-X Prozesses (GAIA-X Workstream 2 Technische Umsetzung) einfließen. Sicherstellung der Übertragbarkeit auf Entwurfsprozesse industrieller Anwender, die aktuell nicht am Vorhaben beteiligt sind, durch eine Cloud-Lösung (quasi als Goldstandard).	GAIA-X Ansatz für wertschöpfungskettenübergreifende 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-Schalbild (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-Schalbild (Quelle: ZUKEN); Typischer SchematicAufbau; siehe auch Abbildung 5. MOSTCheck AnwenderWorkflow (Quelle: 05-MCHP); siehe auch Abbildung 12
IE.13	Alleinstellungsmerkmal durch Quantisierung von Lernerfolgen (Metrisierung) zur Qualitätskontrolle für maschinelles Lernen.	Modular, strukturierte KI-Plattform/Training und Applikation; siehe auch Abbildung 16.
IE.14	Neue Verfahren zur Bewertung und Absicherung der Qualität von Trainings- und Lernprozessen für KI-Module.	Modular, strukturierte KI-Plattform/Training und Applikation; siehe auch Abbildung 16.

Tabelle 2: progressivKI-Innovationselemente gemäß Schumpeter-Definition*

*Zitat aus [E. Borbély; J. A. Schumpeter und die Innovationsforschung; MEB 2008 – 6th International Conference on Management, Enterprise and Benchmarking May 30 - 31, 2008 Budapest, Hungary]: Neue Verfahren zur Bewertung und Absicherung der Qualität von Trainings- und Lernprozessen für KI-Module.: *Schumpeter definiert die Innovation als die Umsetzung neuer Kombinationen in die Realität: [The doing of new things or the doing of things that are already done, in a new way]¹, wobei er immer an die erstmalige Durchführung einer Neuerung denkt. Innovationen sind also neue und andersartige Kombinationen der zur Verfügung stehenden [Dinge und Kräfte], wobei Produktion die übliche Kombination vorhandener Dinge und Kräfte ist – die einmal wahrscheinlich auch neuartig waren².*

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

2.3 Ausgangssituation und Voraussetzungen, unter denen das Vorhaben durchgeführt wurde

2.3.1 Der Stand von Wissenschaft und Technik

Ökonomische Rahmenbedingungen des KI-Einsatzes

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

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

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

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

Konzepte und Begriffe des Maschinellen Lernens

In progressivKI wurde künstliche Intelligenz (KI) zur Automatisierung intelligenten Verhaltens, namentlich der flexiblen, requirement-orientierten Entwicklung elektronischer Hardwarekomponenten für zukünftige Mobilitätskonzepte, eingesetzt. Der Begriff KI umfasst ein Universum unterschiedlicher Algorithmen (siehe z.B. [Ertel]), das angefangen mit lang bekannten, elementaren statistischen Algorithmen zur Klassifikation, Bestapproximation und Filterung über neuronale Netze unterschiedlicher Tiefe bis hin zu komplexen Lernstrategien wie „Reinforced Learning“ oder „Transfer Learning“ reicht. Die einfachste Form maschinellen Lernens erfolgt durch

die Anpassung eines parametrischen Modells an einen großen Datensatz in der Hoffnung, dass die angepassten Parameter die Datenstruktur hinreichend wiedergeben. Die Betrachtung gewisser damals teilweise bereits bekannter mathematischer bzw. statistischer Verfahren unter dem Paradigma eines Lernprozesses begann Mitte des letzten Jahrhunderts (z.B. [Teich]).

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

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

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

Lösung elektrotechnischer Entwurfsprobleme entlang einer gesamten Wertschöpfungskette und die Ableitung von sinnvollen Geschäftsmodellen auf dieser Basis ist neu.

KI für Domänen-spezifische Anwendungsfälle

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

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

KI-Frameworks

Die weltweit operierenden Protagonisten des Einsatzes von KI-Methoden wie Google, Apple, Microsoft etc., setzen für die Entwicklung der Technologie weitgehend auf eine gemischte Strategie: Einen Teil der Wertschöpfung, nämlich den mit der wissenschaftlichen Erforschung von Algorithmen und der Bereitstellung effizienter Tools verbundenen, lassen sie offen unter Partizipation beinahe aller Universitäten der Welt durchführen. So stellen sie sicher, dass sie nicht plötzlich durch eine Innovation, die ihnen nicht zugänglich ist, abgehängt werden, und gleichzeitig über die wissenschaftliche Entwickler-Community Zugriff auf die besten Köpfe jeder Generation haben. Erst daran schließt sich die Firmen-exklusive Wertschöpfung, in der angestrebt wird, durch besseren Zugriff auf mehr Daten, bessere Serverarchitekturen, bessere Anpassung der Algorithmen etc. die besseren Services anzubieten. Dieses Businessmodell, das in höchster Form von Kapitalanlegern goutiert wird, hat dazu geführt, dass weltweit ein freier Zugriff auf die 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 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 progressiv KI angestrebt wurde, die automatisierte Lösung von Design-Problemen, wie in [DACPan20] dargestellt wird. Hierin liegt ein entscheidender Schritt über bereits in der Erprobung befindliche Teilverfahren hinaus.

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

Anders als bei der automatischen Auswertung von Konsumentendaten ist jedoch zu beachten, dass industrielle KI-Anwendungen Spezialisierungen erfordern. Z.B. verlangt die Analyse

sicherheitskritischer Anwendungen nach einer höheren Verlässlichkeit und Validierbarkeit 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 zur Lösung von Automatisierungsproblemen im Elektronikentwurf finden sich z.B. in [DeepPCB], [EffectivePCB], [TrainingModel],[GloBay].

Die große ökonomische Bedeutung der Verfügbarmachung all dieser Einzelkomponenten von progressivKI zeigt sich, u.a., daran, dass der Wertschöpfungsprozess bei der PCB-Produktion vor allem durch Prozessunterbrechungen und Schnittstellenprobleme eingeschränkt wird. Das Fehlen von zusammenhängenden Tools von einem Anbieter gepaart mit Kommunikationsproblemen und dem Austausch nicht standardisierter Informationen verhindern optimierte Arbeitsflüsse. Betroffen sind alle Arbeitsprozesse vom iterativen Anforderungsmanagement bis hin zur manuellen Angebotserstellung. Die Extraktion von Informationen aus Bauteil-Datenblättern erfolgt heutzutage größtenteils manuell. Wie Gespräche mit Industrieexperten ergeben haben, wird der Prozess der Informationsextraktion von Einzelteil-Lieferanten oftmals ins Ausland ausgelagert. Auch EMS-Firmen und Designer schauen manuell nach Informationen in den Datenblättern. Aus

Gesprächen mit EMS-Firmen ist hervorgegangen, dass das Erstellen eines Angebots bis zu 40 Arbeitsstunden in Anspruch nehmen kann, was hauptsächlich an ineffizienten Informationsflüssen und iterativer Kommunikation mit Lieferanten liegt. Der hohe Zeitaufwand birgt das Risiko viel Zeit in Angebote zu stecken, die letztendlich nicht immer verkauft werden. Gleichzeitig entstehen für Designer häufig kostspielige Iterationen, die vermieden werden könnten, wenn sie frühzeitig an nötige Informationen zur Verfügbarkeit, Herstellbarkeit, Konformität usw. kommen würden.

Segment „KI zur Verifikation von Entwürfen“

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

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

Segment „Interpretation Design-relevanter Informationsquellen“

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

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

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

gefördert werden, da Ressourcen von repetitiven Arbeiten befreit werden und wertschöpfender eingesetzt werden können.

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

Um alle relevanten Informationen aus einem semi-strukturierten Datenblatt zu extrahieren, muss das Zielsystem das Dokument somit in seiner Gesamtheit verstehen und differenziert methodisch bearbeiten. Somit ist neben der Kombination von führenden IE-Architekturen auch ein qualitativ hochwertiger Datensatz notwendig, um einen möglichen Durchbruch bei der Automatisierung und Extraktionsleistung zu erreichen.

Der Konsortialpartner DIQA steuerte Methoden zu Wissensrepräsentation, Informationsextraktion, NLP und Machine Learning zu progressivKI bei. Als Input für diese

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

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

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

Segment „Berücksichtigung der EMV im Entwurfsprozess“

Im Bereich der EMV-Abnahmemessungen wird derzeit keine KI zur Optimierung eingesetzt. Meist erfolgt eine Voroptimierung der Elektronik innerhalb des untersuchten Prüflings (Fahrzeugkomponenten EuB) vorab simulationsbasiert beim Kunden. Dies geschieht in einem frühen Stadium der Entwicklung – wie bereits erörtert - meist auf Basis von Simulationen. Hier gibt es für einige Anwendungen, wie z.B. Filteroptimierung, Ansätze, die Performance von Emissionsmessungen computergestützt zu optimieren [MueBel]. Die ersten Versionen der Hardware werden dann zum Teil noch beim Kunden vermessen. Langjährige Erfahrungen aus dem Laborbetrieb zeigen aber, dass es immer wieder bei den Abnahmemessungen teilweise zu großen Abweichungen und Grenzwertüberschreitungen kommt. Da der Projektpartner EMC Test NRW GmbH als Prüflabor die Prüflinge immer als Black-Box betrachtet, wurden bei der Messung nur die äußeren Ports betrachtet. Eine Verknüpfung der Simulationen und der Vorabmessungen mit den Ergebnissen der Abnahmemessungen existierte nicht. Auch wird keine KI zur Optimierung eingesetzt. Rückschlüsse auf die Auswirkungen von Hardwareänderungen auf die Ergebnisse bei

Komponentenmessungen könnten die Anzahl der Iterationsschleifen im Elektronikentwicklungsprozess im Bereich der EMV drastisch reduzieren.

Segment „Lieferkettenübergreifende Qualitätssicherung“

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

Zur Bewertung von Mikroelektronik-Technologien entlang der Wertschöpfungskette, d.h. vom Halbleiterhersteller bis hin zum OEM, wurde in [AlsAdHi] das Werkzeug Technology Black Box (TBB) vorgestellt, welches das kollaborative Entwickeln und Bewerten von Halbleitertechnologien ermöglicht. Hierzu bietet das Werkzeug den Abgleich von Anforderungen und Technologiebewertungen, wobei alle Akteure Modelle bereitstellen und nutzen können. Ein vergleichbares Werkzeug, Collaborative Technology Evaluation Framework (CTEF), wurde in [AhaNovVi] vorgestellt. Ziel war die Bewertung von Zuverlässigkeit und Energiebedarf, ohne den Austausch geistigen Eigentums (Intellectual Property). Hierzu wurde eine Austauschplattform geschaffen, bei welcher Akteure der Wertschöpfungskette Modelle zur Transformation von System- bzw. Technologieparameter anbieten konnten. Der Nutzer kann auf diese Modelle zugreifen, um eine System- bzw. Komponentenbewertung durchzuführen. Beiden Ansätzen gemein ist, dass sie vorrangig auf mathematischen Modellen sowie im begrenzten Umfang auf Simulationen aufbauen. Dennoch stellen sie eine gute Grundlage zur Adaption für den Austausch, bzw. die synergetische Nutzung von KI-Modellen dar. Fragestellungen wie die Handhabung der komplexeren Schnittstellen der Modelle müssen aber noch geklärt werden. Hier könnten Ansätze aus der kooperativen Nutzung von Simulationsmodellen als Vorlage dienen. Beispielsweise bietet das Functional Mock-up Interface (FMI) [FMI], eine standardisierte Schnittstelle zum Koppeln von Simulationsmodellen. In [Masudul] wird FMI zur Kopplung von RTL-Simulationen mit Software-Simulationen in MATLAB verwendet. Im Kontext von FMI wurden weitere Standards wie das System Structure and Parameterization (SSP) [SSP], um die Gesamtarchitektur der Co-Simulationen, sowie den benötigten 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 Beendigung 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 dezidiert Hardwaresysteme, um verschiedene KI-Einsatzbereich (z.B. Bilderkennung) dezidiert zu unterstützen. Im Bereich KI-Technologien beschäftigen sich führende EDA-Unternehmen wie Cadence [Klcdn], Mentor [Klment] oder Synopsis [Klsyn] daher mit Fragestellungen wie der Entwicklung von Tools, mit denen Unternehmen KI-Beschleuniger (Hardwarelösungen) schneller entwickeln können, um auf diesen Systemen ihre maschinellen Lernalgorithmen zur Verbesserung der IC-Designtools einzusetzen und so Kunden die Möglichkeit zu geben, schneller bessere Ergebnisse erzielen zu können.

Der Bedarf an angepasster Hardware zeigt sich daran, dass KI-Methoden, die initial 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

19-TUB

Unternehmensvorstellung

An dem im Jahr 1987 gegründeten Forschungsschwerpunkt Technologien der Mikroperipherik der TU Berlin forschen und entwickeln ca. 70 Mitarbeiter Methoden und Technologien der Aufbau- und Verbindungstechnik von mikroelektronischen Schaltungen und mikrosystemischen Bauteilen. Die Arbeitsgruppe Physical Design Tools & Software besitzt langjährige Erfahrungen in der erfolgreichen Erforschung und Bereitstellung innovativer Entwurfssysteme (EDA Tools) im Rahmen von öffentlich geförderten Verbundvorhaben.

Wissenschaftliche Mitarbeiter dieser Gruppe werden zur Lösung der komplexen Teilaufgabenstellungen der TU Berlin im Rahmen des Verbundvorhabens zum Einsatz kommen.

Projektbezogene Kompetenzen und Schwerpunkte

In den bisher realisierten Vorhaben stellte die Problematik der Untersuchung, Spezifikation und Bereitstellung von effizienten Schnittstellen-Programmen zwischen Software-Tools verschiedener Anbieter (z.B. Altium, Zuken, Mentor Graphics) eine sehr wichtige Arbeitsaufgabe dar. Da jeder dieser EDA Tool-Anbieter unterschiedliche Zugriffsmöglichkeiten auf ihre Datenbasis offerieren (z.B. File-Schnittstelle, COM-Automation, Plugin-API, .NET-Schnittstelle), mussten die benötigten Schnittstellen entsprechend dieser Technologien realisiert werden. Ein weiterer Themenschwerpunkt der Arbeitsgruppe sind KI-basierte Monitoring-Systeme, in denen Verfahren des Maschinelles Lernen (u.a. PCA) und Data Mining zum Einsatz kommen. Mit diesen Erfahrungen und Fähigkeiten werden sich die Arbeiten der TU Berlin in dem Vorhaben auf Schnittstellen (EDA Tools, Analysewerkzeuge, KI) und benötigte KI-Module fokussieren, die in einem Software-Demonstrator integriert werden.

Relevante Vorgängerprojekte

Im KMU-innovativ Vorhaben ZEUS wurden neue 3D-Entwurfswerkzeuge zur Systemplanung und schnellen Pre-Layout-Analyse von komplexen Multi-Board-Systemen und im KMU-innovativ Vorhaben ADAP wurde ein neues Entwurfswerkzeug zur Adaption kritischer Teilschaltungen im Design-Prozess hoch-kompakter Baugruppen erfolgreich erarbeitet. In diesen Beiträgen zur Entwurfsautomatisierung wurde insbesondere in den Gebieten Algorithmen-Entwurf, Layoutsynthese, EMV, maschinelles Lernen, Schnittstellen und Toolentwicklung ein umfangreiches Knowhow erworben, das zur Sicherstellung des Erfolgs des beantragten Vorhabens von den Mitarbeitern der Arbeitsgruppe eingebracht wird.

2.4 Abgrenzung und Zusammenarbeit mit anderen Projekten

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

Rekonfigurierbare Hardwareplattform zur KI-basierten Sensordatenverarbeitung für das autonome Fahren

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

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

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

KI-Prozessorarchitekturen für Radarmodule im autonomen Fahrzeug

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

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

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

Elektronik für verteilte Künstliche Intelligenz zur sensorbasierten Prozess- und Zustandskontrolle

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

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

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

Sichere und intelligente Elektroniksysteme für vertrauenswürdige Elektronikprodukte in Industrie 4.0

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

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

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

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

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

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

KI-Marktplatz (BMW i - KI-Innovationswettbewerb)

Ökosystem für Künstliche Intelligenz in der Produktentstehung

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

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

KIPS (Technologieförderung Sachsen, KI-Plattform Sachsen)

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

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

3 Technische Ergebnisse

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

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

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

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

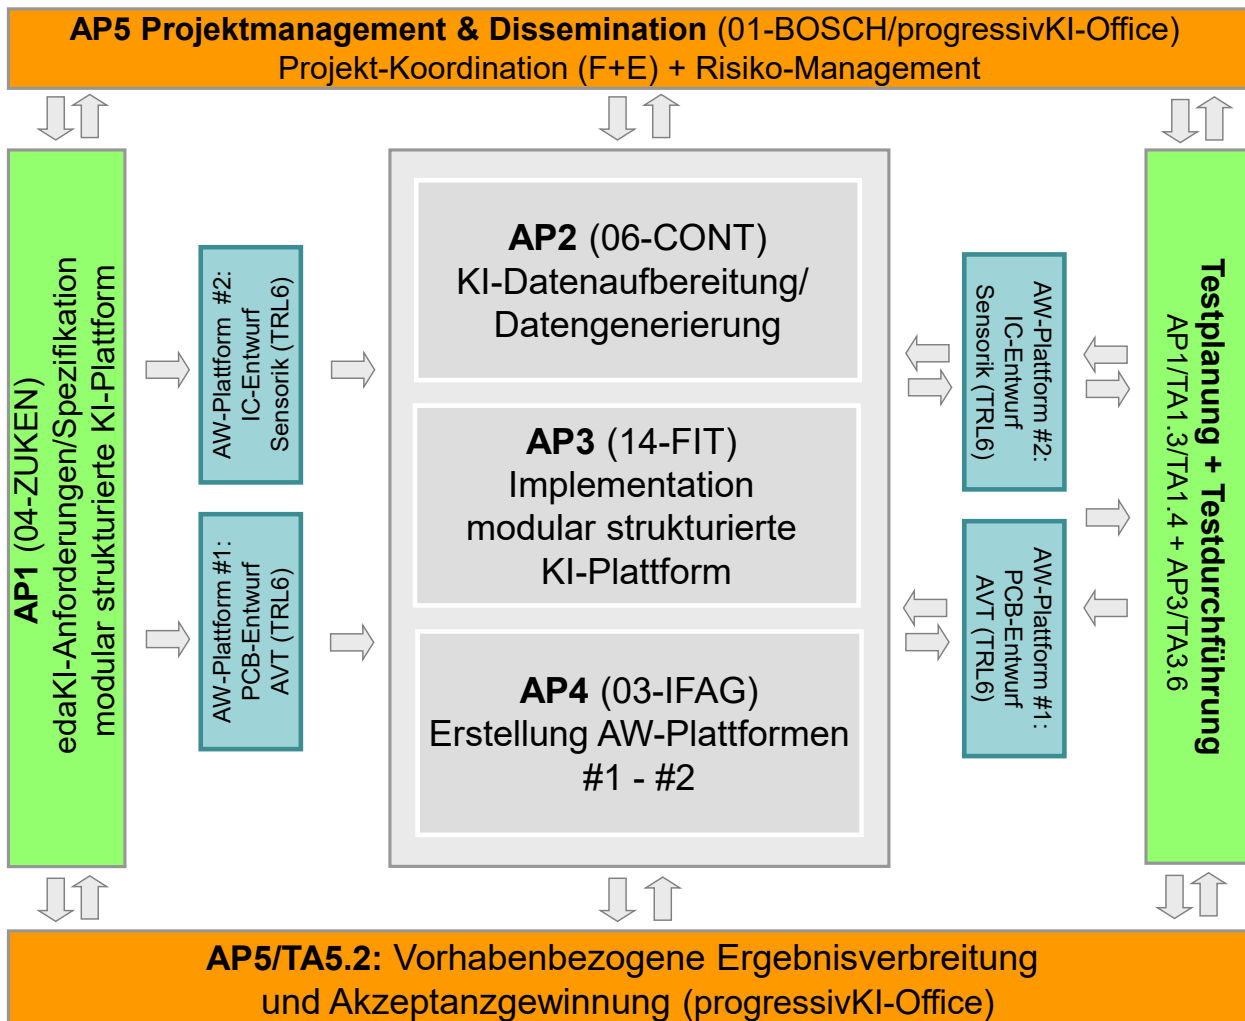


Abbildung 9: Abhängigkeiten und Interaktion der progressivKI-Arbeitspakete

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

Ausgangslage: Mit progressivKI wurde ein hochgradig modularer Ansatz verfolgt, der durch KI-basierte Automatisierung die Effektivierung der Entwurfsprozesse einer umfassenden Wertschöpfungskette unterstützt. Die große damit verbundene Wertschöpfung kann dank der modularen Struktur von Nutzern sowohl systemübergreifend umgesetzt werden als auch im Rahmen von spezifischen Einzelaufgaben entlang der betrachteten Wertschöpfungskette. Damit progressivKI die vorgesehene umfassende Anwendbarkeit und das entsprechende TRL erhält, war eine präzise Analyse des Systems der Requirements erforderlich, die entlang der betrachteten

Wertschöpfungskette gelten, sowie eine transparente Darstellung aller verwendeten Formate und Schnittstellen. Diese wichtige Aufgabe wurde im AP1 geleistet zusammen mit der Definition der daraus abgeleiteten Anforderungen an progressivKI und die im Projekt zu bedienenden Formate, Protokolle und Schnittstellen. Derzeit sind gestützte Entwurfsprozesse von (Teil-) elektronischen Systemen mit Constraints (wie z.B. Applikations- oder IC bzw. OEM-Hersteller-Vorgaben) in der Regel vom jeweiligen Entwickler durchgeführte manuelle Prozesse mit mehr oder weniger formalisiertem Entwurfsziel, zum Teil mit Analyseunterstützung durch EDA/CAD-Werkzeuge. Diese Prozesse sind zeitaufwendig und oft auch fehlerbehaftet. In diesem Arbeitspaket wurden die Spezifikationen für das Projekt im Hinblick auf Schnittstellen zwischen Entwurfsabläufen und den KI-Modulen erarbeitet. Weiterhin wurden Anforderungen an die Datensammlung sowie an die KI-Module definiert. Darüber hinaus musste analysiert werden, ob Synergien zwischen unterschiedlichen KI-Algorithmen nutzbar gemacht werden können.

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

Dieses Arbeitspaket definierte und lieferte:

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

Geplante Ergebnisse von AP1 waren:

- Im Rahmen dieses Arbeitspakets waren mehrere Schlüsselergebnisse vorgesehen. Zunächst erfolgte die Definition und Spezifikation der erforderlichen KI-Algorithmen, wobei der Schwerpunkt auf der funktionalen Sicherheit für die zu automatisierenden Entwurfsabläufe lag. Gleichzeitig wurden die Schnittstellen und Datenformate spezifiziert, um einen sicheren und effizienten Datenaustausch zu gewährleisten.
- Des Weiteren wurden KI-verwertbare Regelwerke erstellt, basierend auf Entwurfs- und Designregeln. Hierbei erfolgte die Spezifikation der Datenaufbereitung und die Festlegung von Anforderungen an die KI-Module aus der Perspektive der Entwurfsprobleme, die sich aus den Use Cases der beiden Anwendungsebenen ergaben.
- Eine umfassende Analyse verschiedener Open-Source KI-Frameworks wurde durchgeführt, wobei der Fokus auf den Eingangsdatenformaten lag. Dabei wurden Synergien zwischen den genutzten Frameworks herausgearbeitet, und die KI-Algorithmen wurden spezifiziert.
- Die Ergebnisse aus den Arbeitsschritten AT1.1 bis AT1.3 sowie AT 2.1 dienen 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 1.1.19: Anforderungsanalyse(n) für Anwendungsebene #1 (19-TUB)

Ziele

- Untersuchung und Auswahl geeigneter EDA-Tools:
Es sollte eine umfassende Untersuchung der verfügbaren EDA-Tools (Electronic Design Automation) durchgeführt werden, um festzustellen, welche dieser Werkzeuge sich am besten für die Bereitstellung der geplanten Anwendungsebene eignen.
- Entwicklung einer praxisorientierten Wertschöpfungskette:
Basierend auf den untersuchten EDA-Tools sollte eine Wertschöpfungskette entwickelt werden, die den praktischen Einsatz der Werkzeuge in der Anwendungsebene optimiert.
- Spezifikation von Schnittstellen und Datenaustauschformaten:
Anhand der Einordnung der EDA-Tools in die Wertschöpfungskette sollten notwendige Schnittstellen und geeignete Datenaustauschformate spezifiziert werden, um einen reibungslosen Austausch zwischen den Komponenten sicherzustellen.
- Förderung des multiplikativen Einsatzes und der Interoperabilität:
Es sollte geprüft werden, wie standardisierte Datenaustauschformate (z. B. IPC2581) genutzt werden können, um die Projektergebnisse weiterverwertbar zu machen und den Austausch mit anderen Forschungsvorhaben im Bereich der KI-gestützten Entwurfsautomatisierung zu fördern.

Problemstellung

Eine zentrale Herausforderung bestand darin, geeignete EDA-Tools auszuwählen und zu integrieren, die den spezifischen Anforderungen der Anwendungsebene entsprachen. Es sollte sichergestellt werden, dass diese Tools eine kohärente und effiziente Wertschöpfungskette ermöglichen und sich nahtlos in bestehende sowie zukünftige Automatisierungsprozesse einfügen konnten.

Darüber hinaus war es notwendig, geeignete Schnittstellen und Datenaustauschformate zu spezifizieren, um eine störungsfreie Zusammenarbeit und Datenkommunikation zwischen den verschiedenen Werkzeugen und Projekten zu gewährleisten. Besonders im Kontext der Zusammenarbeit mit anderen Forschungsprojekten sollte eine Standardisierung angestrebt werden, um eine nachhaltige und breit anwendbare Lösung sicherzustellen.

Lösungsweg und Ergebnisse

Im Rahmen von TB 1.1.19 wurde eine umfassende Bestandsaufnahme der Datenformate und Schnittstellen durchgeführt, die im Entwicklungsprozess der progressiven KI-Wertschöpfungskette erforderlich sind. Ziel dieser Erhebung war es, geeignete Austauschformate und eine Basisstruktur für den Datentransfer zwischen den beteiligten Systemen und den KI-Modulen zu definieren. Darauf aufbauend wurden folgende Schritte und Ergebnisse erzielt:

1. Auswahl geeigneter EDA-Tools: Die beiden EDA-Tools Zuken eCADSTAR und Altium Designer wurden aufgrund ihrer Kompatibilität mit den Projektanforderungen und der Erfahrungen

der Technischen Universität Berlin (TUB) ausgewählt. Die Wahl von Zuken eCADSTAR wurde durch die Partnerschaft mit Zuken unterstützt, während für den Altium Designer das flexible Extension-System den Ausschlag gab, dass eine einfache Anbindung der KI-Module ermöglicht.

2. Festlegung und Anpassung der Datenformate: Nach der Analyse des Entwicklungsprozesses und der zu entwickelnden KI-Module wurden spezifische Datenformate ausgewählt. Für den Datenaustausch mit Zuken wurde auf die proprietären Formate RIF und ERF zurückgegriffen, die PCB-Design-Daten sicher und effizient speichern. Zudem wurde CSV als Austauschformat zur Kodierung von PCB-Daten für das Training der KI-Module etabliert.
3. Spezifikation der Tool-Schnittstellen und Implementierung der Verbindungen: Es wurden Schnittstellen zwischen den einzelnen Projektkomponenten spezifiziert und implementiert, um eine stabile Datenübertragung sicherzustellen. Die wichtigsten Verbindungen umfassen:
 - Eine REST-API und die ONNX Runtime API für die Kommunikation zwischen den Python-basierten KI-Modulen und dem in C++ entwickelten Demonstrator.
 - Eine Batch-Schnittstelle, die von Partner 04-ZUKEN für den Zugang zu eCADSTAR und dessen PI-Simulationssoftware bereitgestellt wurde.
 - Die Möglichkeit der Nutzung von Extensions im Altium Designer, um eine direkte Datenübernahme und Steuerung der KI-Module zu ermöglichen.
4. Entwicklung einer Wertschöpfungskette in Form eines Datenflussmodells: Basierend auf der Bestandsaufnahme und den Schnittstellenspezifikationen wurde ein Datenflussmodell entwickelt. Dieses Modell beschreibt die Übertragung der PCB-Design-Daten von den EDA-Tools zu den KI-Modulen und die anschließende Rückführung der Ergebnisse. Dies legt den Grundstein für eine effiziente Verarbeitung und Weiterverwendung der Daten und Ergebnisse entlang der Wertschöpfungskette.
5. Förderung des multiplikativen Einsatzes: Die Umsetzung der Punkte 2 und 3 trägt wesentlich zur Multiplikation der entwickelten Lösungsansätze bei, indem sie sicherstellt, dass die implementierten Datenformate und Schnittstellen für verschiedene Anwendungen und Systemkomponenten nutzbar sind.

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 1.2.19: KI-Einsatzszenarien (19-TUB)

Ziele

- Es sollte untersucht werden, welche potenziellen Einsatzszenarien für Algorithmen und Methoden der künstlichen Intelligenz (KI) im Designflow der Anwendungsebene 1 geeignet sind.
- Die identifizierten Szenarien sollten spezifiziert werden, um eine fundierte Grundlage für die Entwicklung und Implementierung entsprechender KI-Methoden zu schaffen.
- Es war sicherzustellen, dass die definierten Einsatzszenarien zur Optimierung der Wertschöpfungskette der Anwendungsebene 1 beitragen können.

Problemstellung

Es stellte sich die Herausforderung, geeignete Einsatzmöglichkeiten für KI-Methoden im Designflow der Anwendungsebene 1 zu identifizieren, die den spezifischen Anforderungen der anvisierten Wertschöpfungskette gerecht werden. Angesichts der Vielzahl potenzieller KI-Techniken war es erforderlich, deren Anpassung an komplexe technische Prozesse wie die Optimierung von Power Delivery Networks (PDNs) zu prüfen. Dies erforderte eine enge Abstimmung mit Partnern, um sowohl die technische Machbarkeit als auch den wirtschaftlichen Nutzen sicherzustellen.

Lösungsweg und Ergebnisse

Im Austausch mit dem Partner 04-ZUKEN wurde das Optimieren von Power Delivery Networks (PDNs) als vielversprechendes Einsatzszenario für KI-Algorithmen identifiziert.

1. Definition des Optimierungsszenarios:

- PDNs müssen sicherstellen, dass die Impedanz an den Power-Pins der integrierten Schaltkreise (ICs) bestimmte Zielwerte einhält.
- Diese Zielwerte können durch die Auswahl und Platzierung von Abblockkondensatoren erreicht werden.

2. Möglicher Einsatz von KI-Methoden:

- Reinforcement Learning (RL) und genetische Algorithmen wurden als potenzielle Ansätze zur Optimierung der Anzahl und Platzierung von Abblockkondensatoren identifiziert.
- Ziel dieser Optimierungen ist es, die Kosten und Effizienz des Designs zu verbessern, indem die Anzahl der eingesetzten Kondensatoren minimiert wird, ohne die Funktionalität zu beeinträchtigen.

Dieser Teilbeitrag legte den Grundstein für den Einsatz moderner KI-Algorithmen in einem zentralen Designprozess der Anwendungsebene 1 und zeigte vielversprechende Ansätze für eine spätere Implementierung und Validierung auf.

3.1.3 Teilaufgabe 1.3: KI-Module/KI-Algorithmen/Analyse Synergien

Die Voraussetzungen für Erweiterung/Anpassung von Entwurfs-/Entwicklungsabläufen + KI-Integration (Integrationsstiefe/Modularität) mussten analysiert und für das geplante Umsetzungskonzept dokumentiert werden. Für die KI-Integration standen verschiedene Open-Source KI-Frameworks zur Verfügung. Die Bewertung der synergetischen Verwendbarkeit der in Frage kommenden Frameworks und die Definition einheitlicher Datenformate bzw. deren Anpassung an spezielle KI-Algorithmen basierten auf den bisherigen Erfahrungen der Forschungspartner. Die Spezifikation der für progressivKI geeigneten KI-Algorithmen beruhte ebenfalls auf Vorarbeiten der Forschungspartner.

Die Bewertung und Analyse verschiedener ML- und KI-Algorithmen sowie die Entwicklung von Konzepten zur Realisierung von KI-Modulen für die zwei geplanten Anwendungsebenen stellt eine notwendige Voraussetzung dar. Die Erstellung eines Konzeptes für einen modularen KI-Baukasten zur Entwicklung von anwendungsspezifischen Lösungen beruht auf diesen Bewertungen und Analysen. Dabei kommt dem im Vorhaben bereits vorhandenen Keras/Tensorflow TestClusters zur Umsetzung von KI-Algorithmen eine hohe Bedeutung zu. Ansätze zu Kriterien für die Akzeptanz von KI-basierten Entwurfsvorschlägen im eda-Bereich müssen noch entwickelt werden. Testverfahren zur Zuverlässigkeit von KI-Algorithmen mit Bezug auf die Integration von Regelwerken und Synergien mit prädiktiven Algorithmen mussten vollständig neu entwickelt werden.

Teilbeitrag 1.3.19: KI-Konzept für die anvisierte Anwendungsebene #1 (19-TUB)

Ziele

Identifikation geeigneter KI-Methoden für spezifische Einsatzszenarien

Es galt, geeignete KI-Methoden zu identifizieren und auszuwählen, die optimal auf die zuvor definierten Einsatzszenarien und Anforderungen abgestimmt sind, um die Effizienz und Funktionalität der Anwendung zu maximieren.

Problemstellung

Die Realisierung der definierten Einsatzszenarien erforderte die Auswahl von KI-Methoden, die nicht nur den spezifischen Anforderungen der Anwendungsebene entsprachen, sondern sich auch flexibel an die projektspezifische Infrastruktur anpassen ließen. Dabei war es entscheidend, Algorithmen und Verfahren zu identifizieren, die die gestellten Aufgaben effizient bewältigen konnten und zugleich mit den technischen Gegebenheiten sowie den Anforderungen der Projektpartner kompatibel waren.

Eine zusätzliche Herausforderung lag darin, sicherzustellen, dass die ausgewählten KI-Methoden eine störungsfreie Datenkommunikation mit bestehenden Tools und Schnittstellen ermöglichten, ohne die Leistung oder Sicherheit des Systems zu beeinträchtigen.

Lösungsweg und Ergebnisse

Im Rahmen von TB 1.3.19 wurde eine fundierte Literaturanalyse und Konzepterstellung durchgeführt, um geeignete KI-Methoden zur Lösung von Power-Integrity (PI)-Problemen in der Anwendungsebene #1 zu ermitteln und anzupassen. Der Schwerpunkt lag dabei auf der Entwicklung eines modularen Ansatzes, der verschiedene KI-Techniken kombiniert, um eine

effiziente Impedanzanalyse und Kondensatorplatzierung zu ermöglichen. Die wichtigsten Ergebnisse sind im Folgenden zusammengefasst:

1. Literaturanalyse und Auswahl der PI-KI-Methoden: Zu Beginn wurde eine umfassende Literaturanalyse zu bestehenden KI-Methoden im Bereich Power Integrity (PI) durchgeführt, die relevanten Arbeiten im Bereich Impedanzanalyse und Decap-Platzierung analysierte. Ein besonders richtungsweisendes Paper war "Fast PDN Impedance Prediction Using Deep Learning" von Zhang et al., das als Ausgangspunkt für die schnelle Impedanzvorhersage diente. Für die Kondensatorplatzierung wurden genetische Algorithmen und Reinforcement Learning als mögliche Lösungsansätze identifiziert. Aufgrund der Effizienz und der etablierten Resultate von Reinforcement Learning wurde dieser Ansatz für das Projekt favorisiert.
2. Entwicklung eines Zwei-Stufen-Konzepts für KI-basierte Impedanzanalyse und Kondensatorplatzierung: Auf Basis der Analyse entstand ein Zwei-Stufen-Konzept zur Lösung der PI-Probleme:
 - Stufe 1: In einem ersten Schritt wurde ein Convolutional Neural Network (CNN) als KI-Modul für die schnelle Impedanzanalyse konzipiert, das die aufwändige Berechnung eines klassischen PI-Simulators ersetzt. Dieses CNN-Modell bietet eine erheblich schnellere Möglichkeit, Impedanzwerte für verschiedene Board-Konfigurationen zu simulieren und stellt damit eine flexible Alternative zur herkömmlichen, rechenintensiven Simulation dar.
 - Stufe 2: Das Impedanzanalyse-CNN wurde in einem zweiten Schritt als Bewertungsgrundlage für einen Reinforcement Learning (RL)-Agenten verwendet. Dieser RL-Agent, der in der Lage ist, DeCap-Positionen eigenständig zu optimieren, wird mit der CNN-basierten Impedanzanalyse trainiert. Die Verwendung des schnellen CNN-Modells ermöglicht ein schnelles Training des RL-Agenten, da die für den Agenten erforderliche große Anzahl an Trainingsschritten nur durch schnelle Impedanzberechnungen realisiert werden kann.

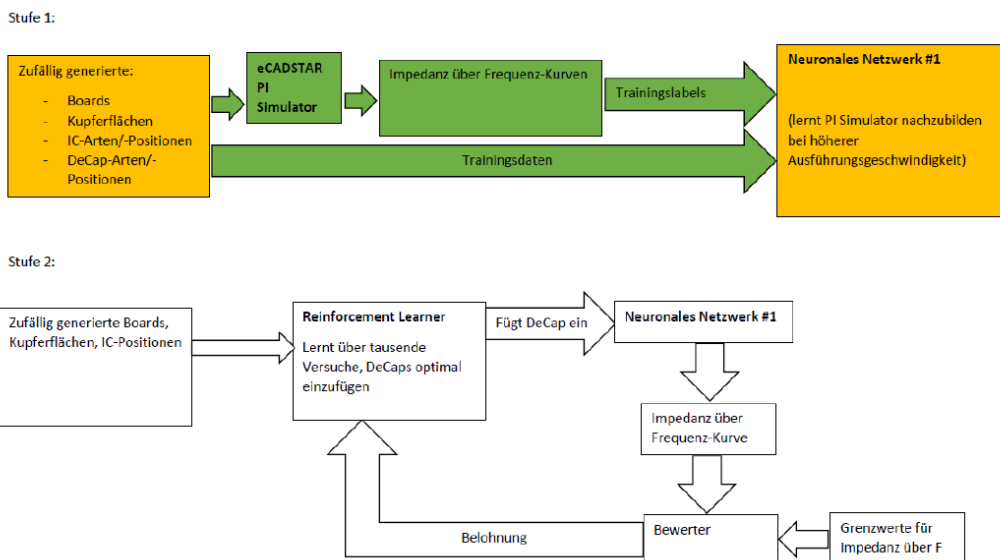


Abbildung 10: Darstellung des Zwei-Stufen-Konzepts: In Stufe 1 wird ein Ersatzmodell eines Impedanzsimulators trainiert. In Stufe 2 optimiert ein Reinforcement-Lerner die Auswahl und Platzierung von DeCaps mithilfe des Ersatzmodells.

3. Anpassungen der Spezifikationen basierend auf Frequenzbereich und Kondensatortypen: Die Spezifikationen der KI-Modelle wurden fortlaufend überprüft und angepasst, um den spezifischen Anforderungen des PI-Designs gerecht zu werden. Hierbei spielten vor allem

Variationen im Frequenzbereich und die Anzahl und Typen der zu platzierenden Kondensatoren eine Rolle. Diese Anpassungen stellten sicher, dass das KI-Modell flexibel und präzise auf unterschiedliche PCB-Designanforderungen reagiert.

4. Abstimmung und Validierung der Schnittstellen für die Integration der PI-KI-Module: Schließlich wurden die Schnittstellen zur Integration der entwickelten PI-KI-Module in die bestehende Toolchain mit den Projektpartnern abgestimmt. Dies gewährleistet, dass die Impedanzanalyse und die Kondensatorplatzierungs-Methoden sowohl technisch als auch organisatorisch kompatibel sind und den Anforderungen der Anwendungsebene #1 gerecht werden.

Durch die modulare Struktur des Konzeptes ist die KI-basierte Lösung für PI-Probleme anwendungsübergreifend und flexibel nutzbar, was eine Grundlage für den späteren Einsatz in unterschiedlichen Anwendungsfällen bietet.

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

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

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

Die folgenden Themen mussten im Detail bearbeitet werden:

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

Teilbeitrag 1.4.19: Detaillierte Beschreibung der KI-Module für die Anwendungsebene #1(19-TUB)

Ziele

Festlegung der erforderlichen KI-Module für die Wertschöpfungskette

Es sollte die Identifikation und Festlegung aller KI-Module erfolgen, die für die Implementierung und Funktionsfähigkeit der Wertschöpfungskette in der Anwendungsebene #1 erforderlich waren.

Definition der notwendigen API-Schnittstellen

Jedes identifizierte KI-Modul sollte mit den erforderlichen API-Schnittstellen spezifiziert werden, um eine effiziente und nahtlose Kommunikation innerhalb der Wertschöpfungskette sowie mit den Systemen der Projektpartner zu gewährleisten.

Abstimmung und Integration in die Partnerarchitektur

Die KI-Module und APIs sollten so entwickelt werden, dass sie den Anforderungen der Partner entsprechen und sich nahtlos in deren technische Infrastruktur und Prozesse integrieren lassen.

Problemstellung

Die Herausforderung bestand darin, die für die Wertschöpfungskette der Anwendungsebene #1 notwendigen KI-Module präzise zu identifizieren und festzulegen, um deren reibungslose Integration und Funktionsfähigkeit sicherzustellen. Es galt, die API-Schnittstellen so zu spezifizieren, dass sie eine effektive Kommunikation zwischen den Modulen ermöglichten und gleichzeitig die Interoperabilität mit den Systemen der Partner gewährleistet wurde. Darüber hinaus war es entscheidend, dass die festgelegten Module und APIs die Anforderungen der Partnerarchitektur erfüllten und an die spezifischen technischen Gegebenheiten angepasst wurden, um die Effizienz und Skalierbarkeit der Wertschöpfungskette zu maximieren.

Lösungsweg und Ergebnisse

In TB 1.4.19 lag der Schwerpunkt auf der Integration der im vorhergehenden Teilbeitrag spezifizierten KI-Module in gängige PCB-Entwurfsprozesse der industriellen Anwendungsebene #1. Der Design Flow wurde auf die verschiedenen, häufig verwendeten Entwurfswerkzeuge wie Zuken eCADSTAR und Altium Designer abgestimmt. Die Implementierung der KI-Module für Impedanzanalyse und Kondensatorplatzierung erfolgte mit spezifischen Anpassungen, um die reibungslose Integration in die Workflows der Zielplattformen zu gewährleisten. Die wichtigsten Ergebnisse lassen sich wie folgt darstellen:

1. Anpassung und Entwicklung der KI-Module für Anwendungsebene #1: Auf Basis der in TB 1.3.19 entwickelten Konzepte wurden spezialisierte KI-Module zur Impedanzanalyse und zur Platzierung von Kondensatoren entwickelt und implementiert. Zur effizienten Berechnung von Impedanzen wurde ein Convolutional Neural Network (CNN) in der Trainingsumgebung TensorFlow/Keras initialisiert. Im weiteren Projektverlauf erfolgte ein Wechsel zu PyTorch, um von der breiten Akzeptanz und aktuellen Weiterentwicklung dieser Plattform in der Forschung zu profitieren.
 - Die Implementierung des Reinforcement Learning (RL)-Moduls für die Kondensatorplatzierung erfolgte in einer Custom OpenAI/Gym-Umgebung, die das PCB-Layout und Positionen für ICs und Decaps modelliert. Nach der Einstellung des Supports von OpenAI/Gym wurde der kompatibelere Fork Gymnasium verwendet, um die Kontinuität der Entwicklungsumgebung zu sichern.
 - Für den RL-Agenten wurde zunächst mit TF-Agents gearbeitet, um eine nahtlose Verbindung zum CNN-Modul zu gewährleisten. Nach dem Wechsel zu PyTorch und den Herausforderungen bei der Agenten-Integration mit TorchRL wurde erfolgreich auf

Stable-Baselines3-Contrib umgestellt, was die Entwicklung beschleunigte und die Agenten-Leistung optimierte.

- Integration und Spezifikation von Schnittstellen: Die ausgewählten Entwurfswerkzeuge Zuken eCADSTAR und Altium Designer wurden eingehend untersucht, um geeignete Andockpunkte für die KI-Module zu identifizieren und zu spezifizieren. Zur Anbindung des Zuken PI-Simulators wurde eine Batchsteuerung entwickelt und durch direkte Schnittstellenanpassungen für die Datenextraktion von Simulatordaten optimiert. Zudem wurde die Kommunikation der KI-Module mit Altium Designer über die Erweiterungsfunktion der Software realisiert, was eine reibungslose Interaktion zwischen den Modulen und den Design-Tools sicherstellte.
- Definition und Optimierung der Eingabe- und Ausgabeformate: Ein strukturierter Datenfluss zur Unterstützung der KI-Wertschöpfungskette wurde etabliert, wobei Formate wie RIF/ERF für die Speicherung von PCB-Design-Daten und CSV-Dateien für die codierten Trainingsdaten der KI-Module zum Einsatz kamen. Diese Spezifikationen wurden durch fortlaufende Tests und Anpassungen erweitert, sodass alle Datenformate sicher und effizient in die Entwurfsumgebung eingebettet wurden.




Abbildung 11: Darstellung der PCBs, modelliert als Matrizen, die im CSV-Format gespeichert werden.

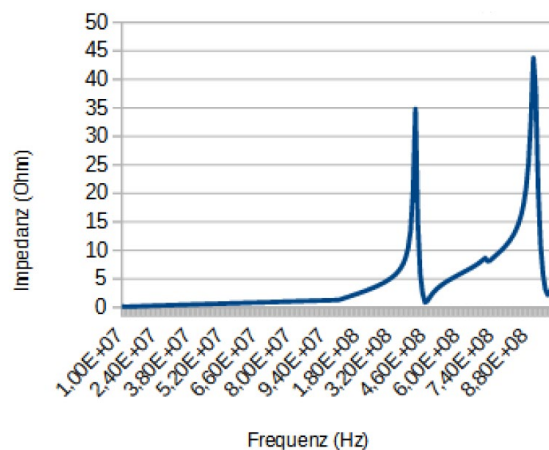


Abbildung 12: Beispiel einer Impedanzkurve, die typische Frequenzverläufe und Resonanzpunkte veranschaulicht.

- Entwicklung eines kontinuierlichen Design Flows: Die festgelegten Module und Schnittstellen wurden schließlich in einen integrierten Design-Flow überführt, der eine multiplikative Wiederverwendung und nahtlose Skalierbarkeit ermöglicht. Damit wurde eine stabile Wertschöpfungskette geschaffen, die eine effiziente Integration von KI-gestützten Designprozessen im industriellen Kontext fördert.

Die sorgfältige Anpassung an die spezifischen Anforderungen der Entwurfsplattformen und die Flexibilität bei der Wahl der KI-Bibliotheken gewährleisten die langfristige Nutzbarkeit und kontinuierliche Optimierbarkeit der entwickelten Module.

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 Rechteverwaltung zur Garantie von Datensouveränität integraler Bestandteil der modularen KI-Plattform sein. Entsprechend dem Konzept der KI-Plattform, wurde auch das Datenmanagement in Form flexibler Module implementiert. Das in diesem Arbeitspaket zu etablierende Datenmanagement für das Training der Algorithmen wurde auch zu deren Verifikation eingesetzt.

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

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

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

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

Beim Datenimport mussten daher unterschiedliche Bedarfe und unterschiedliche Komplexitätsstufen der Probleme beim potenziellen Kunden zu berücksichtigen, um die Module zum Datenimport so zu gestalten, dass für den Kunden Lösungen mit einer großen Hebelwirkung geschaffen und nutzbar gemacht werden können und das Domainwissen adäquat erschlossen

werden kann. Hier kam der – ebenfalls KI-basierten - Bildverarbeitung auf unterschiedlichen Ebenen eine wichtige Rolle für die Qualitätskontrolle und als Wissensspeicher zu. Von großer Bedeutung war hier die Zeta-Suite.

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

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

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

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

Die folgenden F+E Themen wurden in AP2 adressiert:

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

Geplante Ergebnisse von AP2 waren:

- Im Rahmen dieses Arbeitspakets standen mehrere zentrale Ergebnisse im Fokus. Zunächst erfolgte die Definition und Implementierung von Schnittstellenmodellen, die spezifisch auf die Entwurfs- und Simulationsumgebungen, Datenbanken sowie Dateiformate wie Bilder

oder Textdokumente abzielten. Dabei wurde ein besonderes Augenmerk auf Verfahren zum Datenschutz gelegt. Die Schaffung einheitlicher Schnittstellen und Austausch-Dateiformate für sämtliche anfallende Daten sowie die Festlegung von Standards zur Beschaffenheit dieser Daten waren zentrale Aspekte.

- Das Arbeitspaket beinhaltete ebenfalls die Aufbereitung von Test- und Lerndaten aus bestehenden Datenbanken sowie durch Simulationen und Messungen an Demonstratoren. Modelle aus bereits vorhandenem Erfahrungswissen und Regelwerken wurden entwickelt, wobei die Annotation, Kontextualisierung und Klassifikation der Daten anhand von Metadaten, Messergebnissen und der Bewertung durch Entwicklerexperten im Fokus standen. Eine umfassende Evaluation und Bewertung der KI-Ausgaben war ebenfalls Teil der geplanten Ergebnisse.
- Ein wesentlicher Bestandteil bildete der Meta-Algorithmus, der Metriken zur Beschreibung von Problemschwierigkeiten und des Abstands von Problemen im Sinne eines Umlernprozesses sowie zur Bewertung von Lernprozessen und Datenqualität integrierte. Dieser Meta-Algorithmus beinhaltete auch Entscheidungsmethodiken zur Auswahl von Algorithmen, die bei der Vorgabe einer Problem Instanz zielführend eingesetzt werden konnten. Zusätzlich wurden Schnittstellen geschaffen, um den Meta-Algorithmus auf dem gesamten Spektrum der über die modularen KI-Plattform bereitgestellten KI-Verfahren operieren zu lassen.
- Ein weiterer Schwerpunkt lag auf applikationsspezifischen Trainings- und Lernmodulen, die auf den Use Cases für die Anwendungsebenen #1 bis #2 sowie den gewonnenen Daten und erstellten Modellen basierten.

3.2.1 Teilaufgabe 2.1: Definition und Planung von Schnittstellenmodellen

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

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

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

Zusätzlich wird durch die Möglichkeit, beim Endanwender verschiedenste Werkzeuge verwenden zu können, ein Investitionsschutz für Eigenentwicklungen sichergestellt und eine die Erweiterung

von eigenen Modulen vereinfacht. Diese durch den progressivKI-Ansatz sichergestellte Interoperationalität unterscheidet sich deutlich von allen bekannten KI-gestützten Entwurfsprozessen.

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

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

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

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

- Breite Berücksichtigung unterschiedlicher Arten/Typen von Daten (z.B. Schaltplan/Layout/Stückliste/Datenblatt-Parameter (min. - max. - typisch)). Es sind daher viele unterschiedliche (teils inkompatible) Datenformate (z.B. unterschiedliche EDA-Werkzeuge nutzen unterschiedliche Datenformate) einzubinden. Um Insellösungen zu vermeiden, müssen so gut es geht einheitliche Beschreibungen für Schnittstellen im Vorhaben definiert werden.
- Definition und Implementierung der Schnittstellenmodelle zu den applikations- und anwender-spezifischen Entwurfs- und Simulationsumgebungen, Datenbanken und Dateiformaten für Bilder oder Text sowie von Messsystemen, Datenschutz.
- Definierte Schnittstellen zwischen den unterschiedlichen Bereichen EMV, Layout, Schematic und Mechanik, die Möglichkeiten für eine Implementierung von KI sind evaluiert und geplant im beispielhaften Entwurfsprozess.
- IP-Schutz Anforderungen zum Datenaustausch über Unternehmensgrenzen hinweg.
- Ermittlung der Anforderungen und Definition von Schnittstellen um einen umfassenden Input für die geplanten KI-Module durch alle relevanten Parameter/Dateiformate des gesamten Wertschöpfungsprozess zu ermöglichen.
- Festlegung grundsätzlicher Anforderungen an die Schnittstellenbeschaffenheit zwischen den einzelnen KI-Modulen, sowie die notwendigen Beschreibungen der Ein- und Ausgangsschnittstellen des Gesamtsystems. Basierend auf den Anforderungen und Tests muss dann die bestmögliche Kombination gewählt werden.

Teilbeitrag 2.1.19: Datenbasis DesignFlow - Anwendungsebene #1 (19-TUB)

Ziele

Definition und Spezifikation von Schnittstellen für den Designflow

Ziel war es, die erforderlichen Schnittstellen zu identifizieren und zu spezifizieren, die notwendig waren, um die Datenbasis für den Designflow der Anwendungsebene #1 bereitzustellen und effizient zu verwalten.

Entwicklung einer Datenbasis und notwendiger Schnittstellen für Layoutsysteme

Die relevanten Daten des Designflows sollten im Layoutsystem identifiziert werden, um eine robuste Datenbasis zu erstellen und passende Schnittstellen zu EDA-Tools zu entwickeln, die eine Extraktion und Speicherung dieser Daten ermöglichten.

Schnittstellenspezifikation für Analysysteme und KI-Module

Basierend auf den Anforderungen der Analysysteme und KI-Module sollten Schnittstellen entwickelt werden, die die erforderlichen Daten für Berechnungen aus der Datenbasis extrahieren und deren Ergebnisse speichern konnten. Wo möglich, sollten standardisierte Schnittstellen genutzt werden, um die Interoperabilität zu erhöhen.

Problemstellung

Die zentrale Herausforderung bestand darin, spezifische und effiziente Schnittstellen zu EDA-Tools zu definieren, die die für den Designflow der Anwendungsebene #1 notwendigen Daten bereitstellen und speichern konnten. Dabei mussten Daten aus dem Layoutsystem sowie Analysystemen und KI-Modulen konsistent extrahiert und verarbeitet werden, um eine einheitliche und verlässliche Datenbasis zu gewährleisten. Zusätzlich war es wichtig, dass die entwickelten Schnittstellen den Anforderungen der verschiedenen Systeme entsprachen und möglichst standardisiert gestaltet wurden, um die Integration in die Infrastruktur der Projektpartner und die langfristige Nutzbarkeit zu unterstützen.

Lösungsweg und Ergebnisse

Im Teilbeitrag 2.1.19 wurde der Schwerpunkt auf die Entwicklung eines effizienten Schnittstellenkonzepts gelegt, um die Integration von KI-Modulen in den industriellen PCB-Entwurfsprozess zu ermöglichen. Dabei wurden wesentliche Voraussetzungen für die Anbindung von Entwurfswerkzeugen und die Darstellung von KI-Ergebnissen im Software-Demonstrator der TU Berlin (BEREDA) geschaffen. Die wichtigsten Ergebnisse lassen sich wie folgt zusammenfassen:

1. Analyse und Erweiterung der unterstützten Datenformate:

Basierend auf den in AP 1.1.19 festgelegten Datenformaten wurden die proprietären Formate RIF/ERF von Zuken detailliert analysiert, um die Verarbeitung und Generierung von PCB-Design-Daten zu ermöglichen.

- Besondere Aufmerksamkeit wurde auf die Kodierung von PCB-Layout-Informationen wie Form, Größe und IC-Position unter Berücksichtigung der Netzstrukturen gelegt. Diese Erkenntnisse waren essenziell für die Implementierung eines eigenen Datengenerators, der neue Layout-Daten im RIF/ERF-Format erstellen kann.
- Parallel dazu wurden die Datenstrukturen des RIF/ERF-Formats analysiert, um Layout-Daten innerhalb des Demonstrators BEREDA darzustellen. Diese Fähigkeit ermöglicht die Visualisierung und Validierung der KI-Ergebnisse direkt im Software-Demonstrator.

2. Spezifikation von Schnittstellen für KI-Module:

Zur nahtlosen Integration der KI-Module in den PCB-Entwurfsprozess wurden zwei zentrale APIs spezifiziert:

- Eine REST-API, die allgemein für die externe Anbindung von Python-basierten KI-Modulen geeignet ist, ermöglicht eine modulare und flexible Nutzung der KI-Ergebnisse.
 - Eine ONNX Runtime API, die eine native Einbindung von KI-Modulen im ONNX-Format in die C++-basierte Demonstrator-Software ermöglicht. Diese Methode verbessert die Ausführungsgeschwindigkeit der KI-Module erheblich und sorgt für eine robuste Integration in den industriellen Anwendungskontext.
- 3. Implementierung von Funktionen in BEREDA zur Integration und Visualisierung:**
Die Funktionalitäten des Software-Demonstrators BEREDA wurden so erweitert, dass sie als zentrale Plattform zur Integration der Projektergebnisse dienen können. Besonders im Fokus stand die Darstellung der aus den KI-Modulen generierten Layout- und Simulationsdaten. Damit bildet BEREDA eine Brücke zwischen den Ergebnissen der KI-Module und den industriellen PCB-Entwurfswerkzeugen.
- 4. Zusammenarbeit mit Partnern und iterativer Ausbau der Schnittstellen:**
In enger Abstimmung mit Partner 04-ZUKEN wurden die Anforderungen an die Schnittstellen kontinuierlich überprüft und angepasst. Dies schloss die Erweiterung der bestehenden Konzepte für die Übermittlung zusätzlicher Layerstack-Informationen und CSV-basierte Datenformate ein, die eine effiziente Kommunikation zwischen BEREDA und den kommerziellen Simulations- und Entwurfswerkzeugen sicherstellen.
- 5. Integration in die Tool-Suite BEREDA:**
Mit den definierten Schnittstellen und Erweiterungen wurde die Grundlage gelegt, um Projektergebnisse wie die Impedanzanalyse und die Kondensatorplatzierung nahtlos in BEREDA zu integrieren. Diese Maßnahmen tragen dazu bei, die Leistungsfähigkeit der entwickelten KI-Module im Rahmen von AP4 (Erstellung der Anwendungsebene PCB-Entwurf) zu demonstrieren.

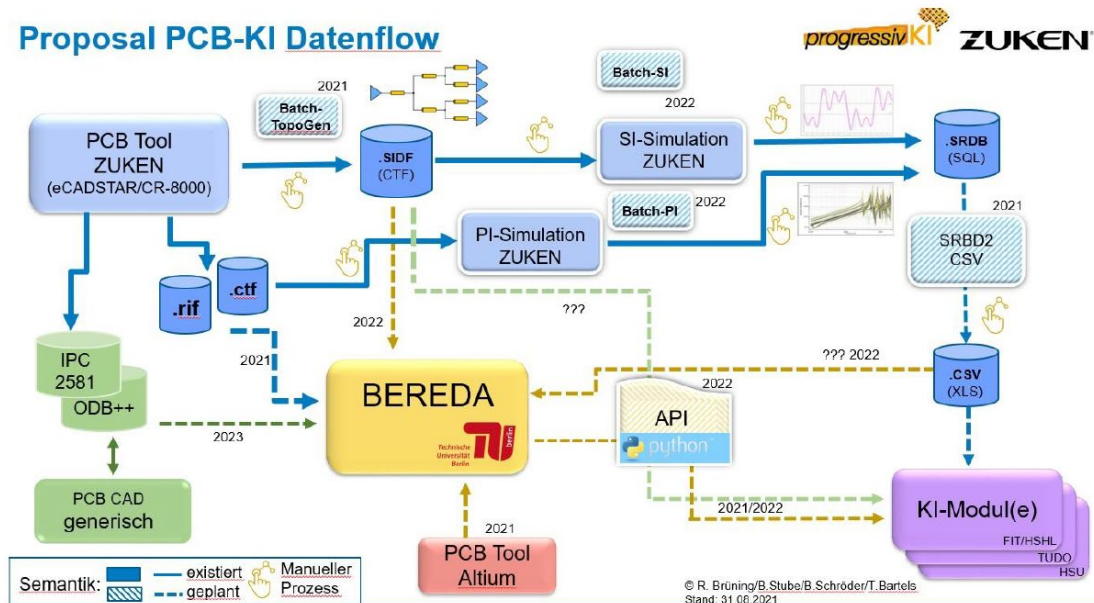


Abbildung 13: Spezifiziertes Schnittstellenkonzept und vorgeschlagener Workflow, der die Interaktion zwischen KI-Modulen, Analysesystemen und EDA-Tools beschreibt.

Durch diese Maßnahmen wurde ein grundlegender Daten- und Schnittstellenfluss etabliert, der es ermöglicht, KI-Module effizient in den Entwurfsprozess einzubinden und deren Ergebnisse in einer verständlichen und praxisnahen Weise darzustellen. Die Weiterentwicklung der BEREDA-Plattform als zentraler Demonstrator sichert dabei eine nachhaltige Nutzbarkeit der Projektergebnisse.

3.2.2 Teilaufgabe 2.2: Test-/Lerndatenerzeugung

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

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

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

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

- Datenakquise und Trainingsdatenerzeugung für die AW #1 - #2
- Datenvorverarbeitung und Datentransformation zur Erzeugung des Ziel-Datensatzes für das Training von künstlichen Neuronalen Netzen auf Datenblättern + Deskriptive Datenanalyse auf Datenblättern
- Daten-Separierung bei der Erstellung der KI durch feste Regeln (durch z.B. feste DesignRules oder physikalischen Gesetze) und klassische Trainingsdaten
- Kombiniertes Ansatz aus Simulationsdaten und gemessenen Daten zur Erzeugung von hinreichend großen Datensätzen für ML
- Datenakquise durch Simulationen und realen Messdaten - Entwicklung von Konzepten zur Herstellung von EM- und thermischen Trainingsdaten für die KI-Module
- Batch-Simulation und -Parametervariationsmethodik zur externen automatischen Ansteuerung von Simulationswerkzeugen (HPC) + Definition von Metriken zur Bewertung von Simulationsdaten
- Einbindung von physikalischen Gesetzen und Design-Rules
- Verfahren zur Erstellung von Testdatensätzen zur Qualitätsbeurteilung KI-basierter Entwurfsentscheidungen/-vorschlägen
- Konzept zur Erstellung der Trainingsdaten, dass Qualität und Quantität der benutzten Trainingsdaten berücksichtigt
- Bewertungsverfahren für die zu erwartende wachsende Menge an Lern-(Trainings)-daten
- Werkzeuge zur Bewertung und Verwaltung (Lifecycle-Management) der wachsenden Menge an Trainingsdaten
- Management zur projektübergreifenden Bereitstellung von Lerndaten.

3.2.3 Teilaufgabe 2.3: Modellbildung + Klassifikation + Signalauswertung

Die Vielzahl der Einzelaufgaben, für die KI-basierte Automatisierungslösungen erarbeitet werden sollen (neben den wertschöpfungsketten-übergreifenden Methoden), müssen ihrerseits systematisch herausgearbeitet werden, um zielführende Lösungen vorhalten zu können. Von besonderer Bedeutung für die Wertschöpfung im EDA-Bereich waren die in diesem TA untersuchten Automatisierungsansätze für Klassifikationsprobleme, Probleme der Signal- und Datenauswertung und der automatisierten Modellbildung.

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

Aus Gründen des IP-Schutzes konnten lediglich Datenaustauschformate und Applikationsschnittstellen zwischen den potentiellen Anwendern geteilt werden. Es musste daher eine generalisierte, vielseitige Plattform erstellt werden, ohne IP-Konflikte lösen zu müssen.

Daten in vereinbarten Standards und vereinbarter Qualität müssen vorliegen. Konkrete Ziele für den Einsatz der KI wurden vorgegeben, allerdings benötigen die meisten Algorithmen (z.B. Supervised Learning mit Neuronalen Netzen) vorverarbeitete Trainingsdaten, welche die Algorithmen zum Erlernen bestimmter Muster nutzen, oder aber zum Testen und zur Validierung der KI genutzt werden.

Die Generierung von applikations-spezifischen Modellen auf der Basis bestehender Erfahrungen und Regelwerke musste sichergestellt werden. Die Annotation und Kontextualisierung sowie Klassifikation der zur Verfügung stehenden Daten erfolgte anhand von Metadaten, Messergebnissen und der Bewertung durch Experten. Darüber hinaus musste eine Evaluation und Bewertung der KI-Ergebnisse erfolgen können.

Die in progressivKI adressierten Anwenderszenarien bzw. deren KI-Module sollten u.a. anhand von Simulationsdaten lernen und dadurch stetig weiterentwickelt werden können. Um eine vereinfachte Eingabe neuer Simulationsdaten zu ermöglichen, waren entsprechende Schnittstellen notwendig. Die Weiterentwicklung bzw. Schaffung neuer Schnittstellen musste sichergestellt werden können. Damit kann die Nutzung neuer Simulationswerkzeuge durch die KI-Module vereinfacht werden. Mittels dieser Schnittstellen können die notwendigen Daten zum KI-Training dann einfacher und nachhaltiger generiert werden.

Im Gegensatz zu einigen EDA-Anbietern (welche tief integrierte KI-Module in Vorbereitung haben) musste das Vorhaben KI-Module bereitstellen, die via Schnittstellen in vorhandene Werkzeugketten eingebunden werden können.

Damit ist es auch möglich, einen Datenaustausch (Vorschläge zur Entwurfsentscheidung durch KI-Module) über definierte Wertschöpfungsketten hinweg zu garantieren.

Die KI-Module aus jedem Teilbereich müssen dazu miteinander kommunizieren und die im Entwicklungsprozess zu beachtenden verschiedenen physikalischen Eigenschaften der Teilsysteme/Komponenten (z.B. elektromagnetisches und thermische Verhalten) verknüpfen können.

Folgende F+E-Arbeiten mussten für die Bearbeitung von TA2.3 im Projektverlauf durchgeführt werden:

- Anwendung von adaptierten DOE-Verfahren zur Datengewinnung
- Entwicklung von Metriken und Bewertungskriterien (Signal und Power Integrity als Gütekriterien) für (Teil-)Netzstrukturen
- Generierung von KI-konformen Regeln/Daten (Wissen) zur Bewertung von (Automotive ECU) PCB-Entwürfen
- Verfahren zur Beurteilung von applikationsspezifischem Expertenwissen für Regelwerke
- Evaluation der durch KI-Module erzeugten Entwurfsanalysen und
- -verbesserungen
- Auswahl von KI-Modulen zur Erstellung eines Frameworks für die schnelle und sichere Analyse von Schaltplänen, PCB-Layouts und Datenblättern + Definition der Software-Architektur und Datenflüsse
- Verfahren zum Benchmarking passender KI-Algorithmen
- KI-Umgebung zur schnellen Optimierung elektronischer Systeme hinsichtlich der Reduktion des Einflusses von physikalischen Kopplungseffekten
- Zur Gewinnung von Eingangsdaten für KI-Algorithmen werden Regelwerke sowie Tacit-Knowledge (inkl. Gewichtungen) aus dem Gebiet der Entwicklung elektronischer Systeme benötigt.
- Modellbildung auf Gesamtsystemebene
- Konzepte zur Spezifikation von Expertenwissen
- Anpassung bereits implementierter KI-Modelle für KFZ-Anwendungen
- Untersuchung und Vorbereitung von Klassifizierungsverfahren als späterer Bestandteil der geplanten KI-Plattformen für die Anwendungsebenen #1 - #2. Dazu wird auch eine automatisierte Übersetzung von Problembeschreibungen benötigt.
- Verknüpfung von Trainingsdaten mit Expertenwissen.
- Viele Beschreibungen von Schaltungen für elektronische Systeme werden aus Gründen des IP-Schutzes nicht als lesbare Schaltpläne vorliegen. Vielmehr ist davon auszugehen, dass diese Schaltpläne lediglich als Bilddaten zur Verfügung stehen. Es ist daher notwendig, eine Klassifikation der Bilddaten anhand von Regelwerken und Metadaten vorzunehmen.

Teilbeitrag 2.3.19: Spezifikation von software-technischen Werkzeugen (Labeling-Tools) für die Annotation von Trainingsdaten –Anwendungsebene #1 (19-TUB)

Ziele

Entwicklung von Werkzeugen zur Annotation von Trainingsdaten

Ziel war es, geeignete Labeling-Tools zu spezifizieren und bereitzustellen, um relevante Trainingsdaten aus der Datenbasis zu extrahieren und mit Expertenwissen zu annotieren.

Sicherstellung der Datenqualität und der Eignung für KI-Methoden

Die entwickelten Tools sollten sicherstellen, dass die annotierten Daten eine hohe Qualität und Relevanz aufwiesen und die Voraussetzungen für einen erfolgreichen Einsatz der KI-Methoden erfüllten.

Integration der Labeling-Tools in den Datenfluss des Projekts

Die Labeling-Tools sollten effizient in den bestehenden Datenfluss integriert werden, sodass die annotierten Daten problemlos an die vorgesehenen KI-Verfahren weitergegeben werden konnten.

Problemstellung

Für den effektiven Einsatz der geplanten KI-Methoden war es erforderlich, die Trainingsdaten aus der Datenbasis mit Expertenwissen anzureichern und entsprechend zu annotieren. Dies erforderte spezialisierte software-technische Werkzeuge zur Datenannotation, die eine zuverlässige und konsistente Kennzeichnung der Daten ermöglichten. Die Herausforderung bestand darin, Labeling-Tools zu entwickeln, die sowohl die Qualität und Konsistenz der Annotationen sicherstellten als auch reibungslos in den bestehenden Projekt-Datenfluss integriert werden konnten, um den KI-Verfahren die nötigen Daten effizient bereitzustellen.

Lösungsweg und Ergebnisse

Im Teilbeitrag 2.3.19 lag der Schwerpunkt auf der Entwicklung und kontinuierlichen Anpassung eines Datengenerators zur Erstellung von Trainingsdaten für die KI-Modelle. Diese Daten wurden automatisiert gelabelt und für die Impedanzvorhersage sowie die KI-basierte Platzierung von Decoupling Capacitors (Decaps) genutzt. Die erarbeiteten Ergebnisse sind sowohl im Kontext der technischen Zielsetzungen als auch im Hinblick auf die Problemstellung des TB präzise ausgearbeitet worden. Im Folgenden die Ergebnisse im Detail:

1. Entwicklung und Implementierung des Datengenerators

- Generierung der PCB-Geometrien:
PCB-Formen wurden als Polygone generiert, die aus 8 sternförmig angeordneten Punkten bestehen, die gleichmäßig auf unterschiedlich großen Feldern verteilt wurden (z. B. 20×20 cm, 5×5 cm).
 - ICs und Decaps wurden mithilfe von Rejection-Sampling auf diesen Formen platziert, wobei Abstände zwischen den Decaps durch die Diskretisierungsauflösung der PCBs bestimmt wurden.
 - Die Diskretisierung erfolgte abhängig von der maximalen PCB-Größe und der gewählten Eingabematrix (z. B. 16×16 für ein 20×20 cm großes PCB ergibt eine Feldgröße von 1,25×1,25 cm).
- Anzahl und Platzierung der Decaps:
 - Die Anzahl der Decaps wurde gleichmäßig in definierten Intervallen (z. B. [0,20] oder [1,20]) verteilt. Die zweite Variante ([1,20]) wurde bevorzugt, da Designs ohne Decaps oft extrem hohe Impedanzwerte aufwiesen, die das Training erschwerten.
 - Decaps wurden zufällig auf Top- oder Bottom-Layer platziert (gleichverteilte Wahrscheinlichkeit auf [0,1]).
 - Decaps wurden in Typen mit spezifischen Eigenschaften (Kapazität, ESR, ESL) unterteilt. Zwischen 6 und 10 Typen wurden mit Domänenexperten von Partner 04-ZUKEN abgestimmt.
 - Alternative Ansätze testeten die direkte Berechnung der Admittanz pro Feld in der Eingabematrix, anstelle von Decap-Typen.
- Layerstack-Variationen:
 - Layeranzahl des PCB wurde zwischen 4 und 12 variiert. Der Fokus lag jedoch darauf, Modelle für kleinere Gruppen von PCB-Designs (z. B. 4- oder 8-Lagen-PCBs) zu entwickeln, um die Modellgenauigkeit zu maximieren.

2. Labeling und Datenformate

- Die erzeugten Daten wurden in zwei Formaten bereitgestellt:
 - RIF/ERF: Zur Darstellung der Layouts im Zuken eCADSTAR und im BEREDA Software-Demonstrator.
 - Matrix im CSV-Format: Zur Verwendung als KI-Trainingseingaben.
- Automatisiertes Labeling:
 - Für jedes vom Datengenerator erstellte PCB-Design wurde durch ein Batch-File des Zuken PI-Simulators eine zugehörige Impedanzkurve generiert. Diese Impedanzkurven wurden als Labels für das Trainingsdatenset verwendet und ebenfalls im CSV-Format gespeichert.
 - Die Batch-Schnittstelle des Zuken PI-Simulators, die während der Projektlaufzeit bereitgestellt wurde, erleichterte den Datenfluss erheblich und ermöglichte eine effiziente Automatisierung der Labelgenerierung.

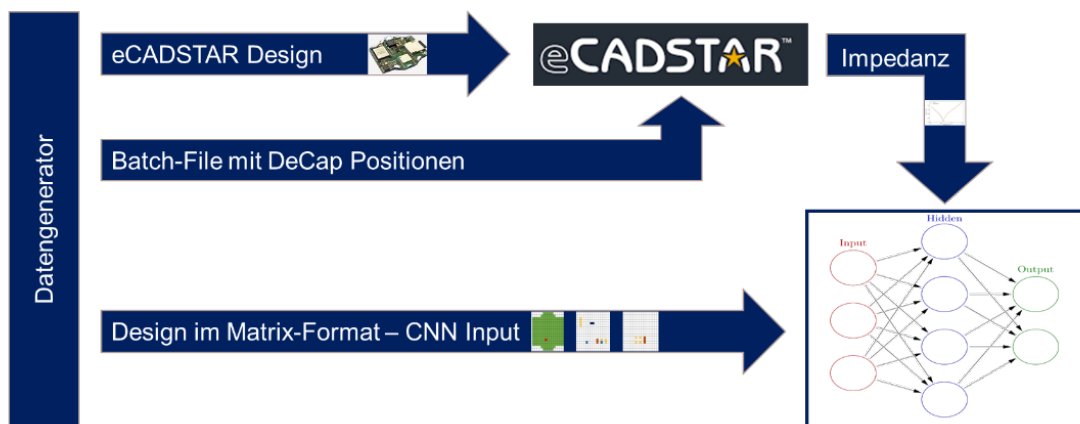


Abbildung 14: Darstellung des Datenflusses vom Datengenerator über den Impedanzsimulator bis hin zum Training des Modells.

3. Qualitätssicherung und Weiterentwicklung

- Datenbereinigung und -validierung:
Zufällig generierte und mit dem Zuken PI-Simulator gelabelte Daten wurden überprüft und bereinigt, um die Qualität der Trainingsdaten sicherzustellen.
- Fortlaufende Anpassungen des Generators:
 - Auf Grundlage der validierten Ergebnisse sowie unter Einbeziehung von Expertenwissen wurde der Trainingsdatengenerator kontinuierlich weiterentwickelt.
 - Ergänzungen wie die Möglichkeit, mehrere ICs oder unterschiedliche Layerstack-Variationen zu berücksichtigen, wurden implementiert, um die Trainingsdaten flexibler und anwendungsnäher zu gestalten.

```

1: algorithm board_shape
2:   output: polygon b
3:
4:   board_points := list of 8 random
5:                 points uniformly
6:                 sampled from
7:                 [0,200]^2
8:   centroid := mean of board_points
9:   sort p in board_points by
10:    atan(p.y - centroid.y,
11:         p.x - centroid.x)
12:   return polygon(board_points)
13:
14: algorithm generate_sample
15:   output: board b, ic-position ic,
16:         decap-positions d
17:
18:   while failure occurred do
19:     b := board_shape()
20:     ic := non_degen_point(b)
21:     dc := uniform integer in [0,19]
22:     d := empty list
23:     for i in {0, ..., dc} do
24:       cap := non_degen_point(b)
25:       cap.side := uniform sample from
26:                 {bottom, top}
27:       cap.type := uniform sample from
28:                 {1, ..., 6}
29:       d.append(cap)
30:     end for
31:   end while
32:   return {b, ic, d}

```

Abbildung 15: Algorithmus für Boardshape mit filterung von degenerierten Punkten

4. Evaluation und Anwendung der Daten

- Zusammen mit Partner 04-ZUKEN wurde ein bestehendes PCB-Design ausgewählt, um die erzeugten Trainingsdaten sowie die entwickelten KI-Modelle zu validieren.
- Der Datengenerator wurde an die Spezifika dieses Beispiel-PCBs angepasst, u. a. durch die Berücksichtigung der enthaltenen Decap-Typen sowie der PCB-Größe.

5. Definition von Bewertungsmetriken

- Es wurden Metriken und Kriterien spezifiziert, um die Qualität der KI-Ergebnisse im USE#1 zu bewerten. Diese Bewertungsgrundlage wurde im späteren Projektverlauf für die Verfeinerung der Modelle genutzt.

Mit der Entwicklung eines robusten und flexiblen Datengenerators sowie der Automatisierung des Labeling-Prozesses wurde ein zentraler Baustein für die Trainingsdatenbereitstellung der KI-Module geschaffen. Durch die enge Abstimmung mit Partnern und die kontinuierliche Anpassung des Generators konnte sichergestellt werden, dass die erzeugten Daten sowohl praxisrelevant als auch technisch präzise sind.

3.2.4 Teilaufgabe 2.4: Entwicklung und Validierung eines Meta-Algorithmus

Der bereitzustellende Meta-Algorithmus trägt der Heterogenität der in der Praxis anfallenden Entwurfsentscheidungen Rechnung. Die für den jeweils erfolgreichen Einsatz der KI erforderlichen Lernprozesse unterscheiden sich hinsichtlich der Art und Geschwindigkeit, in welcher die vorliegenden Daten zum Erlangen der Fähigkeit zur zuverlässigen Entscheidungsfindung genutzt werden. Zur Beurteilung, ob ein einzelner KI-Algorithmus für eine vorliegende Probleminstanz geeignet ist, sind neben der Lerndynamik des Algorithmus auch die Qualität der verfügbaren Daten und der Trainingsstand des Algorithmus zu berücksichtigen. Um automatisiert für eine vorliegende Probleminstanz einen geeigneten Algorithmus identifizieren zu können, wie es in progressivKI vorgesehen war, müssen die Qualität der vorliegenden Daten, der Trainingsstand des Algorithmus und die Problemklasse der vorliegenden Probleminstanz metrisiert bzw. klassifiziert werden. Hierzu mussten geeignete mathematische Modelle bereitgestellt und im Rahmen des algorithmischen Kerns von progressivKI implementiert werden. So war nicht nur eine Beurteilung, wie gut ein bestimmter Algorithmus geeignet ist, einen Lernerfolg in der gegebenen Situation zu erzielen möglich, sondern auch eine Bewertung der daran anschließenden Entwurfsentscheidungen/-vorschläge. Der Meta-Algorithmus umfasst Metriken zur Beschreibung der Problemschwierigkeit und des Abstandes von Problemen im Sinne eines [Umlernprozesses], Metriken zur Bewertung von Lernprozessen, Metriken zur Bewertung der Datenqualität und schließlich eine Entscheidungsmethodik, welche Algorithmen bei Vorgabe einer Probleminstanz zielführend einsetzbar sind.

Voraussetzung für die Verwendbarkeit des Meta-Algorithmus ist das Vorhandensein geeigneter Schnittstellen, die das Operieren auf der KI-Plattform ermöglichen, sowie die Einrichtung der entsprechenden Datenströme im vereinbarten Standard und Format.

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

- Auswahl von Open-Source Algorithmen und Performance-Metriken zur KI-basierten Erkennung und Extraktion von Tabellen, Skizzen und Text-Bausteinen aus Datenblättern für elektronische Bauelemente (aktiv/passiv)
- Ermittlung der Anforderungen an die Integration von Verfahren zur Qualitätskontrolle in den Workflow der geplanten der KI-Modul-Plattform(en)
- Entwicklung von Verfahren zur Bewertung des Lernfortschrittes von ML-Algorithmen
- Abgleich der Lernerfolgs der eingesetzten Optimierungsalgorithmen
- Wahl geeigneter Algorithmen für gegebene Entwurfsaufgaben durch Verwendung einer übergeordneten [Meta-Maschine]
- Entwicklung eines Analyse- und Meta-Algorithmus zur Analyse und Bewertung der Datenqualität

- Kombination von Metaalgorithmus und Qualitätsmatrizen zur späteren Bestimmung der Güte der Algorithmen
- Konzeptionierung und Implementierung von Mechanismen zur Auffindung und synergetischen Nutzung einzelner Prädiktionsmodelle unter Nutzung der jeweils definierten Ontologien
- Untersuchung von Algorithmen-Kombinationen aus unterschiedlichen Teilkomponenten (Decision Tree, SVM, CNN, etc.) für die modularen KI-Plattform(en).
- Untersuchung geeigneter Open-Source KI-Algorithmen zur Klassifikation und Reduzierung des Problemraums sowie anschließender Auswahl von KI-Algorithmen für die Anwenderszenarien #1 - #2.

Teilbeitrag 2.4.19: Festlegung KI-Teilprozesse/-Module (Anwendungsebene #1 PCB) (19-TUB)

Ziele

Identifikation geeigneter Open-Source KI-Algorithmen zur Klassifikation und Reduzierung des Problemraums

Es sollte das Ziel verfolgt werden, Open-Source KI-Algorithmen zu identifizieren, die effektiv zur Klassifikation und Strukturierung des Problemraums beitragen und somit eine Reduzierung der Komplexität der Teilprozesse ermöglichen.

Auswahl und Optimierung von KI-Algorithmen zur Lösungsverbesserung in Teilprozessen

Ein weiteres Ziel war die Auswahl der besten KI-Algorithmen zur Berechnung optimierter Lösungen, die für die spezifischen Anforderungen der Teilprozesse besonders geeignet sind. Diese Algorithmen sollten verbesserte Ansätze zur Lösung komplexer Teilprobleme im Designflow bieten.

Problemstellung

Die Komplexität der Teilprozesse stellt eine wesentliche Herausforderung bei der Entwicklung einer leistungsfähigen KI-gestützten Design-Umgebung dar. Zur effizienten Bewältigung dieser Komplexität ist es notwendig, geeignete Open-Source KI-Algorithmen zu finden, die in der Lage sind, den Problemraum durch Klassifikation und Strukturierung zu reduzieren. Zudem muss die Auswahl dieser Algorithmen gezielt auf die Berechnung optimierter Lösungen für die jeweiligen Teilprozesse ausgerichtet sein, um den Designflow zu optimieren und den Entwicklungsprozess zu beschleunigen.

Lösungsweg und Ergebnisse

Der Teilbeitrag 2.4.19 befasste sich mit der Untersuchung geeigneter Open-Source KI-Algorithmen, um Problemräume im PCB-Design zu klassifizieren und zu reduzieren sowie Algorithmen zur Berechnung verbesserter Lösungen für die Teilprozesse auszuwählen. Dabei lag der Fokus auf einer detaillierten Evaluierung von Ansätzen zur Modellierung und Optimierung unter Berücksichtigung der spezifischen Anforderungen des USE#1. Im Folgenden werden die Ergebnisse unter Berücksichtigung der untersuchten Technologien und der Entscheidungsgrundlagen zusammengefasst:

1. KI-Ersatzmodell für die PI-Simulation: Auswahl eines CNN
 - Untersuchung und Entscheidungsgrundlage:

Basierend auf Erkenntnissen aus der Literaturrecherche (AP 1) wurden Convolutional Neural Networks (CNNs) als bevorzugte Architektur für das Ersatzmodell des PI-Simulators von Partner ZUKEN identifiziert. CNNs, bekannt aus dem Bereich Computer Vision, sind etabliert für datengetriebene Probleme mit großen Fortschritten gegenüber klassischen Algorithmen.

- Vergleich von Implementierungsoptionen:

Für die Entwicklung des Modells wurden die Open-Source-Bibliotheken TensorFlow und PyTorch untersucht. Beide bieten eine breite Unterstützung für Layerstrukturen und Algorithmen. TensorFlow wurde zunächst als Implementierungsbibliothek genutzt, später wurde aus Gründen der Flexibilität und Performance zu PyTorch gewechselt.

2. Optimierung der Decap-Platzierung mit Reinforcement Learning (RL)

- Algorithmische Basis:

Für die Platzierungsoptimierung wurden genetische Algorithmen (GA) und Reinforcement Learning (RL) als potenzielle Ansätze untersucht. Die Entscheidung fiel auf RL, da es sich in der KI-Forschung und -Anwendung als vielseitig und leistungsstark etabliert hat.

- Umgebungsmodellierung:

Die RL-Umgebung modelliert das PCB als diskretes Matrix-Grid (z. B. 16×16) und enthält Platzierungsaktionen wie die Auswahl eines Decap-Typs und die Positionierung auf dem PCB-Layout.

Um die Umgebung effizient zu gestalten, wurden physikalische Constraints (z. B. Platzierungsverbote außerhalb des PCB-Bereichs) sowie spezifische Designanforderungen integriert.

- Agenten-Auswahl:

- DQN-Agent (Deep Q-Network):

Der initiale RL-Agent basierte auf dem DQN-Algorithmus, der für diskrete Umgebungen und kleine Trainingsdatensätze gut geeignet ist. Die Implementierung erfolgte mithilfe der Open-Source-Bibliothek TF-Agents.

Einschränkungen: Aufgrund der begrenzten Fähigkeit des DQN, mit großen Aktionsräumen umzugehen (z. B. 5120 Aktionen für ein 16×16-Grid mit 10 Decap-Typen auf Top- und Bottom-Layer), musste der Aktionsraum zunächst auf

Bereiche um den IC begrenzt werden.

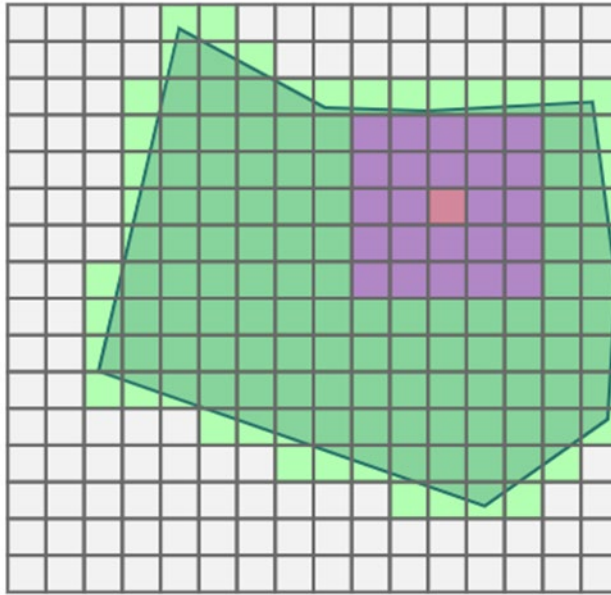


Abbildung 16: Beispiel eines PCBs mit eingeschränktem Platzierungsbereich (lila) um den IC.

- Wechsel zu PPO-Agent (Proximal Policy Optimization):
Zur Überwindung der Aktionsraumprobleme wurde auf den PPO-Algorithmus umgestellt, der größere Aktionsräume effizient handhaben kann. Der PPO-Agent wurde mithilfe der Bibliothek TorchRL implementiert.
- Action Masking mit PPO:
Für noch bessere Lernleistung und Konvergenz wurde ein PPO-Agent mit Action Masking evaluiert und implementiert. Dieser ignoriert illegale Aktionen (z. B. Platzierungen außerhalb des PCB-Bereichs) durch Vorfilterung, sodass der Agent sich auf die Optimierung der Decap-Platzierungen konzentrieren kann. Die Implementierung erfolgte mit Stable-Baselines3-Contrib, einer Open-Source-Erweiterung.
- Hyperparameter-Tuning:
Die Netzwerke wurden mithilfe der Open-Source-Bibliothek Optuna optimiert, die eine flexible und effiziente Hyperparameter-Suche ermöglicht. Optuna wird auch in der Dokumentation von Stable-Baselines3 empfohlen und bewährte sich in der Praxis.

Die Untersuchung geeigneter KI-Algorithmen zeigte, dass sowohl Convolutional Neural Networks als auch Reinforcement Learning zentrale Bausteine für die Lösung der PI-Probleme und Optimierung der Decap-Platzierung darstellen. Die detaillierten Analysen zu Implementierungsdetails und algorithmischen Eigenschaften lieferten die Entscheidungsgrundlage für den weiteren Einsatz im Projekt. Die Ergebnisse ermöglichen es, spezifische Anforderungen der Simulation und Platzierung flexibel zu adressieren und bilden eine solide Grundlage für nachfolgende Entwicklungsarbeiten.

3.2.5 Teilaufgabe 2.5: Datenbasierte Trainings-/Lernmodule

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

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

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

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

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

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

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

Bearbeitung der folgenden TA2.5-Themen:

- Review der bisherigen Arbeiten an den Trainingsmodulen für AW #1 und #2.
- Auswertung des KI-Trainingsmoduls AW#1
- Erstellung, Verwaltung und Validierung von Trainings-Pipelines zur Verbesserung von bereits fertiggestellten KI-Modellen

- Aufteilung und Aufbereitung der Eingangs- und Ausgangsdaten der Datenblätter von elektronischen Komponenten in einen Trainings-, Validierungs-, und Testdatensatz
- Training für KI-Anwendung Kontext von Requirements-Engineering-Methoden
- Schnittstellenmodelle für Datenbasierte Training-/Lernmodule zur Unterstützung des Entwurfs von Komponenten der Industrieelektronik
- Analyse Open-Source Algorithmen für datenbasierte Training-/Lernmodule
- Anpassung von KI-Modulen und Generierung von Trainings- und Lerndaten
- Bereitstellung spezifischer Simulations- bzw. Berechnungsverfahren zur Generierung von Lerndaten (z. B. Daten für Power-Ground-Kopplungen)
- Anpassung von Entwurfsdaten sowie Vorverarbeitung zur Nutzung für CNN und Transfer-Learning.

3.3 Arbeitspaket 3: Verzahnte Entwicklung von Automobilkomponenten

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

Die folgenden F+E Themen wurden in AP3 adressiert:

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

Die folgende Liste fasst die Hauptziele dieses Arbeitspakets zusammen:

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

Plattformen einschließlich der erforderlichen Zugriffsmethoden auf Datenflüsse und KI-Module;

- Nutzung mathematischer Metriken zur Bestimmung der Güte der Eingangs- und Ausgangsdaten, sowie der KI-Algorithmen.

Geplante Ergebnisse von AP3 waren:

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

3.3.1 Teilaufgabe 3.1: Framework KI-Module für AW-Ebenen #1 und #2 + Optimierung KI-Module

In dieser Teilaufgabe sollten KI-gestützte Entwurfsmethoden unter Berücksichtigung der Ergebnisse aus AP 1 und 2 für die AW #1 - #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 Wissensbasen 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 #1 - #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 #1 - #2 + Optimierung KI-Module
- Aufbereitung und Initialisierung der KI-Module auf der Grundlage gängiger KI-Frameworks sowie Installation auf den nötigen Rechnernetzen.
- 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 #1 - #2 (Implementierung von KI-Modulen)

Teilbeitrag 3.1.19: Vorhabensspezifisches KI-Framework – Anwendungsebene #1 PCB-Modul (19-TUB)

Ziele

Entwicklung eines projektspezifischen KI-Frameworks für Anwendungsebene #1

Ziel war es, ein zentrales, integriertes KI-Framework zu schaffen, das die implementierten KI-Module und verwendeten Open-Source-Bibliotheken nahtlos vereint und für die spezifischen Anforderungen der Anwendungsebene #1 optimiert wurde.

Reibungslose Integration von Open-Source-Bibliotheken in die Projektumgebung

Die ausgewählten Open-Source-Bibliotheken wurden so in das Framework eingebunden, dass sie konsistent mit den weiteren Projektergebnissen und Modulen arbeiten und den Entwicklungsfluss unterstützen.

Steigerung der Effizienz und Wiederverwendbarkeit der entwickelten KI-Module

Das Framework sollte als Grundlage für eine langfristig effiziente Nutzung der entwickelten KI-Module dienen und die Wiederverwendung dieser Module in ähnlichen Anwendungsszenarien ermöglichen.

Problemstellung

Die Implementierung eines konsistenten, anwendungsspezifischen KI-Frameworks stellte die Herausforderung dar, verschiedene Open-Source-Bibliotheken, die zur Entwicklung der KI-Module genutzt wurden, in eine gemeinsame Struktur zu integrieren. Diese Bibliotheken mussten so eingebunden werden, dass die Zusammenarbeit und Interoperabilität der Module gewährleistet werden konnte. Dabei musste besonders darauf geachtet werden, dass die Bibliotheken flexibel auf die spezifischen Anforderungen der Anwendungsebene #1 zugeschnitten sind, ohne die Effizienz und Wartbarkeit des Frameworks im Gesamtprojekt zu beeinträchtigen.

Lösungsweg und Ergebnisse

Teilbeitrag 3.1.19 zielte darauf ab, die für das Projekt genutzten Open-Source-Bibliotheken in ein vorhabenspezifisches KI-Framework der Anwendungsebene 1 zu integrieren. Das implementierte CNN-basierte KI-Modul wurde dabei als Bestandteil dieses Frameworks eingefügt. Diese Integration erfolgte, indem das CNN-Modul genutzt wurde, um die Impedanzbewertung für den Reinforcement Learning (RL)-Algorithmus zu ermöglichen, der ebenfalls Teil der Anwendungsebene 1 ist. Der Schwerpunkt lag auf der Entwicklung des RL-basierten Moduls zur Decap-Platzierung, wobei das CNN-Modul eine präzise Bewertung der Platzierungsentscheidungen sicherstellte.

1. RL-Umgebungsmodellierung

Der größte Entwicklungsaufwand lag in der Erstellung einer spezialisierten RL-Umgebung, die den physikalischen Aufbau eines PCBs simuliert und als Grundlage für die Platzierungsentscheidungen des RL-Agents dient. Die Umgebung wurde strukturell an OpenAI/Gym ausgerichtet, was durch die Definition spezifischer Funktionen wie reset, step und reward erreicht wurde. Diese Architektur gewährleistet Kompatibilität mit verschiedenen RL-Bibliotheken, darunter TF-Agents, Stable-Baselines3 und TorchRL.

- Reset-Funktion: Generiert ein neues PCB-Design ohne Decaps zu Beginn jeder Episode.
- Step-Funktion: Führt die Aktion des Agents (Platzierung eines Decap-Typs an einer bestimmten Position) aus und berechnet die resultierende Umgebung.

i. Bewertungsfunktion:

Die Bewertung der Aktionen erfolgte durch den Vergleich der von dem integrierten CNN-KI-Modul vorhergesagten Impedanzkurve mit einer vorgegebenen Zielimpedanzkurve, die auf den Spezifikationen des jeweils betrachteten ICs basierte. Im Rahmen der Entwicklung wurden verschiedene Zielkurven getestet, um die Flexibilität und Effektivität des Ansatzes zu evaluieren. Um die Anforderungen unterschiedlicher RL-Ansätze zu erfüllen, wurden mehrere Bewertungsfunktionen implementiert:

ii. Einfache Bewertungsfunktion für DQN:

- Legale Platzierungen: +10 Punkte.
- Unzulässige Platzierungen (z. B. Überlappung): -10 Punkte.
- Ziel erreicht: Belohnung abhängig vom Abstand zur Zielkurve.
- Ziel nicht erreicht nach 20 Platzierungen: -100 Punkte.

iii. Komplexere Bewertungsfunktion für PPO/Maskable PPO:

- Neben der Berücksichtigung der Zielkurve wurde die Bewertung für jede Platzierung an den resultierenden Impedanzverlauf angepasst, was eine differenzierte Optimierung erlaubte.

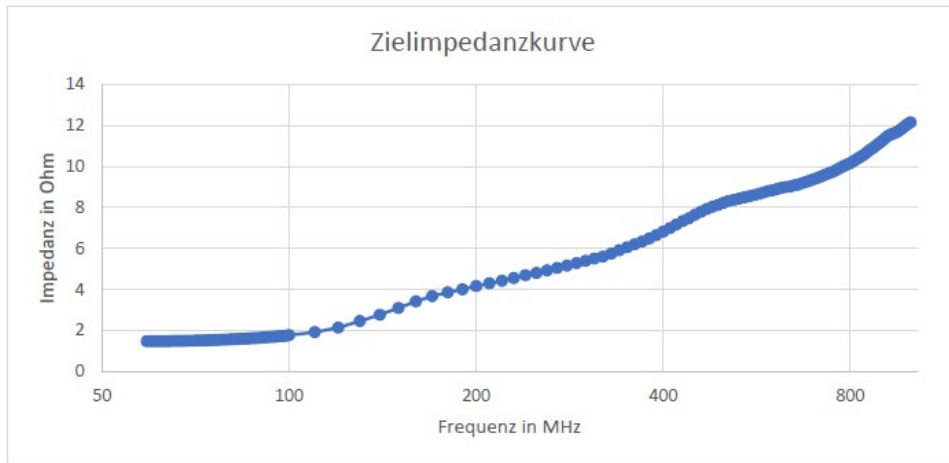


Abbildung 17: Erste Zielimpedanzkurve, die wir genutzt haben. Sie wurde aus dem Durchschnitt der Impedanzen der Trainingsdaten erzeugt.

2. Umsetzung verschiedener RL-Agenten

- Deep Q-Network (DQN)

i. Ansatz:

- Der DQN-Agent wurde mit TF-Agents entwickelt und verwendete einen eingeschränkten Aktionsraum (5x5-Grid um den IC und 6 Decap-Typen), um die Komplexität zu reduzieren.
- Resultierender Aktionsraum: 300 mögliche Aktionen.

ii. Ergebnisse:

- Der Agent konnte in 9 von 10 Fällen eine Platzierung finden, die die Zielimpedanzkurve unterschritt.
- Aufgrund des begrenzten Aktionsraums war der Agent jedoch nur für spezifische PCB-Konfigurationen geeignet.

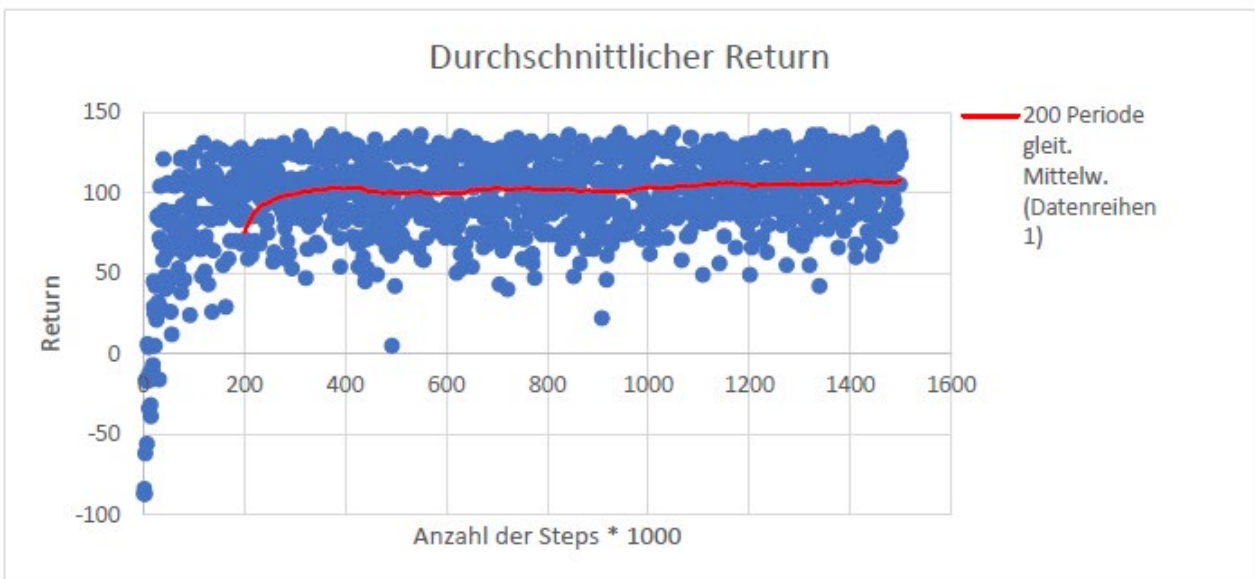


Abbildung 18: Durchschnittliche Belohnung des DQN-Agenten.

- Proximal Policy Optimization (PPO) und Maskable PPO
- Ansatz:
 - i. Nutzung eines erweiterten Aktionsraums, der die Platzierung auf dem gesamten PCB erlaubte.
 - ii. Action-Masking wurde verwendet, um illegale Platzierungen direkt zu vermeiden.
- Ergebnisse:
 - i. Die komplexere Bewertungsfunktion führte zu einer weniger intuitiven, aber differenzierteren Bewertung.
 - ii. Die Modelle zeigten eine gute Konvergenz und konnten mit Referenzdesigns verglichen werden, um ihre Effektivität zu bestätigen.

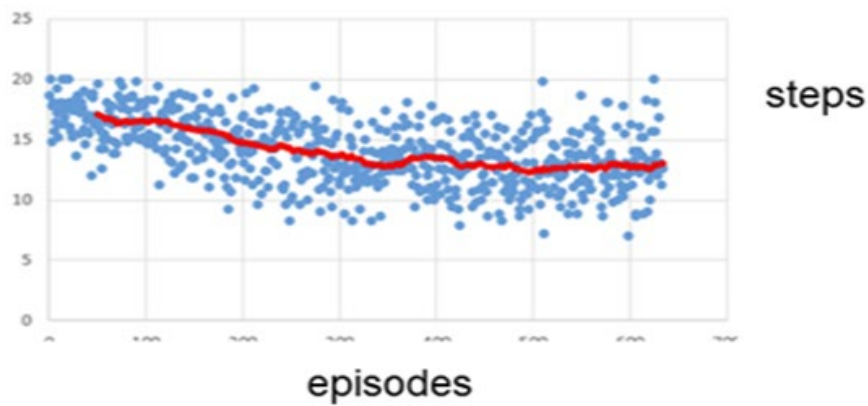


Abbildung 19: Anzahl der benötigten Schritte pro Episode. Da wir die Anzahl der Decaps minimieren möchten und in jedem Schritt ein Decap platziert wird, ist die sinkende Anzahl der Schritte pro Episode ein guter Indikator für die Leistung des RL-Agenten.

$$R = \frac{\sum_k^n \max_{>0}(I_P - I_T) - \sum_k^n \max_{>0}(I_C - I_T)}{n} + D$$

$$D = \begin{cases} 20 - \#placed_decaps & | \text{ if done and caps } \leq 19 \\ \frac{-(n - \#non-neg-points)}{n} & | \text{ if done and caps } > 19 \\ 0 & | \text{ else} \end{cases}$$

Abbildung 20: Belohnungsfunktion des PPOs: Die Verbesserung der nicht-negativen gemessenen Differenz der Impedanz aus dem vorherigen Schritt (I_p) zur Zielimpedanz (I_T) wird mit der des aktuellen Schritts (I_C) verrechnet und durch die Anzahl der Stützstellen geteilt. Falls der Agent eine optimale Platzierung gefunden hat oder versagt hat, wird der Wert durch einen weiteren Summanden (D) ergänzt.

Dieser Teilbeitrag hat eine zentrale Grundlage für die Anwendung von KI-Methoden auf der Anwendungsebene 1 geschaffen, indem ein Reinforcement Learning-Framework zur Decap-Platzierung entwickelt wurde. Das RL-Modul integriert ein CNN-Modell für die Impedanzbewertung, das als Bewertungsgrundlage dient und die Präzision der Platzierungsentscheidungen sicherstellt. Durch die Kombination beider Ansätze wurde ein flexibles und leistungsstarkes System geschaffen, das die Anforderungen der Anwendungsebene 1 erfüllt und durch den Einsatz moderner Open-Source-Bibliotheken skalierbar und erweiterbar ist.

3.3.2 Teilaufgabe 3.2: Implementation Modul-Schnittstellen (Datenaustausch)

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

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

Die Arbeiten zu dieser Teilaufgabe wurden wie folgt zusammengefasst:

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

Teilbeitrag 3.2.19: Bereitstellung Werkzeug-Schnittstellen für Anwendungsszenario #2 (19-TUB)

Ziele

Implementierung und Integration der definierten Schnittstellen für Anwendungsebene #1

Es sollte die Entwicklung und Anbindung aller notwendigen Schnittstellen erfolgen, um eine effiziente Datenkommunikation zwischen den PCB-Layout- und Analysesystemen sowie den KI-Modulen zu ermöglichen.

Optimierte Datenbereitstellung und -verarbeitung für KI-Module

Es war das Ziel, sicherzustellen, dass alle relevanten Daten für KI-Module effizient verfügbar gemacht und die Berechnungsergebnisse konsistent in der projektspezifischen Datenbasis gespeichert werden.

Verbesserung des Gesamt-Workflows und der Datenbasis für PCB-Design- und Analysesysteme

Es wurde ein robustes Schnittstellen-Framework entwickelt, das eine reibungslose Integration der Layout- und Analysesysteme gewährleisten sollte, um eine kontinuierliche Datenverfügbarkeit entlang der Wertschöpfungskette zu unterstützen.

Problemstellung

Die Implementierung eines KI-gestützten PCB-Design-Workflows erforderte den Austausch von Daten und Analyseergebnissen zwischen verschiedenen Systemen (PCB-Layout, Analysesysteme und KI-Module) und deren strukturierte Speicherung in einer einheitlichen Datenbasis. Es galt, eine Vielzahl von Schnittstellen anzubinden, die sowohl mit den spezifischen Anforderungen der eingesetzten Tools als auch mit den Anforderungen der definierten KI-Module kompatibel sein sollten. Die Herausforderung bestand darin, eine effiziente Schnittstellenarchitektur zu entwickeln, die den nahtlosen Datenfluss sicherstellte und gleichzeitig den Austausch sowie die Integration der KI-Ergebnisse in den Designprozess ermöglichte.

Lösungsweg und Ergebnisse

Teilbeitrag 3.2.19 konzentrierte sich auf die Implementierung und Bereitstellung der Schnittstellen, die in TB 2.1.19 spezifiziert wurden, um die Integration der entwickelten KI-Module in das vorhabenspezifische KI-Framework zu ermöglichen. Der Fokus lag darauf, durch die Schnittstellen eine reibungslose Kommunikation zwischen der PCB-Designumgebung und den KI-gestützten Modulen sicherzustellen. Insbesondere wurde die REST-API implementiert, um Designinformationen in verschiedenen Formaten wie JSON, CSV und SVG bereitzustellen, sodass diese effizient in den Modulen verarbeitet werden konnten.

1. Schnittstelle Zuken eCADSTAR – BEREDA

- **Bereitstellung und Weiterentwicklung:**
Eine Schnittstelle zwischen dem PCB-Layout-Tool Zuken eCADSTAR und BEREDA wurde durch das Einlesen von Layout-relevanten Daten im RIF/ERF-Format realisiert. Diese Schnittstelle ermöglicht es, umfassende Informationen über das PCB-Design für den Software-Demonstrator bereitzustellen.
 - i. Die Schnittstelle wurde im Laufe des Projekts kontinuierlich erweitert, um zusätzliche Anforderungen zu erfüllen. Beispielsweise wurden ergänzende Informationen wie Kapazitätswerte für Decaps integriert.

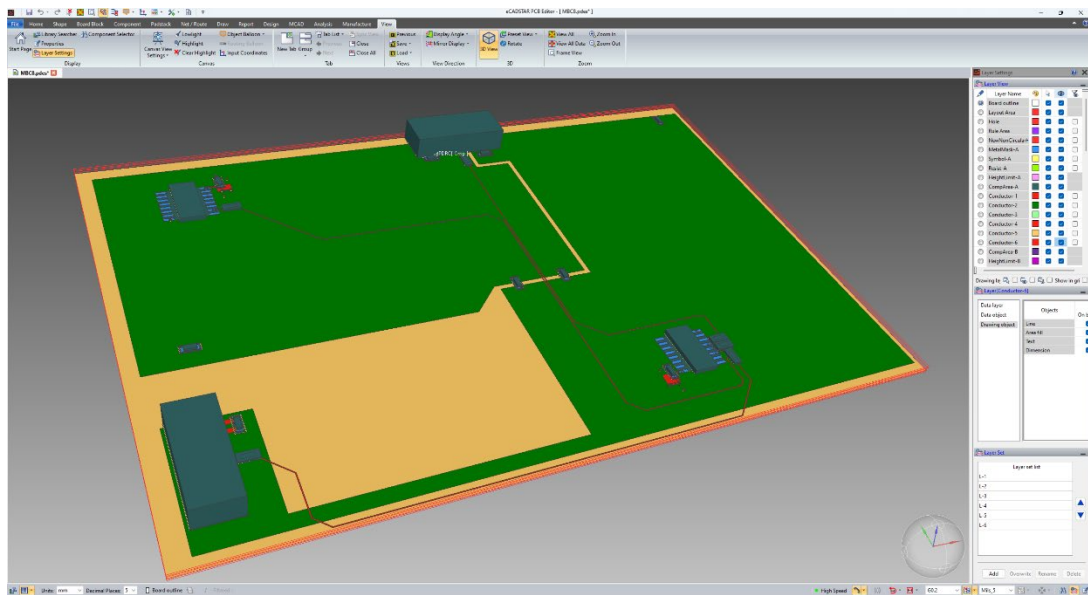


Abbildung 21: Beispiel eines PCBs im Zuken eCADSTAR

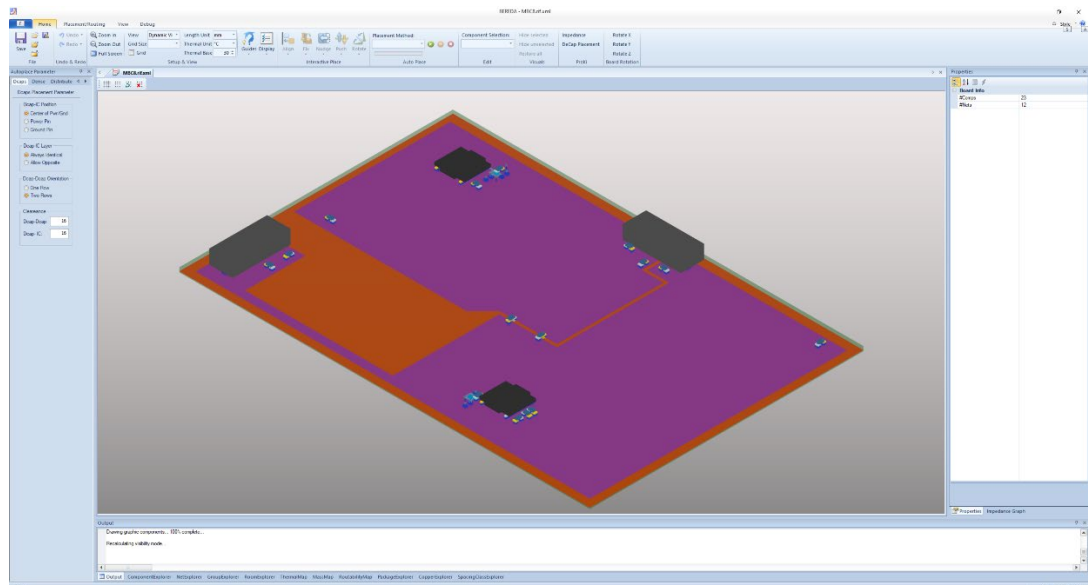


Abbildung 22: Beispiel eines PCBs im Software-Demonstrator der TUB "BEREDA", welches über eine RIF/ERF-Schnittstelle eingelesen wurde

2. Schnittstelle Altium Designer – BEREDA

- Umsetzung mit Altium Developer API:
Für den Altium Designer wurde eine Schnittstelle auf Basis der Altium Developer API implementiert. Diese ermöglicht es, Board-Informationen mithilfe einer Altium-Extension in ein XML-Format zu exportieren, das vom BEREDA-Demonstrator verarbeitet werden kann.



Abbildung 23: Altium Designer Add-On zur Datenübermittlung an BEREDA.

3. 3. Python-Anbindung für BEREDA und KI-Module

- Bereitstellung von Layout-Daten:
Eine Python-Schnittstelle wurde entwickelt, die grundlegende Layout-Daten wie Komponentenlisten, Layer-Stackups und Netzlisten bereitstellt. Diese Schnittstelle bildet die Grundlage für die selektive Verarbeitung durch die KI-Module.

bereda_python	20.09.2021 16:13	Dateiordner	
bin	27.09.2021 17:06	Dateiordner	
data	23.09.2021 10:40	Dateiordner	
tmp	27.09.2021 15:45	Dateiordner	
WPy64-3950	20.09.2021 13:30	Dateiordner	
<input checked="" type="checkbox"/> draw_board.bat	20.09.2021 13:57	Windows-Batchda...	1 KB
<input checked="" type="checkbox"/> print_components.bat	20.09.2021 15:15	Windows-Batchda...	1 KB
<input checked="" type="checkbox"/> print_layerstack.bat	20.09.2021 15:25	Windows-Batchda...	1 KB
<input checked="" type="checkbox"/> print_netlist.bat	20.09.2021 13:56	Windows-Batchda...	1 KB
<input checked="" type="checkbox"/> start.bat	27.09.2021 17:06	Windows-Batchda...	1 KB

Abbildung 24: Python Funktionalitäten zur Datenübernahme durch KI-Module

```
PCIE_Txp_4, #comps: 2, #pins: 2
    IC1
    C10
PCIE_Txp_5, #comps: 2, #pins: 2
    IC1
    C8
PCIE_Txp_7, #comps: 2, #pins: 2
    IC1
    C4
PS1_BOOT_REG, #comps: 3, #pins: 3
    IC101
    C101
    Z101
PS1_EAO_REG, #comps: 3, #pins: 3
    IC101
    C102
    R101
PS1_FB_REG, #comps: 6, #pins: 6
    IC101
    C102
    C103
    R106
    R107
    R102
PS1_FREQ_REG, #comps: 2, #pins: 2
    IC101
    R105
PS1_HG_REG, #comps: 2, #pins: 2
    IC101
    M101
PS1_ISEN_REG, #comps: 2, #pins: 2
    IC101
    R104
PS1_LG_REG, #comps: 2, #pins: 2
```

Abbildung 25: Auszug Netzliste

- Erweiterung um JSON- und CSV-Formate:
Um die Nutzung der Daten zu erleichtern, wurden JSON- und CSV-Formate implementiert. Diese Formate erlauben eine standardisierte und vielseitige

Übertragung zwischen verschiedenen Modulen und Systemen.

```
▼ outline: Object { form_type: "area", outline: {...}, cutouts: [] }
  form_type: "area"
  ► outline: Object { form_type: "arc_polygon", points: {...} }
    cutouts: []
▼ extrema: Object { ll: {...}, ur: {...} }
  ► ll: Object { x: 39, y: 39 }
  ► ur: Object { x: 5827, y: 3858 }
► components: [ {...}, {...}, {...}, {...}, {...}, {...}, {...}, {...}, {...}, {...}, ... ]
  keepins: []
  keepouts: []
► nets: [ {...}, {...}, {...}, {...}, {...}, {...}, {...}, {...}, {...}, {...}, ... ]
  groups: []
► layerstack: Object { 10: {...}, 15: {...}, 20: {...}, ... }
► top_layer: Object { name: "L1", hash: 2027176344 }
► bottom_layer: Object { name: "L14", hash: 3431078612 }
```

Abbildung 26: Beispielausgabe von Layoutdaten im JSON-Format für KI-Module

- Verifikation der Datenübernahme:
Zur Überprüfung der erfolgreichen Datenübernahme wurde die Möglichkeit integriert, ein SVG-Bild des importierten Boards zu generieren. Dieses Bild dient der visuellen Verifikation der übernommenen Layout-Daten und erleichtert die Validierung durch Entwickler und Projektpartner.

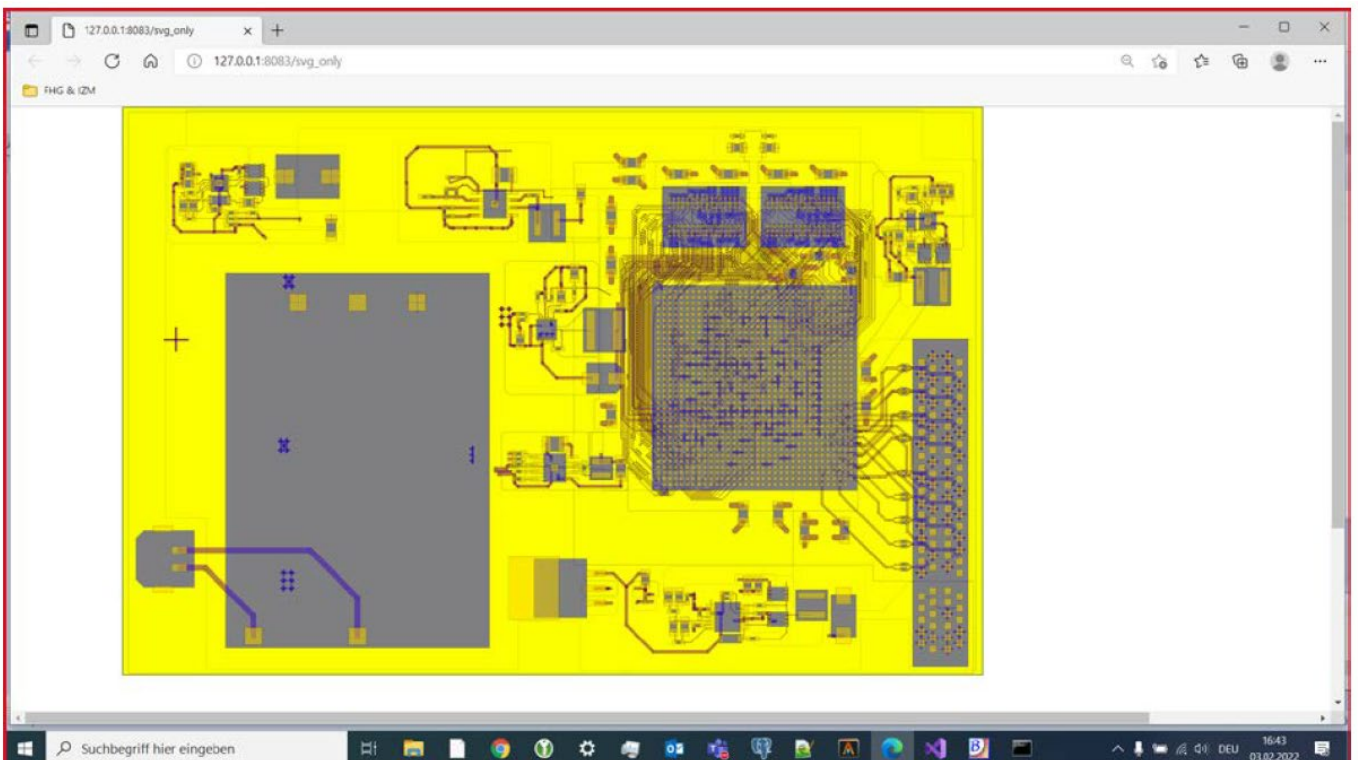


Abbildung 27: SVG-Bild des aus BEREDA übernommenen Boards in Python generiert

4. Implementierung einer REST-API

- Zugriff auf BEREDA-Daten:
Eine REST-API wurde entwickelt, um Daten aus der BEREDA-Tool-Suite effizient abrufen zu können. Diese API bietet eine moderne und plattformunabhängige Lösung für die Datenübertragung und unterstützt die Automatisierung von Arbeitsabläufen.

▶ GET `http://127.0.0.1:8083/board`

Status	200 OK ?
Version	HTTP/1.1
Übertragen	371,81 KB (371,73 KB Größe)
Anfrage-Priorität	Highest
▼ Antwortkopfeilen (76 B)	
?	Content-Type: application/json

Abbildung 28: Beispiel für ein HTTP-Request an die REST-Schnittstelle der BEREDA Tool Suite

Die im Teilbeitrag umgesetzten Schnittstellen legten den Grundstein für eine effektive Integration zwischen PCB-Layout-Tools und der BEREDA-Tool-Suite. Die iterative Weiterentwicklung und die Einbindung moderner Formate und Technologien wie REST-APIs sowie JSON- und CSV-Schnittstellen gewährleisten eine flexible und zukunftssichere Anbindung. Diese Ergebnisse tragen wesentlich zur Automatisierung und Effizienzsteigerung der KI-basierten Optimierungsprozesse bei.

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

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

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

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

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

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

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

Teilbeitrag 3.3.19: Anpassung vortrainierter KI-Module (19-TUB)

Ziele

Optimierung der Effizienz und Genauigkeit vortrainierter KI-Module für den spezifischen Designflow der Anwendungsebene #1.

Anpassung bestehender Modelle mithilfe von Transfer-Learning, um sie gezielt für die Anforderungen der Anwendungsebene #1 nutzbar zu machen.

Sicherstellung, dass die KI-Module mit den relevanten PCB-Design-Daten effektiv arbeiten und genaue Vorhersagen sowie eine verbesserte Performance liefern.

Steigerung der Leistungsfähigkeit und industriellen Relevanz der KI-Module.

Problemstellung

Vortrainierte KI-Modelle sind oft nur begrenzt auf spezifische Anwendungen übertragbar. Um die Modelle im Kontext der Anwendungsebene #1 effektiv einzusetzen, stellte sich die Herausforderung, diese mittels Transfer-Learning an die spezifischen PCB-Design-Daten anzupassen. Nur so konnte eine höhere Genauigkeit und Effizienz in der realen Anwendung gewährleistet werden.

Lösungsweg und Ergebnisse

Im Rahmen von Teilbeitrag 3.3.19 wurde das KI-Modul für die Impedanzanalyse in Use Case #1 weiterentwickelt und an die spezifischen Anforderungen des Projekts angepasst. Ziel war es, ein zuverlässiges Vorhersagemodell für die Bewertung der Positionierung von Decoupling Capacitors (DeCaps) und Integrated Components (ICs) zu schaffen. Dies erforderte sowohl die Nachimplementierung als auch die Anpassung bestehender Netzwerkarchitekturen sowie umfangreiche Tests und Optimierungen.

1. Nachimplementierung und Anpassung des Modells

- Modell aus der Literatur:
Das CNN-basierte Modell von Zhang et al., identifiziert während der Literaturrecherche, wurde nachimplementiert und schrittweise angepasst.
- Technologische Basis:
Die Nachimplementierung begann in TensorFlow, das zu Projektbeginn als geeigneter für den Einsatz und das Deployment galt. Im späteren Projektverlauf wurde das Modell auf PyTorch portiert, was flexiblere Anpassungen und eine bessere Kompatibilität mit anderen Modulen ermöglichte.
- Anpassungen an Input- und Output-Layer:
 - Das Modell wurde so modifiziert, dass es die vom projektspezifischen Datengenerator erstellten PCB-Daten und die vom ZUKEN-Simulator generierten Impedanzkurven als Trainingsdaten verarbeiten konnte.
 - Die Anpassungen beinhalteten die Integration von Datenformaten und spezifischen Labelstrukturen für die KI-Modelle.




Abbildung 29: Schematische Darstellung des Ablaufs der Impedanzanalyse durch ein CNN-basiertes KI-Modul (Quelle: [ZhangJua])




Abbildung 30: Definition des Aufbaus der verschiedenen Schichten eines CNN für die Impedanzanalyse (Quelle: [ZhangJua])

2. Architekturtests und domänenspezifische Optimierungen

- Test verschiedener Netzwerkarchitekturen:
Es wurden Tests mit leicht veränderten Netzwerkarchitekturen durchgeführt. Die Ergebnisse dieser Anpassungen führten in der Regel nur zu minimalen Änderungen der Vorhersagequalität.
- Domänenspezifische Anpassungen:
Die Integration von Expertenwissen und spezifischen Projektanforderungen führte zur Entwicklung eines neuen Netzwerks (Details hierzu siehe TB 3.4.19).




Abbildung 31: Schematische Darstellung einer zufällig generierten Board-Form mit IC-Position für das Training eines CNN für Impedanzanalyse

3. Anpassung an ein praxisnahes Demo-Board

- Definition eines spezifischen Testboards:
Gemeinsam mit Partner 04-ZUKEN wurde ein praxisnahes Demo-Board als Grundlage für die Validierung des KI-Modells ausgewählt.
- Spezifische Modell Anpassungen:
 - PCB-Größe und Matrix-Auflösung:
Die maximale PCB-Größe wurde auf 5x5 cm festgelegt, und die Matrix-Auflösung wurde auf 32x32 erhöht, um eine feinere Modellierung und Vorhersage der Impedanz zu ermöglichen.
 - DeCap-Typen und Layerstruktur:
Neue Decap-Typen wurden definiert, die den tatsächlichen Eigenschaften des Demo-Boards entsprechen. Die Layerstruktur wurde fest an die des Testboards angepasst, anstatt wie zuvor variiert zu werden.

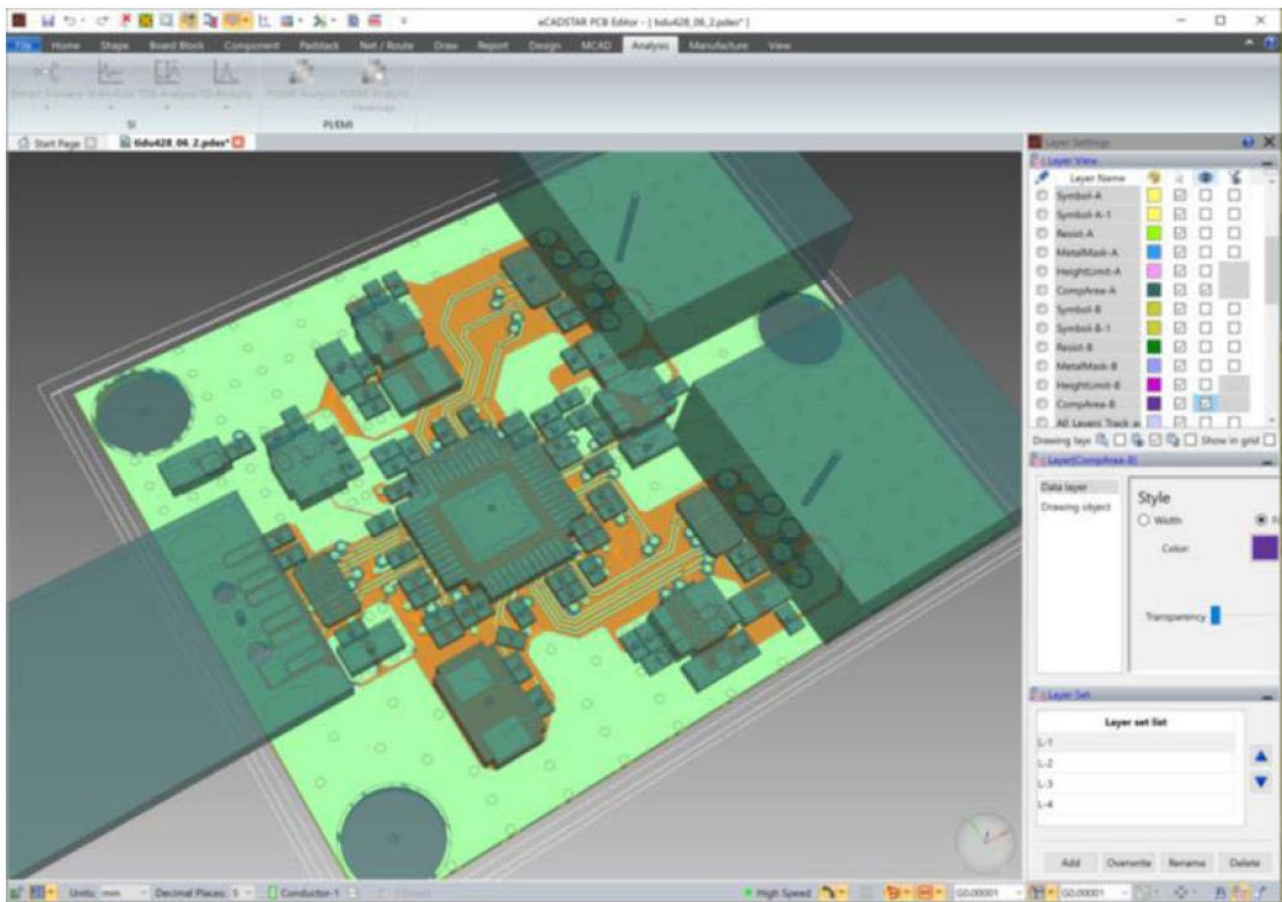


Abbildung 32: Darstellung des Demo-Boards im Zuken eCADSTAR

Das Teilbeitrag 3.3.19 hat entscheidend zur Anpassung und Optimierung des CNN-Modells für die Impedanzanalyse beigetragen. Die Nachimplementierung und Anpassung des Modells aus der Literatur, die umfassende Nutzung domänenspezifischen Wissens sowie die Ausrichtung auf ein praxisnahes Demo-Board ermöglichten signifikante Fortschritte in der Modellgenauigkeit und der Anwendbarkeit des KI-Systems.

3.3.4 Teilaufgabe 3.4: Implementation Domänenwissen

In allen hier adressierten Entwurfsegmenten musste es möglich sein, Domänenwissen zu integrieren, zunächst einmal, um auf dieser Basis einen geordneten Prozess zu starten (ML, DL, KI) und schnell zu über eine Problemdefinition zu einer Lösung im Entwurfsraum zu gelangen. Andererseits musste das Ergebnis der Prozesse hinsichtlich der Qualität und Wirksamkeit als Lösung kontrolliert und eingeschätzt werden können.

Die Qualität muss definiert und nachvollziehbar sein. Damit werden die erforderlichen qualitätskontrollierten modularen KI-Plattform(en) (hier Anwendungsebenen #1 - #2) und schließlich qualitätskontrollierte KI-Module zur Verfügung gestellt, deren interne KI-Prozesse jederzeit nachvollziehbar sind. Diese Eigenschaft stellt – werden diese Anforderungen mit herkömmlichen KI-Ansätzen verglichen – ein Alleinstellungsmerkmal der geplanten KI-Plattform(en) dar.

Ein wichtiges Ziel des Vorhabens war daher die Realisierung von echten selbstlernenden Prozessen. Gleichzeitig sollte eine sich optimierende und wachsende Wissensbasis geschaffen werden, die aufgrund ihrer speziellen Struktur eine stetige Verbesserung der Prozesse und Lösungen gestattet.

Wesentlich für den Erfolg einer KI-Komponente ist die Verfügbarkeit von umfangreichem und erschlossenem Domänenwissen. Dieses steht in den adressierten Anwendungsfeldern durch die eingebundenen Partner in ausreichendem Umfang zur Verfügung und wird durch Regeln und |best-practise|-Eingaben der beteiligten Fachleute ergänzt, um auch in Bereichen mit kleiner Lernmenge ein funktionales System zu ermöglichen.

Um die in diesem Vorhaben zu behandelnden interdisziplinären physikalischen Entwurfsaufgaben zu bewältigen, war deshalb ein hohes Domainwissen auf allen relevanten Gebieten notwendig, welches heutige Entwickler aufgrund der stetig steigenden System-Komplexität kaum bewältigen können.

Zur Erleichterung dieser Prozesse wurde der Einsatz von LLM (Large Language Models) untersucht und in Form von Bots integriert.

Es war notwendig, fest definierbare Regeln (Domänenwissen) zu extrahieren und in die KI-Module zu implementieren, wenn diese allgemein gültig sind. Es muss allerdings auch möglich sein, nicht allgemein gültige Regeln (anwender- und applikations-spezifisch) zu berücksichtigen und zu implementieren.

Durch das Training der betreffenden KI-Module (siehe TA 3.2/3.3) anhand einer aggregierten Wissensbasis konnte erreicht werden, dass nicht nur die gegenwärtigen Entwickler-Fähigkeiten im Entwurfsprozess abgebildet, sondern auch das Wissen aus vergangenen Entwürfen eingebunden und in zukünftige Anwendungen gebracht (Domänenwissen) wird.

In dieser Teilaufgabe wurden die nachfolgenden F+E Komplexe bearbeitet:

- Ausarbeitung und Transformation von Domänenwissen für die KI-Plattformen Anwendungsebenen #1 - #2;
- Implementierung der benötigten Schnittstellen zu den geplanten KI-Plattformen;
- Entwicklung von Beschreibungssprache(n) für Domänenwissen;
- Implementierung, Verifikation und Validierung von eindeutigen Beschreibungssprachen für Domänenwissen;
- Ermittlung von Beschreibungen für die im dezidierten Entwurfsprozess zu beachtenden physikalischen Zusammenhänge mittels der zuvor erstellten Klassifikationsschemata (Taxonomien);
- Übersetzungs- und Konvertierungsalgorithmen zur quellen-übergreifenden Datenanalyse;
- Implementierung von Schnittstellen für den Import von Tacit-Knowledge sowie Extraktion von Anwenderwissen und Regelsätzen;
- Aufbereitung von applikations-spezifischem Wissen für Regelwerke;
- Gewichtete Integration von Domänenwissen und der Regelwerke in KI-Algorithmen;
- Transformation von Tacit-Knowledge sowie der Regelwerke in KI-Module;
- Algorithmen zur Extraktion von Anwenderwissen;
- Umsetzung von Simulationsdaten und daraus abgeleitete
- Datensätze in Domänenwissen;
- Aufbereitung von Entwurfswissen für Regelwerke aus Simulationsdaten mittels Anwendung definierter Metriken;

- Generierung von Domänenwissen um DesignConstraints KI-gestützt aus Lastenheften abzuleiten
- Aufbereitung von Domänenwissen für die KI-gestützte Behandlung von Optimierungsproblemen im Systementwurf;
- Qualifikation der KI-Module mit Domänenwissen.

Teilbeitrag 3.4.19: Verfahren zur Qualifikation von KI-Modulen mit Domänenwissen (19-TUB)

Ziele

Integration von Domänenwissen in KI-Module

Es war beabsichtigt, die bestehenden vortrainierten KI-Module der Anwendungsebene #1 durch gezielte Einbindung von Domänenwissen (Intellectual Property, IP) zu erweitern, um die Leistungsfähigkeit und Genauigkeit der KI-Modelle für die spezifischen Anforderungen des PCB-Designs und der Power Integrity-Analyse zu steigern.

Verbesserung der KI-Module durch Expertenwissen

Die KI-Modelle sollten so angepasst werden, dass sie nicht nur auf allgemeinen Trainingsdaten, sondern auch auf domänenspezifischem Expertenwissen basieren, um relevante Problemstellungen und typische Entwurfsanforderungen in der Praxis besser abzubilden.

Optimierung der vortrainierten Modelle

Durch die Integration von Domänenwissen war es beabsichtigt, die vortrainierten Modelle zu optimieren, sodass sie speziellere und realistischere Ergebnisse für die Anwendung im PCB-Design und der Simulation liefern konnten.

Problemstellung

Die vortrainierten KI-Module in der Anwendungsebene #1 boten eine grundlegende Lösung für die PCB-Design- und Power Integrity-Analyse. Allerdings waren diese Module häufig auf allgemeine Daten und Modelle angewiesen, die nicht immer die spezifischen Anforderungen und Herausforderungen des Anwendungsgebiets widerspiegeln. Um die Leistungsfähigkeit der KI-Module zu steigern und sicherzustellen, dass sie die in der Praxis auftretenden Herausforderungen besser adressieren, war es notwendig, gezielt Domänenwissen und Expertenwissen (IP) in die Modelle zu integrieren. Diese stellte die Herausforderung dar, dieses Wissen in die bestehenden Modelle einzubringen, ohne die ursprüngliche Modellarchitektur und -leistung negativ zu beeinflussen.

Lösungsweg und Ergebnisse

Das Teilbeitrag 3.4.19 fokussierte sich auf die systematische Einbindung von domänenspezifischem Wissen in die KI-Modelle und den Datengenerator. Auf Grundlage der Ergebnisse aus TB 3.3.19 wurden sowohl die Modellarchitektur als auch die zugrundeliegenden Daten und Simulationen optimiert, um die Qualität und Relevanz der Vorhersagen zu verbessern.

1. Eingrenzung des Frequenzbereichs durch domänenspezifisches Feedback
 - Anpassung des Frequenzbereichs:
Basierend auf Rückmeldungen von Partner 04-ZUKEN wurde festgestellt, dass der ursprünglich gewählte Frequenzbereich von 50 MHz bis 1 GHz zu breit und weniger praxisnah war. Es wurden daher neue Frequenzbereiche definiert:

- Modell 1: 0,5 MHz bis 10 MHz
- Modell 2: 0,1 MHz bis 100 MHz
- Neue Datengenerierung und Training:
Um diese neuen Frequenzbereiche abzudecken, wurde der Datengenerator angepasst, neue Daten erstellt und zwei separate Modelle trainiert.

2. Optimierung der PCB-Formen im Datengenerator

- Probleme mit ungünstigen PCB-Formen:
Zunächst erzeugte der Datengenerator zufällige PCB-Formen, die häufig spitze Winkel oder ungewöhnliche Geometrien aufwiesen. Diese führten zu unerwarteten Ergebnissen bei der Impedanzsimulation.
- Domänenspezifische Anpassung:
Der Datengenerator wurde so modifiziert, dass ein Mindestwinkel von 30 Grad zwischen benachbarten Kanten im Board-Polygon gewährleistet ist. Dies führte zu realistischeren und stabileren Simulationsergebnissen.




Abbildung 33: Darstellung einer zufällig generierten Boardform mit scharfen Kanten (links) und einer zufälligen Vereinigung von Rechtecken (rechts).




Abbildung 34: Modellfehler (Wurzel des mittleren quadratischen Fehlers, RMSE) für KI-basierte Impedanzanalyse mit unterschiedlichen Variationen der Eingabedaten.

3. Experimentelle Behandlung von PCBs ohne Decaps

- Herausforderungen mit leeren Boards:
PCBs ohne Decaps zeigten in den Simulationen besonders hohe Impedanzwerte, was das Training erschwerte.
- Ansätze zur Lösung:
Es wurden Modelle trainiert, die entweder nur auf Designs mit mindestens einer minimalen Anzahl von Decaps basierten oder leere Designs nur eingeschränkt berücksichtigten.

4. Entwicklung eines neuen Modells basierend auf Admittanz

- Herausforderungen des bisherigen Modells:
Das Modell aus TB 3.3.19 zeigte Limitationen durch die diskrete Struktur der Input-Matrizen und die Verwendung von festen Decap-Typen. Diese Einschränkungen führten zu begrenzter Modellflexibilität.
- Neuer Ansatz mit Admittanz:
Nach Rücksprache mit Partner 02-UA-TUHH wurde ein neues Modell entwickelt, das physikalisches Wissen über die Parallelschaltung von Decaps integriert:
 - Decaps, die in einem Matrixfeld nahe beieinander liegen, werden als parallel geschaltet betrachtet.
 - Für jedes Feld wird die resultierende Admittanz (Kehrwert der Impedanz) berechnet und als physikalisch fundierter Input für das KI-Modell genutzt.
 - Der resultierende Tensor enthält für jedes Board-Feld in verschiedenen Channels die Admittanzkurven. Dadurch wird die physikalische Aussagekraft der Inputs signifikant erhöht.

$$Y_{x,y}(\omega) = Y_{\text{Board},x,y}(\omega) + \sum_{i=1}^{n_{d,xy}} Y_i(\omega)$$

$$Y_i(\omega) = \frac{1}{Z_i(\omega)}$$

$$Z_i(\omega) = ESR_i + \frac{1}{j\omega C_i} + j\omega ESL_i$$

Abbildung 35: Mathematische Beschreibung der Admittanz

- Vorteile des Admittanz-Modells:
 - Ermöglicht die Verwendung kontinuierlicher Werte anstelle fester Typen.
 - Verbessert die Modellierung physikalischer Effekte und die Generalisierungsfähigkeit.

Durch die Integration von domänenspezifischem Wissen, die Verfeinerung des Datengenerators und die Entwicklung eines neuen Admittanz-basierten Modells konnten wesentliche Fortschritte in der Modellierung und Simulation erzielt werden. Diese Ergebnisse legen die Grundlage für robustere und physikalisch fundierte KI-Modelle, die sowohl für die Impedanzanalyse als auch für die RL-gestützte Decap-Platzierung geeignet sind.

Teilbeitrag 3.4.20: Verfahren zur Einbettung von Domänenwissen in KI-Algorithmen (20-HSHL)

Ziele

Gewichtete Integration des Domänenwissens und der Regelwerke in die KI-Algorithmen.

Problemstellung

Vorhandenes Domänenwissen und bestehende Regelwerke sollen mit den KI-Algorithmen kombiniert werden. Dies bringt verschiedene Probleme mit sich, da Regelwerke, sofern sie formell aufgestellt sind, nicht direkt in KI-Algorithmen verwendet werden können.

Lösungsweg und Ergebnisse

Zusammen mit 03-BOSCH wurde ein Workshop in Hildesheim durchgeführt, der sich mit dem geplanten Workflow und den Grundlagen des Use-Case 3 beschäftigte. Dazu waren Bosch-PCB-Entwickler anwesend, die den geplanten Umsetzungsprozess des Use-Case 3 mit Erfahrungswissen anreicherten. Es wurde ferner während des Workshops diskutiert, ob – und gegebenenfalls wie – man Erfahrungswissen (*Tacit Knowledge*) nutzbar machen könne. Eine Möglichkeit wurde in der Verwendung von Fragebögen, Interviews, Workshops und *supervised* Techniken gesehen, die die Entwickler in Prozesse einbinden. Eine starke Formalisierung und Automatisierung des „Erntens“ von *Tacit Knowledge* wurde angestrebt.

Wie bereits in TB 1.3.20 beschrieben, findet eine Integration von Domänenwissen über die Generierung von Trainingsdaten statt. Allerdings könnten bei Bedarf auch zusätzliche, händisch eingepflegte Prüfungen auf den Ergebnissen der KI-Algorithmen ausgeführt werden. Dies ist beispielsweise in Use-Case 6 geschehen, wo mit bestimmten Annahmen von Textpositionen und Einheiten das Mapping von Text auf Komponente verbessert wurde.

In Use-Case 5 ist diskutiert worden, wie man die KI mit einem auf einem Regelwerk basierenden System kombinieren könnte. Ein Chatbot sollte trainiert werden, der auf bestimmten Wenn-Dann Designregeln basiert. Stellt die KI nun eine bestimmte Fehlerklasse als wahrscheinlichste Ursache fest, kann dem Benutzer ausgegeben werden, ob schon Funktionalität X oder Dimensionierung Y auf dem Board überprüft wurde, was oft Ursachen für das genannte Problem sind.

Insgesamt ist aber aus den in Teilaufgabe 1 genannten Gründen Domänenwissen in Form von Trainingsdaten kodiert und nutzbar gemacht worden.

3.3.5 Teilaufgabe 3.5: Implementierung Meta-Algorithmen

Im TA3.5 wurden zwei unterschiedliche Ebenen von Meta-Methoden auf unterschiedlichen Architekturen (Server- und Cloud-basiert) implementiert. Einerseits wurden Algorithmen, die die eingesetzten KI-Verfahren aufgrund einer Daten-, Problemstellungs- und Lerndynamik-Analytik steuern für die Anwendungsebenen #1 - #2 bereitgestellt. Diese wurden bereits umfassend in den vorhergehenden TA, die ihrer Entwicklung dienten, beschrieben. Zusätzlich wurden in diesem TA Module implementiert, die weiteres, hochspezielles Domänenwissen bereitstellen:

Die hohen Komplexitätsgrade mikroelektronischer Systeme und die Vielzahl von zu beachtenden parasitären physikalischen Kopplungen erlauben es nicht, eine Validierung der entwickelten HW allein durch formale Beschreibungen des Systemverhaltens durchzuführen - selbst dann nicht, wenn

Modelle, Simulationsverfahren und die in diesem Projekt abgeleiteten Kenntnisse über Entwurfsabläufe vollumfänglich ausgenutzt werden.

Vielmehr muss immer noch ein erhebliches Meta-Wissen durch die jeweiligen Entwickler in den Entwurfs- und Validierungsprozess für mikroelektronische Systeme eingebracht werden.

Erforderlich ist eine Ebene aus Meta-Wissen, welches derzeit durch die jeweiligen Entwickler in den Entwurfs- und Validierungsprozess eingebracht wird.

Der Einsatz eines KI-basierten Systems kann dann die im Verlauf des Entwicklungsprozesses vorhandenen Wissenslücken durch systematische Erfassung des Meta-Wissens (Lernmodus) der beteiligten Entwickler schließen und den Bezug zum Gesamtkonzept des Systementwurfs wiederherstellen.

Damit bleibt die notwendige Flexibilität auf jeder Entwurfsstufe erhalten und der Komplexität der Zusammenhänge bei parasitären physikalischen Kopplungen wird Rechnung getragen. Die Entwurfsebenen von der |Anforderungsbeschreibung| bis zum |Test| müssen durch die Einbindung von Meta-Wissen unterstützt werden.

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

- Modell-Training und Optimierung mittels E2E ML Pipeline-Ansatz
- ML-Modelle für die automatisierte Extraktion von Bild-, Text- und Tabellen-Informationen aus Datenblättern und Systementwürfen (PCB-/IC-Entwurf)
- Effektive Planung von Lernfortschritten.
- Meta-Algorithmen für Cloud-basierten KI-Plattform-Ansatz
- Bewertung der Echtzeitfähigkeit von KI-Modulen mit Fokus auf die funktionale Sicherheit in komplexen Systemen
- Schnittstellenprogrammierung + Portierung und Verifikation + Cloud-Anbindung
- Verifikation und Validierung unterschiedlicher Einsatzszenarien der Anwendungsebene #1 mittels Meta-Algorithmen
- Erprobung und Validierung von Meta-Algorithmen.

Teilbeitrag 3.5.19: Untersuchung und Bereitstellung einer automatisierten und /oder benutzergesteuerten Auswahl von KI-Algorithmen zur Implementation definierter Meta-Algorithmen (19-TUB)

Ziele

Die Entwicklung einer Methodik zur Auswahl von KI-Algorithmen für unterschiedliche Szenarien der Anwendungsebene #1 war geplant.

Ein Meta-Algorithmus sollte bereitgestellt werden, der die für spezifische Problemstellungen optimalen KI-Modelle auswählt.

Die bestehenden KI-Modelle sollten optimiert und modularisiert werden, um sie für die Integration in zukünftige Meta-Algorithmen und erweiterte Frameworks nutzbar zu machen.

Es sollte eine Untersuchung und Validierung der Leistung der KI-Modelle unter Verwendung unterschiedlicher Daten- und Bewertungsmetriken durchgeführt werden.

Problemstellung

Der Teilbeitrag adressierte die Herausforderung, unterschiedliche Einsatzszenarien der Anwendungsebene #1 durch eine flexible und optimierte Auswahl von KI-Algorithmen zu unterstützen. Aufgrund der variierenden Anforderungen, wie beispielsweise der Frequenzbereiche bei Impedanzvorhersagen oder der Aktionsräume bei RL-Agenten, war es notwendig, mehrere spezialisierte Modelle zu entwickeln und geeignete Mechanismen zur Auswahl des am besten geeigneten Algorithmus bereitzustellen. Eine zentrale Herausforderung bestand darin, die KI-Modelle so zu modularisieren und zu parametrisieren, dass eine reibungslose Integration in zukünftige Meta-Frameworks gewährleistet war.

Lösungsweg und Ergebnisse

Im Rahmen von Teilbeitrag 3.5.19 wurden die Grundlagen für die Implementierung eines Meta-Algorithmus geschaffen, der die automatisierte Auswahl von KI-Modellen ermöglicht.

1. Hyperparameter-Optimierung der RL-Algorithmen:

- Die Hyperparameter der RL-basierten Decap-Platzierungsalgorithmen wurden mithilfe der Open-Source-Bibliothek *Optuna* optimiert. Diese Ergebnisse stellen eine wertvolle Basis für die zukünftige Integration in Meta-Algorithmen dar.

2. Training und Spezialisierung mehrerer Modelle:

- CNN-basierte Impedanzmodelle wurden auf verschiedene Frequenzbereiche (z. B. 50 MHz bis 1 GHz, 0,5 MHz bis 10 MHz, 100 kHz bis 100 MHz) trainiert. Dies ermöglicht die Auswahl des jeweils passendsten Modells für spezifische Platzierungsprobleme durch einen Meta-Algorithmus.

3. Modularisierung und Parametrisierung der Modelle:

- Zur Vorbereitung auf Meta-Algorithmen wurden sowohl die CNN-Module als auch die RL-Umgebungen modularisiert und parametrisiert. Diese Änderungen erlauben eine flexible Anpassung der Zielfunktionen, Bewertungsmetriken und Aktionsräume.

4. Erweiterung der RL-Agenten:

- Neben den bestehenden RL-Agenten (z. B. DQN) wurden zusätzliche Algorithmen wie Proximal Policy Optimization (PPO) implementiert, um die Auswahlmöglichkeiten für Meta-Optimierungen zu erweitern.

5. Validierung der KI-Modelle:

- Die CNN-Module für die Impedanzvorhersage wurden mit erweiterten Fehlermetriken wie *Mean Absolute Percentage Error (MAPE)* und *Root Mean Squared Error (RMSE)* validiert. Die Ergebnisse zeigen eine hohe Genauigkeit der Modelle und eine zuverlässige Konvergenz.

Durch die erarbeiteten Modelle und die Vorbereitungen für die Einbindung in ein Meta-Framework wurde ein entscheidender Schritt zur automatisierten und benutzergesteuerten Auswahl der besten KI-Algorithmen für die Anwendungsebene 1 erzielt.

3.3.6 Teilaufgabe 3.6: Validierung KI-Module/KI-Framework für Plattformen Anwendungsebenen #1 und #2

Mit der Zielsetzung von funktional-sicheren System-Gesamtfunktionen liefern z.B. eine messtechnische Validierung und ein abschließender Test sowie eine anschließende Dokumentation der Systemeigenschaften bereits im Entwurfsprozess eine erhebliche Datenmenge.

Das durch diese Datenmenge repräsentierte Entwurfswissen muss mittels angepasster KI-Module, die für jede Entwurfsebene eine andere Ausprägung haben müssen, effizient nutzbar gemacht werden.

Die durch die hier entwickelten KI-Module inklusive domänenspezifischer Wissensrepräsentation erstellten Charakterisierungen eines Entwurfs bzw. Entwurfsstadiums musste die Notwendigkeit des Durchlaufens einer neuen Entwurfsphase oder den Abschluss einer Entwicklung aufzeigen.

Da Messdaten ebenfalls mit den modularen KI-Plattform(en) eingelesen werden können und dem entsprechend zur Validierung von Simulationsmodellen und der Verfeinerung von Entwurfsregeln herangezogen werden können, war es möglich, den gesamten Entwurfsprozess KI-gestützt durchzuführen und parallel dazu die KI-Module weiter zu trainieren.

Für die Validierung der in AP3 erstellten KI-Module und der KI-Frameworks für die Plattformen der Anwendungsebenen #1 - #2 mussten die folgenden Aspekte beachtet werden:

- Anwendung der entwickelten und implementierten Algorithmen (AP2 und AP3) zur mathematischen Analyse der Gesamtheit in progressivKI implementierten KI-Algorithmen
- Bewertung spezieller UseCases durch Nutzung der entwickelten und implementierten Metriken zur Bestimmung der Güte der Eingangs- und Ausgangsdaten, sowie der KI-Algorithmen
- Verwendung von Metriken zur Beurteilung des Lernfortschritts der implementierten KI-Algorithmen
- Verwendung und Validierung der erarbeiteten Metriken für Datenqualität
- Festlegung des operationellen Vorgehens zur Sicherung und Überprüfung der Datenqualität
- Bewertung des Konfigurationsraums und dessen Ausschöpfung
- Validierung von KI-Ergebnissen durch Simulation in dedizierten Entwurfsräumen
- Bewertung des Lernerfolges durch künstliche Intelligenz. Die Bewertung kann genauer a posteriori erfolgen, wenn unterschiedliche Lernstrategien parallel verfolgt und verglichen werden.

Die folgenden Themen mussten bearbeitet werden:

- Erstellung von Datensätzen zur Validierung der vorliegenden KI-Framework (Kombination der erstellten KI-Module für die Anwendungsebenen #1 - #2) Versionen
- Identifikation von angepassten Datensätzen zur Validierung von möglichen Optimierungen der vorliegenden KI-Framework Versionen
- Test-Verbesserungen für KI-Module durch Anpassung von Trainingsdaten
- Validierte Metriken und Meta-Algorithmen zur Sicherstellung der Qualität von KI-Algorithmen
- Modell-Evaluation und Test mittels Metriken und Meta-Algorithmen
- Test und Validierung von KI-Ergebnissen für PCB-Fertigungsprozesse

- Test-Durchführung und Validierung sowie Auswertung zur Optimierung von KI-Modulen für die Anwendungsebenen #1 - #2
- Validierung/Optimierung von KI-Modulen für die Anwendungsebene #2.

Teilbeitrag 3.6.19: Validierung/Optimierung von KI-Modulen für die Anwendungsebene #1 (19-TUB)

Ziele

Validierung der KI-Module

Die bestehenden KI-Module innerhalb des KI-Frameworks der Anwendungsebene #1 sollten anhand von Testdaten validiert werden, um sicherzustellen, dass sie die angestrebten Anforderungen und Vorhersagen korrekt und zuverlässig erfüllten.

Optimierung der KI-Module

Es sollte eine kontinuierliche Verbesserung und Feinabstimmung der KI-Module erfolgen, um ihre Genauigkeit und Effizienz zu erhöhen. Dabei wurden sowohl einzelne Module als auch deren Zusammenspiel im Gesamtframework betrachtet.

Vergleich mit Expertenwissen

Die Leistung der KI-Module sollte mit dem zuvor annotierten Expertenwissen und den berechneten Vorhersagen verglichen werden, um die Übereinstimmung und Validität der Modelle zu überprüfen.

Testdatenbasierte Validierung

Die KI-Module sollten mit einem Satz von Testdaten evaluiert werden, um deren praktische Anwendbarkeit und Leistung unter realistischen Bedingungen zu überprüfen.

Problemstellung

Die KI-Module in der Anwendungsebene #1 sind darauf angewiesen, genaue Vorhersagen für Power Integrity-Probleme und PCB-Designs zu liefern. Um die Qualität und Verlässlichkeit dieser Vorhersagen zu garantieren, mussten die Module gegen Testdaten validiert werden. Eine weitere Herausforderung bestand darin, sicherzustellen, dass das Zusammenspiel der verschiedenen KI-Module innerhalb des KI-Frameworks reibungslos funktionierte. Zudem musste die Leistungsfähigkeit der Modelle mit dem annotierten Expertenwissen verglichen werden, um sicherzustellen, dass die KI-Lösungen sowohl in der Theorie als auch in der Praxis den Anforderungen gerecht wurden. Eine kritische Herausforderung bei der Validierung und Optimierung war die Nutzung von Testdaten, die das gesamte Spektrum möglicher Design- und Simulationsszenarien abdeckten, um sicherzustellen, dass die Modelle auch in realen Anwendungen korrekt arbeiteten.

Lösungsweg und Ergebnisse

Das Teilbeitrag 3.6.19 befasste sich mit der Validierung und Optimierung der im Projekt entwickelten Modelle und Algorithmen. Ziel war es, die entwickelten CNN-Modelle zur Impedanzvorhersage sowie den Reinforcement-Learning-(RL)-basierten Algorithmus für die Platzierung von Abblockkondensatoren (Decaps) auf ihre Praxistauglichkeit und Genauigkeit hin zu überprüfen und weiter zu verbessern.

1. Validierung der CNN-Modelle zur Impedanzvorhersage

- Evaluation mittels Loss-Funktion
Die entwickelten CNN-Modelle wurden während der gesamten Projektlaufzeit mithilfe der Loss-Funktion evaluiert. Diese bot eine quantitative Metrik zur Beurteilung der Modellgenauigkeit während des Trainings und bei Testläufen.




Abbildung 36: Average-Case (oben) und Worst-Case (unten) des 100 MHz Modells.

- Vergleich mit Simulationskurven
Um die Qualität der Vorhersagen sicherzustellen, wurden die simulierten und vorhergesagten Impedanzkurven miteinander verglichen. Diese Vergleiche bestätigten, dass die Modelle eine hohe Übereinstimmung mit den Simulationsdaten erreichten (siehe Abbildungen).

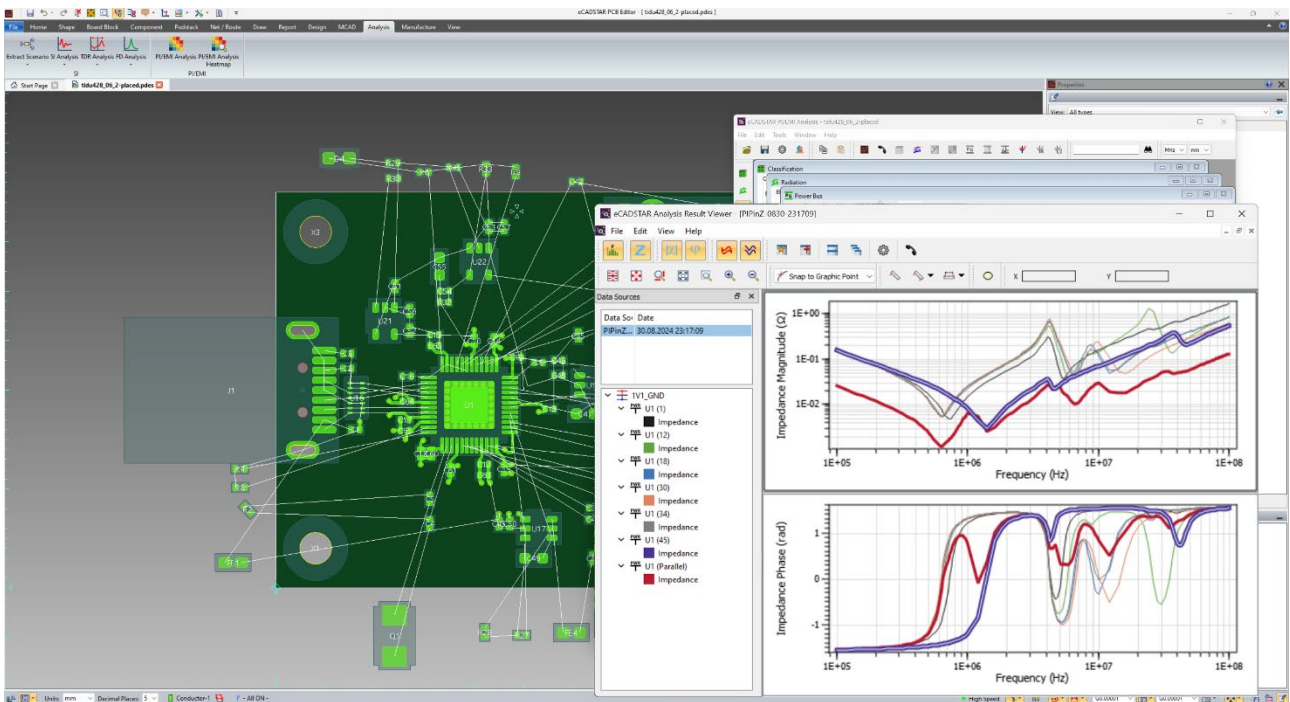


Abbildung 37: Impedanzsimulation des Demo-Boards im Zuken eCADSTAR

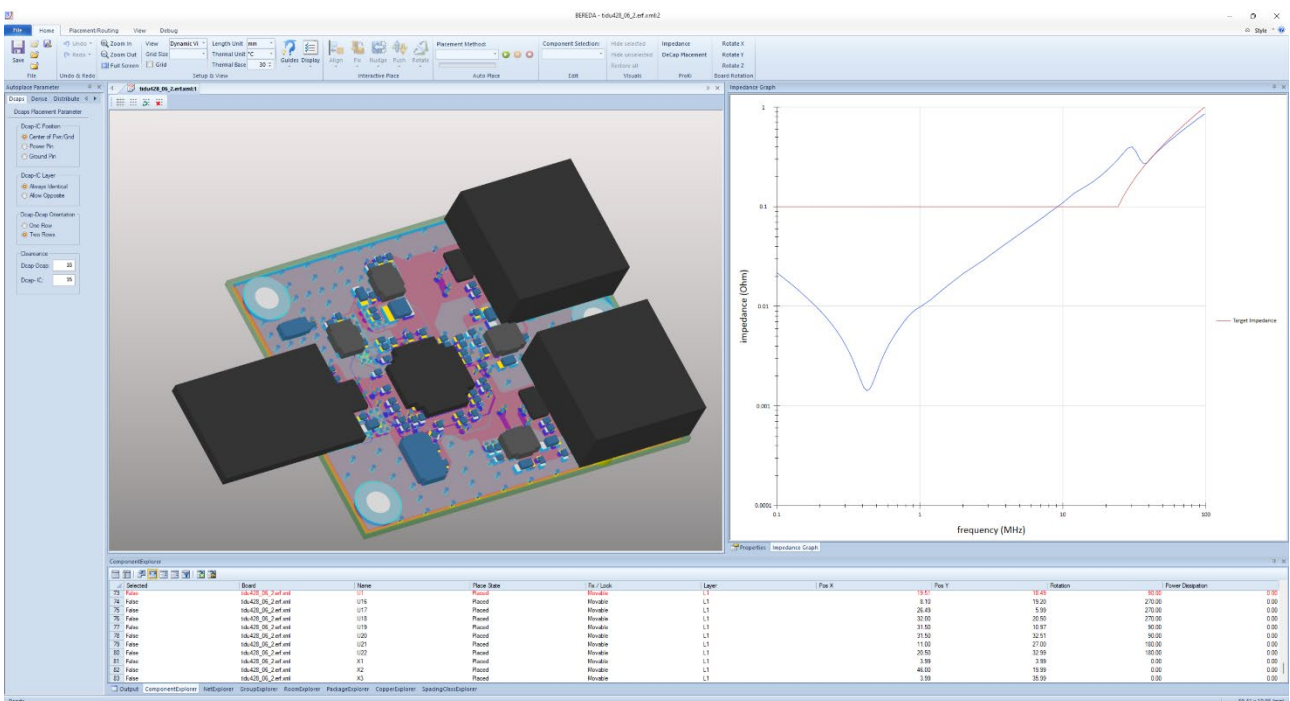


Abbildung 38: Dasselbe Board mit Echtzeit-Impedanzvorhersage durch KI-Modul im Software-Demonstrator "BEREDA": Im Gegensatz zum eCADSTAR wird hier die Impedanz nur für einen Pin in vorhergesagt.

2. Validierung und Optimierung des Reinforcement-Learning-Ansatzes

- Erste Validierungsversuche mit DQN-Agenten
 - Zu Beginn der Entwicklung wurde ein Deep-Q-Learning-(DQN)-Agent eingesetzt. Die Validierung erfolgte mit einer einfachen Bewertungsfunktion, die schnelle Rückschlüsse auf die Funktionsfähigkeit des Algorithmus zuließ.
 - Einfaches Bewertungsziel: Eine Gesamtbewertung über 100 deutete auf einen erfolgreichen Platzierungsvorgang hin.

- Übergang zu PPO und maskable PPO
Für präzisere Ergebnisse wurde später ein Proximal Policy Optimization-(PPO)-Agent mit einer komplexeren Bewertungsfunktion verwendet.

- Diese Funktion umfasste mehrere Parameter, die den physikalischen Anforderungen und den Entwurfszielen besser entsprachen, darunter die Einhaltung von Impedanzlimits und die optimale Nutzung von Decaps.

3. Herausforderung der Bewertung

Aufgrund der erhöhten Komplexität der Bewertungsfunktion war eine direkte Bewertung des RL-Agents anhand der durchschnittlichen Belohnung weniger intuitiv. Eine detailliertere Validierung erfolgte durch den Vergleich mit realen Platzierungen und der Integration in den Software-Demonstrator (siehe TB 4.1.19).

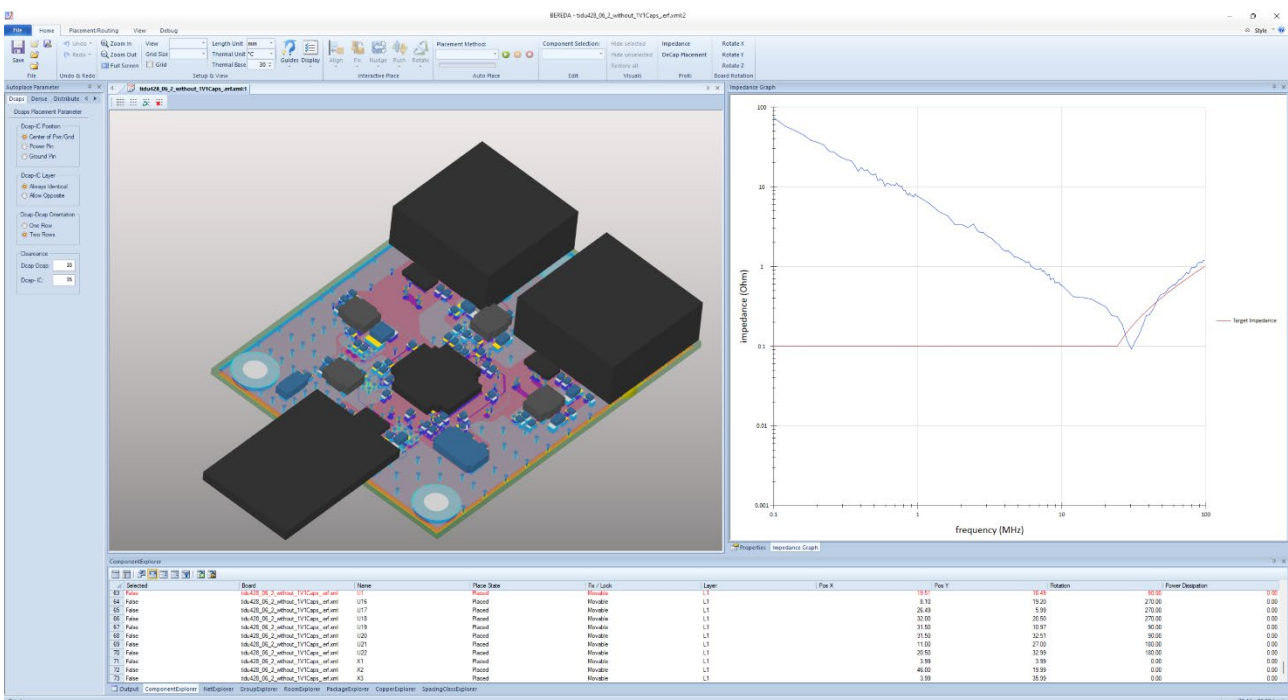


Abbildung 39: Impedanz an einem Power-Pin, bei dem alle Decaps im zugehörigen Netz entfernt wurden.

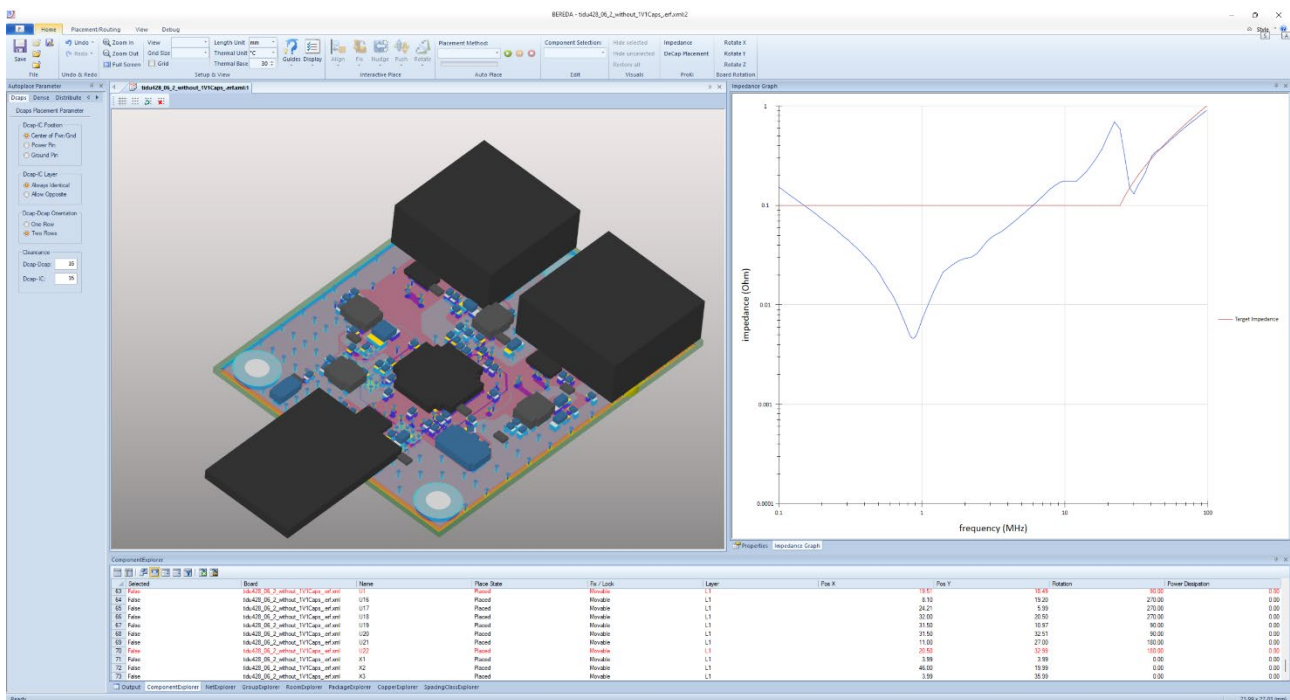


Abbildung 40: Impedanz nach der Anwendung des Reinforcement-Learning-Agenten.

Die Validierung und Optimierung der Modelle erfolgte kontinuierlich und in enger Abstimmung mit den Anforderungen des Software-Demonstrators und den Simulationsergebnissen. Die CNN-Modelle zur Impedanzvorhersage zeigten hohe Genauigkeit, und der RL-Algorithmus wurde durch fortlaufende Anpassungen der Bewertungsfunktion und Tests auf spezifischen PCBs optimiert.

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

Anhand von zwei zu gestaltenden Ausprägungen der modularen KI-Plattform sollte der bisherige Entwicklungsprozess angewendet werden und so dessen Impact nachgewiesen werden. Diese zwei Plattformausrägungen (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 Plattformausrägungen für die Anwendungsbereiche #1 - #2 nachgewiesen werden.

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

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

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

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

Auch ist es notwendig zu überprüfen, ob die Analyse von Entwurfsentscheidungen hinsichtlich physikalischer Kopplungen durch die jeweiligen KI-Module (z.B. EMC/SI/Thermische Kopplungen) im Zusammenhang mit dem Entwurf eines vollständigen elektronischen Systems (Use-Cases/Referenzsysteme (HW): Leiterplatte für Infotainment-Komponente oder PCB/Kabel mit 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 Plattformausrüstungen #1 - #2. Diese Dokumentation enthält auch alle Angaben zu den Entwurfs-Entscheidungen, die durch die verwendeten KI-Module getroffen wurden. Darüber hinaus stellt diese Dokumentation für das sogenannte Nach-Training der KI-Module eine wesentliche Rolle dar. So lassen sich die Entwurfsentscheidungen der erfahrenen Entwickler mit den Entwurfsvorschlägen der KI-Module vergleichen und als weitere Trainingsdaten verwenden.

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

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

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

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

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

Geplante Ergebnisse von AP4 waren:

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

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

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

Als Schaltungsträger für funktional sichere elektronische Systeme werden hier alle heute gängigen PCB-Ausrägungen betrachtet (Material: FR4/PTFE/Polyamid/...; Ausführung: Flex- oder Starrflex-PCBs; Metallkern; HF; Hoch-TG; Dickkupfer; hochlagige Multilayer; Feinstleiterstrukturen).

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

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

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

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

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

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

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

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

Teilbeitrag 4.1.19: Integration der im Vorhaben bereitgestellten KI-Module zusammen mit den implementierten Schnittstellen (EDA-Tools; Analysesysteme; KI-Module) in ein Gesamtsystem (TRL 6) (19-TUB)

Ziele

Integration der Projektergebnisse in einen Software-Demonstrator

Es war vorgesehen, die Projektergebnisse, insbesondere die entwickelten KI-Module, Schnittstellen und Tools, in einen Software-Demonstrator zu integrieren, der den gesamten Designflow entlang der Wertschöpfungskette der Anwendungsebene #1 abbilden sollte.

Auswahl und Integration von KI-Modulen und Schnittstellen

Die entwickelten KI-Module sollten ausgewählt und zusammen mit den implementierten Schnittstellen (EDA-Tools, Analysesysteme, KI) in das Gesamtsystem integriert werden, um den Designprozess effizient zu unterstützen.

Entwicklung einer benutzerfreundlichen grafischen Benutzeroberfläche (GUI)

Es war geplant, eine benutzerfreundliche GUI zu entwickeln, die es den Nutzern ermöglichte, auf einfache Weise mit dem Software-Demonstrator zu interagieren.

Visualisierung von Schnittstellendaten und KI-Ergebnissen

Die Daten, die zwischen den verschiedenen Systemen ausgetauscht wurden, sowie die Ergebnisse der KI-Module sollten visualisiert werden, um eine transparente und verständliche Darstellung der Designprozesse und -ergebnisse zu bieten.

Evaluierung durch die Anwendungs-Partner

Der Software-Demonstrator sollte den Anwendungs-Partnern zur Verfügung gestellt werden, um die Funktionalität und Effektivität des Gesamtsystems zu testen und zu evaluieren.

Problemstellung

Um den Designflow für die Anwendungsebene #1 vollständig abzubilden, mussten die verschiedenen im Projekt entwickelten Komponenten, wie KI-Module, Schnittstellen und Analysewerkzeuge, in einen kohärenten Software-Demonstrator integriert werden. Dabei stellte sich die Herausforderung, den Designprozess so zu gestalten, dass er alle relevanten Phasen und Datenströme entlang der Wertschöpfungskette effizient abbildete. Eine weitere Schwierigkeit lag in der Entwicklung einer intuitiven und benutzerfreundlichen grafischen Benutzeroberfläche (GUI), die den Nutzern eine einfache Handhabung des Demonstrators ermöglichte. Zusätzlich mussten alle Schnittstellendaten und KI-Ergebnisse transparent visualisiert werden, um eine fundierte Auswertung und Nutzung zu ermöglichen. Die Integration der Labeling-Tools stellte eine weitere Herausforderung dar, da diese Tools die korrekte Annotation von Trainingsdaten sicherstellen mussten. Abschließend mussten die Anwendungs-Partner das System testen, um die Wirksamkeit und Nutzbarkeit des Demonstrators zu evaluieren und gegebenenfalls Anpassungen vorzunehmen.

Lösungsweg und Ergebnisse

In Teilbeitrag 4.1.19 stand die Integration der entwickelten KI-Modelle und Algorithmen in den Software-Demonstrator BEREDA im Fokus. Ziel war es, eine nahtlose Verbindung zwischen Layoutdaten, KI-Modulen und der Benutzeroberfläche zu schaffen, um eine Echtzeit-Interaktion und Visualisierung zu ermöglichen.

1. Initiale Integration über REST-Schnittstellen

- Prototypische Anbindung

Zu Beginn wurde eine REST-Schnittstelle entwickelt, um Layoutdaten in Matrixform an die externen KI-Modelle zu übergeben. Die Modelle wurden in Python ausgeführt, wobei die Berechnungsergebnisse – einschließlich der Impedanzvorhersagen – in einem separaten Fenster visualisiert wurden. Diese Visualisierung basierte auf matplotlib.

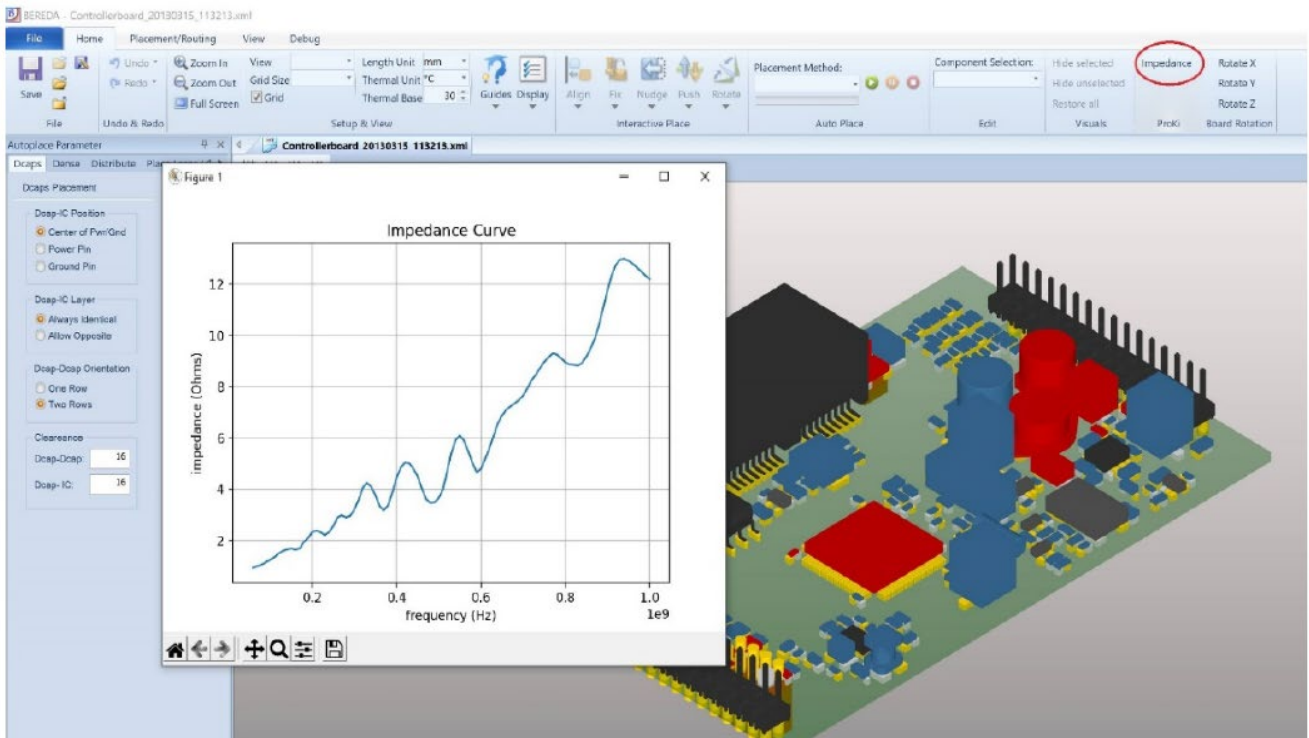


Abbildung 41: Erste Einbindung des Impedanzmoduls über REST-API.

- Einschränkungen der REST-Integration

Jede neue Vorhersage erforderte das erneute Starten des Python-Skripts und das Laden des KI-Modells, was zu erheblichen Verzögerungen führte. Zudem war die Darstellung nicht vollständig in die Benutzeroberfläche von BEREDA integriert, was die Benutzererfahrung beeinträchtigte.
- 2. Optimierung durch native Einbindung der KI-Modelle
 - Umstellung auf ONNX-Modelle

Um die Effizienz zu verbessern, wurden die KI-Modelle in das ONNX-Format konvertiert. Die Integration erfolgte mithilfe der ONNX Runtime API, die eine direkte Einbindung der Modelle in den C++-basierten Demonstrator ermöglichte.

 - i. Die Modelle konnten nun direkt als Objekte in BEREDA geladen werden, was die Vorhersagezeiten drastisch reduzierte.
 - ii. Es mussten spezielle Array-Formate für die Datenübertragung verwendet werden, was Debugging und Entwicklung zunächst erschwerte.
 - GUI-Integration:

Für die Visualisierung der Impedanzkurven wurde die bestehende GUI von BEREDA, basierend auf BCGSoft und MFC-Klassen, erweitert.

 - i. Funktionen der GUI: Darstellung von Zielimpedanzkurven mit korrekter Achsenskalierung und flüssiger Echtzeit-Visualisierung.
 - ii. Ein Umschaltmechanismus für unterschiedliche Frequenzbereiche wurde implementiert, um zwischen verschiedenen Modellen und den zugehörigen Achsen wechseln zu können.
 - Echtzeit-Impedanzvorhersage:

Durch die native Einbindung konnte die Impedanzvorhersage nahezu in Echtzeit erfolgen. Dies wurde ermöglicht, indem die Modelle einmalig geladen wurden und Vorhersagen direkt über die ONNX Runtime API ausgeführt wurden.

3. Erweiterte Funktionen für Benutzerfreundlichkeit

- Farbliche PCB-Darstellung
Nach der Auswahl eines Decaps wurde eine Farbcodierung des PCBs implementiert, die gute und schlechte Platzierungspositionen markiert. Diese visuelle Unterstützung basierte auf den Impedanzvorhersagen der KI und erleichtert es den Nutzern, optimale Platzierungen schnell zu erkennen.
- Integration des Reinforcement-Learning-Algorithmus
Der RL-Agent für die Decap-Platzierung wurde über die REST-Schnittstelle angebunden. Da typischerweise nur eine Platzierung pro PCB erforderlich ist, war diese Methode ausreichend performant.

i. Es wurde zusätzlicher Code implementiert, um Decaps dynamisch zu erzeugen und Platzierungsvorschläge zu simulieren.

4. Es wurde daran gearbeitet, die KI-Modelle für Echtzeit-Impedanzvorhersage und Kondensatorplatzierung in den Altium Designer zu integrieren. Ziel war es, die entwickelten Algorithmen direkt in die Arbeitsumgebung des Layout-Tools einzubinden, um Designern eine unmittelbare Unterstützung bei der Decap-Platzierung zu bieten. Dabei lag der Schwerpunkt auf der Anpassung der KI-Module an die spezifischen Anforderungen und Schnittstellen des Altium Designers, um eine nahtlose Funktionalität zu gewährleisten.

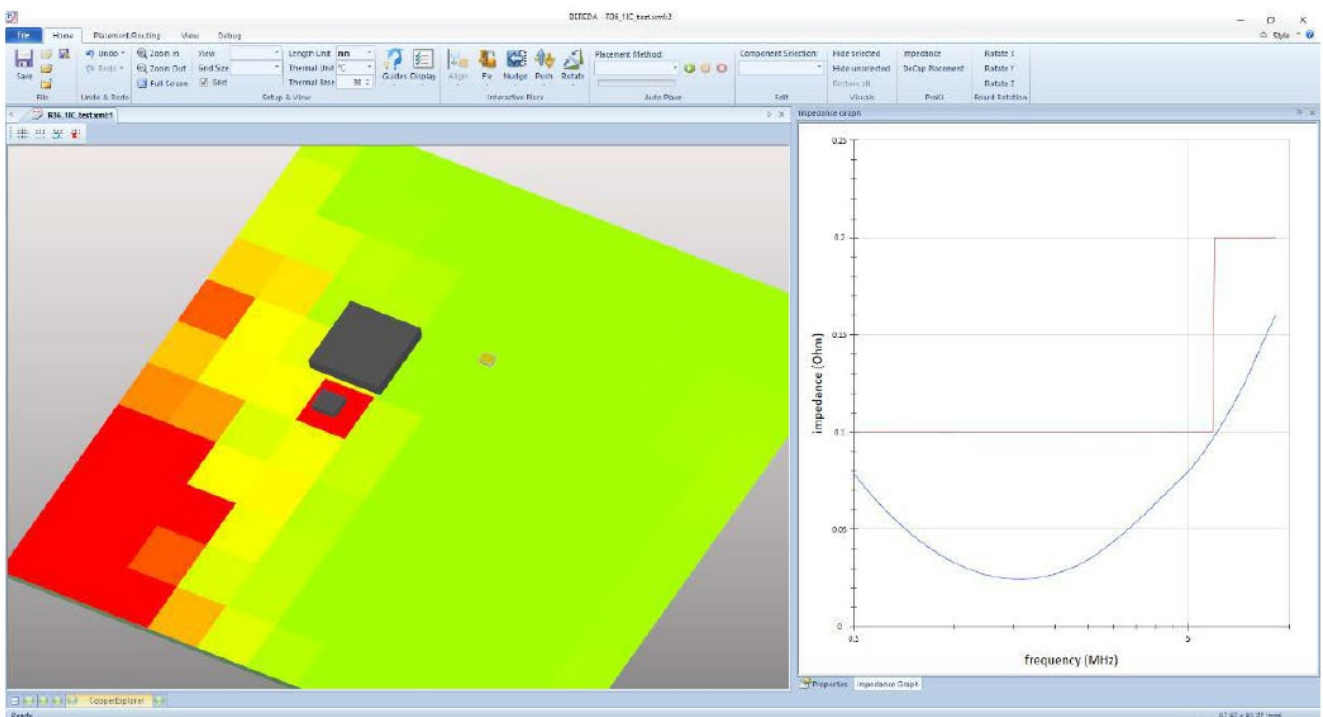


Abbildung 42: Direkt im Software-Demonstrator integriertes KI-Modul über ONNX Runtime API. Ermöglicht Impedanzvorhersage in Echtzeit. Änderungen können durch Color-Highlighting vorgenommen werden, das ebenfalls auf dem KI-Modul basiert.

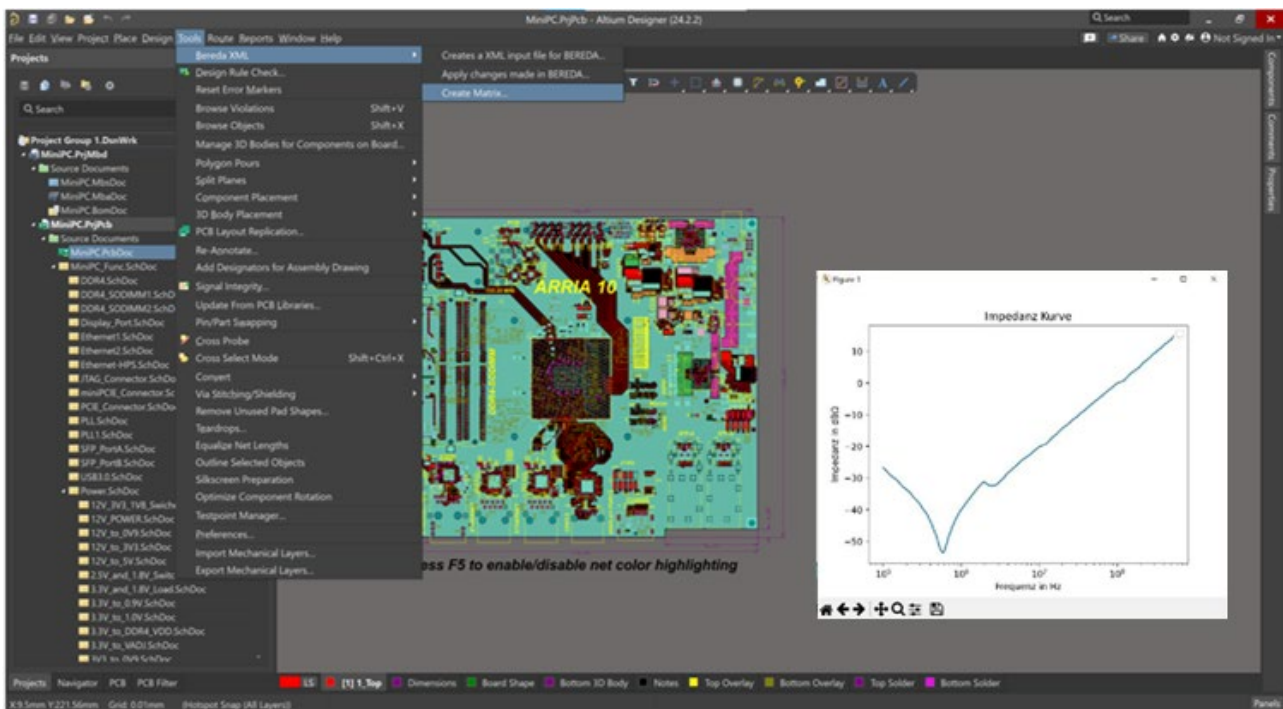


Abbildung 43: Aufruf des KI-Impedanzmoduls im Altium Designer über das Extension System.

3.4.2 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.

3.5 Arbeitspaket 5: Projektmanagement & Dissemination

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

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

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

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

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

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

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

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

- Einrichtung einer Projektorganisation (Projektbüro)
- Aufbereitung strategischer edaKI-Themen (Beitrag zur edaKI-RoadMap)
- Organisation von Treffen mit dem Projektteam
- Organisation von Review-Treffen
- Herstellung relevanter Kontakte mit anderen edaKI-Forschungsaktivitäten auf europäischer und nationaler Ebene
- Überwachung des technischen/wissenschaftlichen progressivKI-Managements und Behandlung rechtlicher progressivKI-Themen, die Behandlung von IP-Angelegenheiten und laufenden Konsortiumsabsprachen
- Überwachung des technischen Projekt-Fortschritts, der Einhaltung von Meilensteinen und Darstellung der Projektergebnisse
- Erstellung eines halb-jährlichen Fortschrittberichts zum Projekt
- Einrichtung und Durchführung eines Qualitäts- und Risikomanagements; dazu werden spezifische progressiv-Projekt Stakeholder von jedem Industriepartner vorgeschlagen
- Abstimmung der Kostenaufstellung(en) mit dem jeweils aktuellen Fortschrittsbericht.

Geplante Ergebnisse von AP5 waren:

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

3.5.1 Teilaufgabe 5.1: Projektleitung/ProjektOffice + progressivKI Advisory Board

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

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

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

Im progressivKI-Konsortium wurde festgelegt, dass die Koordination der Projektarbeit und die Steuerung der wichtigen Aufgaben Innen- und Außenkommunikation, Datenfluss und Informationsmanagement, IT-Ressourcenplanung, Verwertung etc. nur mit Hilfe eines ProjektOffice in der erforderlichen Qualität geleistet werden kann und dass für den Betrieb des progressivKI-Office umfangreiche Erfahrungen auf dem Gebiet der Steuerung und FE-Betreuung von öffentlich geförderten Projekten verfügen müssen.

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

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

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

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

Teilbeitrag 5.2.19: F+E-Ergebnisse + F+E-Nutzungsplanung eda-Schnittstellen <=> KI-Module (19-TUB)

Ziele

Testen und Präsentieren der erzielten Forschungsergebnisse

Die erzielten Forschungsergebnisse sollen im Rahmen von Vorträgen, Veröffentlichungen und Demonstrationen getestet und präsentiert werden.

Einbindung neuer sowie bestehender F+E-Partner

Die Ergebnisse sollen gezielt kommuniziert werden, um sowohl neue als auch bestehende F+E-Partner einzubinden und deren Anwendungspotenziale aufzuzeigen.

Veröffentlichung der Forschungsergebnisse

Die Forschungsergebnisse sollen auf relevanten Konferenzen und in begleitenden Ausstellungen veröffentlicht werden, um die Sichtbarkeit und den Transfer der gewonnenen Erkenntnisse in die wissenschaftliche und industrielle Gemeinschaft zu fördern.

Problemstellung

Ein zentrales Anliegen dieses Teilbeitrages war es, die vielfältigen Forschungsergebnisse des Projekts so aufzubereiten, dass sie effektiv kommuniziert und einer breiten Zielgruppe zugänglich gemacht werden können. Neben der technischen Validierung war es erforderlich, die Ergebnisse sowohl für assoziierte Partner als auch für potenzielle Interessenten in Industrie und Wissenschaft nachvollziehbar zu präsentieren. Darüber hinaus sollten durch die Präsentation auf relevanten Konferenzen und Ausstellungen neue Netzwerke und Anwendungsfelder erschlossen werden, um den Transfer der entwickelten Technologien zu unterstützen.

Lösungsweg und Ergebnisse

1. Präsentationen und Vorträge:

- a. Auf der Kleinheubacher Tagung 2022 wurde ein Vortrag mit dem Titel "Ein Beitrag zur Behandlung von Power Integrität Entwurfsaufgaben mittels Reinforcement Learning" gehalten.
- b. Die bisherigen Ergebnisse wurden im Rahmen des AVT-Seminars am Fraunhofer IZM präsentiert.
- c. Ein weiterer Vortrag mit dem Titel "AI Driven Power Integrity Compliant Design of High-Speed PCB" wurde auf der EMC Europe 2024 gehalten.

2. Veröffentlichungen:

- a. Der Beitrag "AI-supported PDN Design for PCBs in Automotive Applications" [70] wurde veröffentlicht und auf der iCampus Cottbus Conference (iCCC 2024) in Form einer Posterpräsentation vorgestellt.
- b. Ein Beitrag mit dem Titel "AI Driven Power Integrity Compliant Design of High-Speed PCB" [69] wurde für die EMC Europe 2024 veröffentlicht.

3. Demonstrationen:

- a. Eine Demo für den ProgressivKI-Tag in Hamm wurde erfolgreich vorbereitet und vorgeführt.
- b. Für das ProgressivKI-Abschlussseminar wurde eine finale Demo erstellt, die die Ergebnisse anschaulich zusammenfasste und die Anwendungsmöglichkeiten der entwickelten Technologien verdeutlichte.

3.5.3 Teilaufgabe 5.3: Dokumentation Gesamtprojekt

Im Rahmen von Teilaufgabe 5.3 lag der Fokus auf der sorgfältigen Aufbereitung der Forschungs- und Entwicklungsergebnisse der jeweiligen Teilvorhabens für das gemeinsame Projektarchiv. Dies beinhalteten die systematische Zusammenstellung und Strukturierung sämtlicher relevanten Informationen, um eine übersichtliche und leicht zugängliche Dokumentation zu gewährleisten.

4 Verwertung und voraussichtlicher Nutzen

19-TUB

Ausgangslage

Vor Beginn des Projekts *progressivKI* gab es keine etablierten Ansätze, um KI-gestützte Methoden für die Optimierung von Power-Integrity-Analysen und PCB-Design-Prozessen in einem vollständig integrierten Workflow zu nutzen. Der Bedarf an hochspezialisierten Werkzeugen, die Domänenwissen effizient einbinden und gleichzeitig eine benutzerfreundliche Integration in bestehende EDA-Umgebungen ermöglichen, wurde in der Industrie zunehmend erkannt. Dennoch waren bestehende Lösungen oft auf allgemeine KI-Frameworks beschränkt, die für spezifische Herausforderungen der Anwendungsebene #1 (z. B. die Impedanzvorhersage oder DeCap-Platzierung) weder optimiert noch validiert waren.

Ergebnisse in *progressivKI*

Im Rahmen des Projekts wurden innovative KI-Module entwickelt, die speziell für die Anwendungsebene #1 maßgeschneidert sind. Hierzu zählen insbesondere:

- Entwicklung eines KI-gestützten Ersatzmodells für Impedanzsimulationen, das gezielt an reale PCB-Daten angepasst wurde.
- Implementierung eines Reinforcement-Learning-Agenten zur Optimierung der DeCap-Platzierung, der mithilfe von Echtzeit-Feedback des Impedanzmodells die Designeffizienz erheblich verbessert.
- Integration dieser KI-Module in den Software-Demonstrator *BEREDA* unter Einsatz moderner Schnittstellentechnologien wie REST-API und ONNX Runtime API.
- Echtzeit-Visualisierung der Impedanzanalyse und Bereitstellung einer interaktiven, KI-gestützten Optimierung der DeCap-Platzierung im *BEREDA*.
- Etablierung eines durchgängigen Workflows zur PDN-Optimierung, der über die *BEREDA*-Schnittstellen bestehende EDA-Tools wie Zuken eCADSTAR und Altium Designer nahtlos einbindet.

Diese Ergebnisse wurden durch umfassende Tests und Validierungen mit realistischen Testdaten sowie durch Kooperation mit den Anwendungs-Partnern auf ihre Praxistauglichkeit hin überprüft.

Nutzen und Verwertbarkeit

Die im Projekt entwickelten Technologien bieten vielfältige Verwertungsmöglichkeiten:

1. **Wissenschaftliche Verwertung:**

Die Erkenntnisse und entwickelten Module fließen in die Forschungsschwerpunkte der TU

Berlin ein, insbesondere in den Bereichen KI-gestützte Elektronikentwicklung und Power-Integrity-Analyse. Sie dienen als Grundlage für zukünftige Forschungsprojekte und ermöglichen eine stärkere internationale Vernetzung. Ergebnisse wurden auf Konferenzen präsentiert und veröffentlicht, um die Fachöffentlichkeit zu erreichen und neue Kooperationen zu initiieren.

2. Industrielle Anwendung:

Die entwickelten KI-Modelle und Schnittstellen werden kontinuierlich weiter optimiert, mit dem Ziel, sie zu marktreifen Produkten weiterzuentwickeln und in industrielle Designprozesse zu integrieren. Hierfür sind gegebenenfalls Bug-Fixes sowie eine Feintuning der Software-Komponenten erforderlich. Die erstellten Demonstratoren dienen als Brücke zwischen akademischer Forschung und industrieller Praxis, indem sie den Transfer von innovativen Lösungen in die realen Anwendungsumgebungen ermöglichen.

3. Lehre und Ausbildung:

Die Projektergebnisse werden in Lehrveranstaltungen und Seminaren der TU Berlin integriert, um den Wissenstransfer an Studierende zu fördern. Dies ermöglicht es den Studierenden, die im Projekt entwickelten Technologien und Methoden in ihre zukünftigen Arbeitsfelder zu übernehmen. Darüber hinaus können auf diesen Ergebnissen basierend Bachelor- und Masterarbeiten verfasst werden, was den nachhaltigen Mehrwert der Forschung weiter verstärkt.

4. Langfristige Verwertbarkeit:

Durch die Etablierung von Schnittstellenstandards und die Integration in gängige EDA-Werkzeuge werden die Projektergebnisse auch langfristig anwendbar sein. Die modulare Struktur der entwickelten Lösungen ermöglicht eine flexible Anpassung an neue Anwendungsbereiche und sich ändernde Anforderungen in der Industrie.

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“, xxxxxxxxxxxxxxxxxxxx, xxxxxxxxxxxxxxxxxxxxxxxxxxxxxxx
- [5] Nima Ghafarian Shoaee, Zouhair Nezhi, Werner John, Ralf Brüning, and Jürgen Götze: „Generating AI Modules for Decoupling Capacitor Placement Using Simulation“, xxxxxxxxxxxxxxxxxxxx, xxxxxxxxxxxxxxxxxxxxxxxxxxxxxxx
- [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. Withöft; J. Götze (17-TUDO); W. John (PYRAMIDE2525) „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 (PYRAMIDE2525); 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 (PYRAMIDE2525) 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 Electro-magnetic 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. Ramanan: "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>

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://deppcb.ai/>), Demystifying Machine Learning for Signal and Power Integrity Problems in Packaging (<https://ieeexplore.ieee.org/document/9149655>)
- [Dernoncourt] Dernoncourt F., Young Lee J. und Szolovits P. (2017) Neuroner: an easy-to-use program for named-entity recognition based on neural networks. arXiv preprint arXiv:1705.05487
- [Dhiran] Dhiran, T., & Sharma, R. (2013). Table detection and extraction from image document. International Journal of Computer & Organization Trends, 3(7), 275-278.
- [Dierig] Dierig, C. (2018, April 22). Fachkräftemangel kostet Deutschland 30 Milliarden Euro. WELT. Retrieved from: <https://www.welt.de/wirtschaft/article175699077/Fachkraeftemangel-kostet-Deutschland-30-Milliarden.html>
- [DiKMU] Karl Lichtblau, Thomas Schleiermacher, Henry Goecke, Peter Schützdeller: Digitalisierung der KMU in Deutschland – Konzeption und empirische Befunde, iwconsult, Köln, 2018
- [DiWiGe] Karl Lichtblau, Manuel Fritsch, Agnes Millack: Digitalisierung von Wirtschaft und Gesellschaft in Deutschland – ein Überblick, iwconsult, Köln, 2018
- [DREAMplace] DREAMPlace: Deep Learning Toolkit-Enabled GPU Acceleration for Modern VLSI Placement (<https://www.cerc.utexas.edu/utda/publications/C252.pdf>)
- [EffectivePCB] Effective PCB Decoupling Optimization by Combining an Iterative Genetic Algorithm and Machine Learning (<https://www.mdpi.com/2079-9292/9/8/1243>)

- [Ertel] Wolfgang Ertel: Grundkurs Künstliche Intelligenz - Eine praxisorientierte Einführung, 4., überarbeitete Auflage, Springer Vieweg, 2016
- [Esteban] Arroyo Esquivel Esteban, Capturing and Exploiting Plant Topology and Process Information as a Basis to Support Engineering and Operational Activities in Process Plants, Dissertation, HSU / UNiBw H 2017
- [Eurostat] Eurostat. (November 20, 2018). Number of enterprises in the manufacture of electronic components industry in Germany from 2008 to 2016 [Graph]. In Statista. Retrieved May 07, 2020, from <https://www.statista.com/login.bibproxy.whu.edu/statistics/383830/enterprises-manufacturing-electronic-components-germany/>
- [Evertiq] Evertiq (2018, Januar 08). Top 25 der EMS-Dienstleister in Europa. Retrieved from: <https://evertiq.de/news/21703>
- [Farrukh] Farrukh, W., Foncubierta-Rodriguez, A., Ciubotaru, A. N., Jaume, G., Bejas, C., Goksel, O., & Gabrani, M. (2017, November). Interpreting data from scanned tables. In 2017 14th IAPR International Conference on Document Analysis and Recognition (ICDAR) (Vol. 2, pp. 5-6). IEEE.
- [Fisher] Fisher, R. A.: The Use of Multiple Measurements in Taxonomic Problems. *Annals of Eugenics*. 7 (2), Seiten 179–188, 1936
- [FMI] <https://fmi-standard.org>
- [Gatos] Gatos, B., Danatsas, D., Pratikakis, I., & Perantonis, S. J. (2005, August). Automatic table detection in document images. In *International Conference on Pattern Recognition and Image Analysis* (pp. 609-618). Springer, Berlin, Heidelberg.
- [Gilani] Gilani, A., Qasim, S. R., Malik, I., & Shafait, F. (2017, November). Table detection using deep learning. In 2017 14th IAPR International Conference on Document Analysis and Recognition (ICDAR) (Vol. 1, pp. 771-776). IEEE.
- [GloBay] A Global Bayesian Optimization Algorithm and Its Application to Integrated System Design (<https://ieeexplore.ieee.org/abstract/document/8253829>)
- [Graeber] F. Graeber; Sechs KI-Trends in 2019; *Elektronik 04-2019 (GMM)*; Seiten 25 – 26
- [Graves] Graves, Alex & Wayne, Greg & Reynolds, Malcolm & Harley, Tim & Danihelka, Ivo & Grabska-Barwińska, Agnieszka & Gómez, Sergio & Grefenstette, Edward & Ramalho, Tiago & Agapiou, John & Badia, Adrià & Hermann, Karl & Zwols, Yori & Ostrovski, Georg & Cain, Adam & King, Helen & Summerfield, Christopher & Blunsom, Phil & Kavukcuoglu, Koray & Hassabis, Demis. (2016). Hybrid computing using a neural network with dynamic external memory. *Nature*. 538. 10.1038/nature20101.
- [Gupta] Gupta, A., Tiwari, D., Khurana, T., & Das, S. (2019). Table detection and metadata extraction in document images. In *Smart Innovations in Communication and Computational Sciences* (pp. 361-372). Springer, Singapore.
- [ISO26262] ISO 26262: „Road vehicles – functional safety“, 2018-12

- [ITAS] BMBF-Förderprojekt „Integrationstechnologien für autonome Sensorsysteme“, <https://www.binder-elektronik.de/referenzen#itas-integrationstechnologien-fuer-autonome-sensorsysteme>
- [Jahan] Jahan Mac A. und Ragel R. G. (2014) Locating Tables in Scanned Documents for Reconstructing and Republishing (ICIAFS14).
- [JITX] Startup JITX Uses AI to Automate Complex Circuit Board Design, <https://spectrum.ieee.org/tech-talk/computing/hardware/startup-jitx-uses-ai-to-automate-complex-circuit-board-design> (Artikel vom 31.07.18)
- [KabYed] M. R. Kabir, B. B. Yedla Ravi, and S. Ray, “A virtual prototyping platform for exploration of vehicular electronics,” IEEE Internet of Things Journal, vol. 10, no. 18, pp. 16 144–16 155, 2023.
- [Kavasidis] Kavasidis, I., Pino, C., Palazzo, S., Rundo, F., Giordano, D., Messina, P., & Spampinato, C. (2019, September). A saliency-based convolutional neural network for table and chart detection in digitized documents. In International Conference on Image Analysis and Processing (pp. 292-302). Springer, Cham.
- [Klcdn] AI / Machine Learning Solutions; https://www.cadence.com/ko_KR/home/solutions/machine-learning.html
- [Klment] Deliver “smarter” faster: Mentor introduces new AI/ML toolkit, adds AI/ML power to Calibre tools to speed smarter IC innovation; <https://www.mentor.com/company/news/siemens-mentor-introduces-new-ai-ml-toolkit-adds-ai-ml-power-to-calibre-tools-to-speed-smarter-ic-innovation>
- [Klsyn] Artificial Intelligence Solutions, Unlock the Transformative Power of AI; <https://www.synopsys.com/ai.html>
- [KI-MUSIK40] BMBF-Förderprojekt „Mikroelektronik-basierte universelle Sensor-Schnittstelle mit Künstlicher Intelligenz für Industrie 4.0“, <https://www.elektronikforschung.de/projekte/ki-musik4.0>
- [Krizhevsky] Krizhevsky, Sutskever, Hinton; ImageNet Classification with Deep Convolutional Neural Networks; 2012; Advances in Neural Information Processing Systems 25
- [Kuru] Kuru O., Can O. A., und Yuret D. (2016) Charner: Character-level named entity recognition. In Proceedings of COLING 2016, the 26th International Conference on Computational Linguistics: Technical Papers, pp. 911–921.
- [Lample] Lample G. , Ballesteros M., Subramanian S., Kawakami K. und Dyer C. (2016) Neural architectures for named entity recognition. arXiv preprint arXiv:1603.01360.
- [LiHanLi] Li J., Sun A., Han J. und Li C. (2020) A Survey on Deep Learning for Named Entity Recognition. In Proceedings of the Seventh Joint Conference on Lexical and Computational Semantics, pp. 167-172.
- [Liu] Liu, Y. (2009). Tableseer: automatic table extraction, search, and understanding.

- [LuSun] T. Lu, J. Sun, K. Wu and Z. Yang; High-Speed Channel Modeling With Machine Learning Methods for Signal Integrity Analysis; IEEE Transactions on Electromagnetic Compatibility, vol. 60, no. 6, pp. 1957 - 1964, Dec. 2018.
- [Mandal] Mandal, S., Chowdhury, S. P., Das, A. K., & Chanda, B. (2004). A Very Efficient Table Detection System from Document Images. In ICVGIP (pp. 411-416).
- [Masudul] Masudul H. Quraishi, Hessem S. Sarjoughian, and Soroosh Gholami. 2018. Co-simulation of hardware RTL and software system using FMI. In Proceedings of the 2018 Winter Simulation Conference (WSC '18). IEEE Press, 572–583.
- [Mikolov] Tomas Mikolov, Kai Chen, Greg Corrado, Jeffrey Dean: Efficient Estimation of Word Representations in Vector Space. <https://arxiv.org/abs/1301.3781>
- [Milošević] Milošević, N. (2018). A multi-layered approach to information extraction from tables in biomedical documents.
- [Minsky] M. Minsky, Neural Nets and the Brain Model Problem, Ph.D. dissertation in Mathematics, Princeton, 1954; siehe auch: M. Minsky, Seymour Papert: Perceptrons. An Introduction to Computational Geometry. MIT Press, Cambridge MA u. a. 1969
- [MueBel] D.Mueller, M.Beltle, S.Tenbohlen: Automated Filter Optimization for High-Voltage Cable Harness Based on Circuit Simulations for Conducted Emissions Prediction, EMC Europe 2018, Amsterdam 2018
- [NgLimKoo] Ng, H. T., Lim, C. Y., & Koo, J. L. T. (1999, June). Learning to recognize tables in free text. In Proceedings of the 37th annual meeting of the Association for Computational Linguistics on Computational Linguistics (pp. 443-450). Association for Computational Linguistics.
- [OWL2] <https://www.w3.org/TR/owl2-overview/>
- [Pomerleau] Dean A. Pomerleau. 1988. ALVINN: an autonomous land vehicle in a neural network. In Proceedings of the 1st International Conference on Neural Information Processing Systems (NIPS'88). MIT Press, Cambridge
- [PythonML] Pros and Cons of Python in Machine Learning, <https://www.zarantech.com/blog/pros-and-cons-of-python-in-machine-learning/>
- [Qiao] Qiao, Kai; Zeng, Lei; Chen, Jian; Hai, Jinjin; Yan, Bin; Wire segmentation for printed circuit board using deep convolutional neural network and graph cut model; IET Image Processing, 2018, 12, (5), p. 793 – 800
- [RamaSingh] Ramasubramanian K., Singh A.; Deep Learning Using Keras and TensorFlow; Machine Learning Using R. Apress, Berkeley, CA, 2019
- [RDF] <https://www.w3.org/TR/rdf-schema/>
- [RDF11] <https://www.w3.org/TR/rdf11-concepts/>
- [Redmon] Redmon, J., & Farhadi, A. (2018). Yolov3: An incremental improvement. arXiv preprint arXiv:1804.02767

- [Sarawagi] Sunita Sarawagi: Information Extraction. In: Foundations and Trends in Databases. Volume1, Issue 3, 2008 <https://doi.org/10.1561/1900000003>
- [Schreiber] Schreiber, S., Agne, S., Wolf, I., Dengel, A., & Ahmed, S. (2017, November). Deepdesrt: Deep learning for detection and structure recognition of tables in document images. In 2017 14th IAPR International Conference on Document Analysis and Recognition (ICDAR) (Vol. 1, pp. 1162-1167). IEEE.
- [SciKit] scikit-learn, Machine Learning in Python;<https://scikit-learn.org/stable/>
- [Silva] e Silva, A. C., Jorge, A., & Torgo, L. (2003, December). Automatic selection of table areas in documents for information extraction. In Portuguese Conference on Artificial Intelligence (pp. 460-465). Springer, Berlin, Heidelberg.
- [SKOS] <https://www.w3.org/TR/skos-primer/>
- [SSP] <https://ssp-standard.org/>
- [Statista] Statistisches Bundesamt. (May 28, 2019). Industry revenue of “manufacture of electronic components and boards“ in Germany from 2011 to 2023 (in billion U.S. Dollars) [Graph]. In Statista. Retrieved May 07, 2020, from <https://www.statista.com/login.bibproxy.whu.edu/forecasts/883959/manufacture-of-electronic-components-and-boards-revenue-in-germany>
- [SurTay] Transfer Learning for Reinforcement Learning Domains: A Survey, Tayler et al., 2009, Journal of Machine Learning Research 10 1633-1685
- [Teich] Irene Teich: Meilensteine der Entwicklung künstlicher Intelligenz. Informatik Spektrum 43, Seiten 276-284, 2020
- [Tengli] Tengli, A., Yang, Y., & Ma, N. L. (2004, August). Learning table extraction from examples. In Proceedings of the 20th international conference on Computational Linguistics (p. 987). Association for Computational Linguistics.
- [Torabi] Faraz Torabi and Garrett Warnell and Peter Stone, Behavioral Cloning from Observation, 2018
- [TrainingModel] A Data-Efficient Training Model for Signal Integrity Analysis based on Transfer Learning (<https://ieeexplore.ieee.org/document/8953103>)
- [TransLearn] Journal of Machine Learning Research 10 (2009) 1633-1685 Submitted 6/08; Revised 5/09; Published 7/09, Transfer Learning for Reinforcement Learning Domains: A Survey;
- [TUDO1] Marian Patrik Felder, Michael Kiffmeier, Jürgen Götze, Stephan Frei, Daniel Renner, Fusion of measurements by existing nodes in an on-board power supply system for condition monitoring with focus on the battery, In Beiträge der 8. GMM-Fachtagung, VDE VERLAG GMBH, vol. 8, pp. 75-80, 2017.
- [TUDO2] P. Jansen, T. Gebel, D. Renner, D. Vergossen, W. John, J. Götze, An approach to determine the state of charge of a lithium iron phosphate cell using classification methods based on frequency domain data, In 8th IET International Conference on Power Electronics, Machines and Drives (PEMD 2016), Glasgow, 2016.

- [TUDO3] M. P. Felder, J. Götze, State of Charge-Klassifizierung für Lithium-Ionen-Batterien anhand von impedanzbasierten Merkmalen, In *Advances in Radio Science*, Copernicus Publications, vol. 14, Miltenberg, Germany, pp. 1-5, 2016.
- [TUDO4] Jansen, M. Vollnhals, D. Renner, D. Vergossen, W. John, J. Götze, Advanced binary search pattern for impedance spectra classification for determining the state of charge of a lithium iron phosphate cell using a support vector machine, In *Advances in Radio Science*, vol. VI, no. 14, pp. 55-62, 2016.
- [TUDO5] P. Jansen, D. Vergossen, D. Renner, W. John, J. Götze, Impedance spectra classification for determining the state of charge on a lithium iron phosphate cell using a support vector machine, In *Advances in Radio Science*, Copernicus Publications, vol. 13, Miltenberg, Deutschland, pp. 127-132, 2015.
- [TUDO6] P. Jansen, D. Vergossen, D. Renner, W. John, J. Götze, Bestimmung des Ladezustands von Batterien mittels zustandsraumbasierter Verfahren mit online-Parameterschätzung, In *Elektrik/Elektronik in Hybrid- und Elektrofahrzeugen und elektrisches Energiemanagement*, expertverlag, vol. VI, no. 138, Bad Boll, Deutschland, pp. 361-376, 2015.
- [TUDO7] T. Nick, Signalverarbeitungsmethoden zur Lokalisierung passiver UHF RFID Label in der Logistikbranche, In *6. Dresdner RFID-Symposium*, Dresden, Germany, 2012.
- [TUDO8] T. Nick, J. Götze, Multi-Hypothesis Kalman Filter for RFID-Based Localization and Tracking, In *URSI Kleinheubacher Tagung 2012*, Miltenberg, Germany, 2012.
- [TUDO9] M. Lechtenberg, J. Götze, K. Görner, C. Rehtanz, Parameter Estimation under Non-Stationary Circumstances using extended Signal Model, In *Kleinheubacher Tagung (KH 2013)/Advances in Radio Science 2014*, Miltenberg, Germany, 2013.
- [UNECE10] Regelung Nr. 10 der Wirtschaftskommission der Vereinten Nationen für Europa (UN/ECE) — Einheitliche Bedingungen für die Genehmigung der Fahrzeuge hinsichtlich der elektromagnetischen Verträglichkeit, Rev. 6, Europäische Union, 20.12.2018
- [VRue] Von Rueden, Laura, et. al., „Informed Pre-Training on Prior Knowledge“, arXiv preprint arXiv:2205.11433, 2022
- [Weiss] Weiss, D. (2019, Dezember). Die Europäische EMS Industrie, eine detaillierte Analyse. Weiss Engineering. Retrieved from: <https://www.in4ma.de>
- [WIKImem] https://de.wikipedia.org/wiki/Long_short-term_memory
- [Yadav] Yadav V., Sharp R., und Bethard S. (2018) Deep affix features improve neural named entity recognizers. In *Proceedings of the Seventh Joint Conference on Lexical and Computational Semantics*, pp. 167–172.
- [Zhang] L. Zhang et al.; Convolutional neural network-based multi-label classification of PCB defects; *The Journal of Engineering*, vol. 2018, no. 16, pp. 1612 - 1616, 11 2018.

- [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 Intelligence, 2008
- [ZVEI2019] ZVEI, (2019, Juli 11). Die globale Elektroindustrie – Daten, Zahlen und Fakten. Retrieved from: <https://www.zvei.org/presse-medien/publikationen/die-globale-elektroindustrie-daten-zahlen-und-fakten/>
- [ZVEI2020] ZVEI, (2020, April 21). The German Electric Industry – Facts & Figures. Retrieved from: <https://www.zvei.org/en/press-media/publications/the-german-electric-industry-facts-figures/>

