



Finanziert von der  
Europäischen Union  
NextGenerationEU

Gefördert durch:



Bundesministerium  
für Wirtschaft  
und Klimaschutz

aufgrund eines Beschlusses  
des Deutschen Bundestages

BMWK-Verbundprojekt: progressivKI  
Förderkennzeichen: 19A21006Q  
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: Erforschung und Implementierung  
von KI-Bildverarbeitungsalgorithmen.**

Version: 0.18  
Erstelldatum: 16.12.2024

Autoren: Prof. Dr. Harald Mathis, Indranil Ghosh

Zuwendungsempfänger: Hochschule Hamm-Lippstadt (Fkz: 19A21006Q)

Ansprechpartner: Hochschule Hamm-Lippstadt  
Prof. Harald Mathis  
59063 Hamm  
[harald.mathis@hshl.de](mailto:harald.mathis@hshl.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

<b>1 Zusammenfassung</b>	<b>4</b>
<b>2 Ziele</b>	<b>5</b>
<b>2.1 Problemstellung und allgemeine Ziele des Vorhabens</b>	<b>5</b>
<b>2.2 Wissenschaftliche und/oder technische Ziele des Vorhabens</b>	<b>7</b>
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	14
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	23
<b>2.3 Ausgangssituation und Voraussetzungen, unter denen das Vorhaben durchgeführt wurde</b>	<b>26</b>
2.3.1 Der Stand von Wissenschaft und Technik	26
2.3.2 Bisherige Arbeiten des Antragstellers	39
<b>2.4 Abgrenzung und Zusammenarbeit mit anderen Projekten</b>	<b>40</b>
<b>3 Technische Ergebnisse</b>	<b>42</b>
<b>3.1 Arbeitspaket 1: edaKI-Anforderungen/Spezifikation modular strukturierte KI-Plattform</b>	<b>43</b>
3.1.1 Teilaufgabe 1.1: Funktionale Sicherheit + Entwurfsabläufe (Wertschöpfungsketten) + Schnittstellen	45
3.1.2 Teilaufgabe 1.2: Spezifikation KI-gestützter Entwurf	45
3.1.3 Teilaufgabe 1.3: KI-Module/KI-Algorithmen/Analyse Synergien	47
3.1.4 Teilaufgabe 1.4: KI-Module für KI-Plattformen der Anwendungsebenen #1 - #2 + Struktur der KI-Plattformen	52
<b>3.2 Arbeitspaket 2: KI-Datenaufbereitung/-generierung</b>	<b>54</b>
3.2.1 Teilaufgabe 2.1: Definition und Planung von Schnittstellenmodellen	57
3.2.2 Teilaufgabe 2.2: Test-/Lerndatenerzeugung	60
3.2.3 Teilaufgabe 2.3: Modellbildung + Klassifikation + Signalauswertung	61
3.2.4 Teilaufgabe 2.4: Entwicklung und Validierung eines Meta-Algorithmus	64
3.2.5 Teilaufgabe 2.5: Datenbasierte Trainings-/Lernmodule	75
<b>3.3 Arbeitspaket 3: Verzahnte Entwicklung von Automobilkomponenten</b>	<b>78</b>

3.3.1	Teilaufgabe 3.1: Framework KI-Module für AW-Ebenen #1 und #2 + Optimierung KI-Module	80
3.3.2	Teilaufgabe 3.2: Implementation Modul-Schnittstellen (Datenaustausch)	82
3.3.3	Teilaufgabe 3.3: Implementation spezifischer und vor-trainierter KI-Module für die Anwendungsebenen #1 und #2	85
3.3.4	Teilaufgabe 3.4: Implementation Domänenwissen	88
3.3.5	Teilaufgabe 3.5: Implementierung Meta-Algorithmen	90
3.3.6	Teilaufgabe 3.6: Validierung KI-Module/KI-Framework für Plattformen Anwendungsebenen #1 und #2	94
<b>3.4</b>	<b>Arbeitspaket 4: Erstellung Teilplattformen (#1: PCB-Entwurf; #2: IC-Anwendung/Sensorik)</b>	<b>96</b>
3.4.1	Teilaufgabe 4.1: KI-Plattform Anwendungsebene #1 PCB-Entwurf	99
3.4.2	Teilaufgabe 4.2: KI-Plattform Anwendungsebene #2 IC-Entwurf/Sensorik	106
<b>3.5</b>	<b>Arbeitspaket 5: Projektmanagement &amp; Dissemination</b>	<b>107</b>
3.5.1	Teilaufgabe 5.1: Projektleitung/ProjektOffice + progressivKI Advisory Board	109
3.5.2	Teilaufgabe 5.2: F+E-Ergebnisverbreitung + F+E-Nutzungspotentiale	109
3.5.3	Teilaufgabe 5.3: Dokumentation Gesamtprojekt	110
<b>4</b>	<b>Verwertung und voraussichtlicher Nutzen</b>	<b>110</b>
<b>5</b>	<b>Veröffentlichungen</b>	<b>112</b>
<b>6</b>	<b>Quellen</b>	<b>119</b>

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

Bekanntlich ist die Definition des Begriffes „künstliche Intelligenz“ schwierig – schon allein, da unklar ist, wie der zugrunde liegende Begriff „Intelligenz“ zu fassen ist und welche kognitiven Leistungen diesem zuzuordnen sind. In dieser Gesamtvorhabenbeschreibung soll der Begriff „künstliche Intelligenz“ daher nicht in seiner umgangssprachlichen Bedeutung als Oberbegriff für computerbasierte Methoden, die Aspekte der menschlichen Intelligenz, insbesondere dessen Lernvermögen aus Erfahrungen, auf unterschiedliche Arten nachbilden, verwendet werden, sondern lediglich zur Abgrenzung einer Forschungsdisziplin gegenüber anderen wissenschaftlichen Bereichen (siehe bitte die folgende Tabelle 1). Dies vermeidet die Diskussion, was „Intelligenz“ eigentlich ist, die sich zwangsläufig ergeben würde, wenn dem Begriff der "künstlichen Intelligenz“ auch eine interpretierende Bedeutung gegeben werden würde. Die Interpretation des Begriffs „künstliche Intelligenz“ hat beispielsweise in der Vergangenheit dazu geführt, dass die Definition von KI vom jeweils erzielten Fortschritt abhängig wurde, da allgemein die Neigung besteht, die bereits verstandenen („entzauberten“) Aspekte von Lernprozessen aus der Definition herauszunehmen. Genau dieses Phänomen ("AI effect") wird in dem bekannten Aphorismus "Artificial intelligence is whatever hasn't been done yet" von Larry Tesler thematisiert.

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

Künstliche Intelligenz (KI/AI)	Wird als Bezeichnung der wissenschaftlichen Disziplin verwendet, die sich mit dem Studium von Agenten beschäftigt, die ihre Umgebung wahrnehmen, auf diese reagieren und Maßnahmen ergreifen, um die Wahrscheinlichkeit, ihre Ziele zu erreichen, zu maximieren (Poole, David; Mackworth, Alan; Goebel, Randy (1998). <i>Computational Intelligence: A Logical Approach</i> . 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 Huskarl<sup>1</sup>-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

---

<sup>1</sup> 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.

trainierbare Plattform darstellt, auf der Bildverarbeitungsmethoden durch IT-Laien innerhalb kürzester Zeit auf einem GUI mit der Maus generiert und zur Anwendung gebracht werden können.

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

ML-Segment
<p><b>Zeta</b> - Zeta ist eine von Fraunhofer FIT selbst entwickelte digitale Bildverarbeitungs-Suite in deren Entwicklung mehrere Personen-Jahre eingeflossen sind. Sie unterstützt zahlreiche Funktionen und Algorithmen zur Registrierung, Vorder-/Hintergrunderkennung, Segmentierung, Tracking, Klassifikation etc. Da ein Hauptteil der Problematik auf Bildverarbeitung (Leiterbahnen, Schematics) zurückzuführen sein wird, kann die Zeta Suite dort eine große Hilfe bieten.</p>
<p><b>Support Vector Machines</b> - Support Vector Machines werden auf eine Menge von Trainingsdaten bezogen, deren Klassifizierung bekannt ist. Jeder Datenpunkt wird entsprechend durch einen Vektor im n-Dimensionalen Raum betrachtet. In diesen Raum wird eine Hyperebene gesetzt, die die jeweiligen Klassen der Datenpunkte mit maximalem Abstand trennt. Daten, deren räumlicher Abstand zur Trennebene gering ist, werden dabei mehr berücksichtigt als Datenpunkte, deren Abstand zur Trennebene groß ist.</p>
<p><b>Decision Trees</b> - Decision Trees, oder auch Entscheidungsbäume sind geordnete, gerichtete Bäume, die der Erstellung und Darstellung von Entscheidungsregeln dienen. Besondere Bedeutung kommt Entscheidungsbäumen in Bereichen zu, in denen aus tacit knowledge/Erfahrungswissen formale Regeln abgeleitet werden können.</p> <p>Sie können entweder durch Experten manuell erstellt oder durch verschiedene Algorithmen des ML induziert werden. Dabei kann das tacit-Knowledge der Experten mit in den Induktionsprozess einfließen. Genau für diese Anwendung wurden die trainierbaren Prozesse erfunden. Ein Spezialfall der trainierbaren Prozesse ist das "supervised learning".</p>
<p><b>Random Forest</b> - Ein Random Forrest besteht aus mehreren unkorrelierten Entscheidungsbäumen, die unter einer bestimmten Art der Randomisierung in einem Lernprozess induziert wurden. Eine Klassifikationsentscheidung wird durch einen einfachen Mehrheitsentscheid über alle Bäume getroffen.</p> <p>Vorteile:</p> <ul style="list-style-type: none"><li>Evaluierung basiert auf mehreren Bäumen - ist also parallelisierbar.</li><li>Effizient für große Datenmengen.</li><li>Sehr schnelles Training möglich.</li><li>Zusammenhang zwischen Klassen/Entscheidungen kann unmittelbar hergestellt werden.</li></ul>

DL-Segment
<p><b>Tensorflow</b> - Entwickelt von Google bietet Tensorflow Schnittstellen zu allen populären Programmiersprachen. Am häufigsten verwendet wird es allerdings mit Python.</p>



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

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

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

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

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

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

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

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

Dabei werden die im ML-Segment erhaltenen Parameter und Features<sup>3</sup> für den DeepLearning-Prozess nach Möglichkeit eingesetzt.

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

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

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

- Python ist eine dynamische High-Level Programmiersprache, die schon knapp drei Jahrzehnte am Markt etabliert ist.
- Komplett Open Source
- Eine große Sammlung an built-in Bibliotheken die Funktionen für Maschinelles Lernen bereitstellen
- 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

---

<sup>3</sup> 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

notwendig sind. Mit Hilfe der KI-Module muss auch wertschöpfungsketten-übergreifend ein *netzbasierter* und *workflow-orientierter Ergebnistransfer* der in der Kette erarbeiteten Ergebnisse (Wissen, Methoden) realisiert werden.

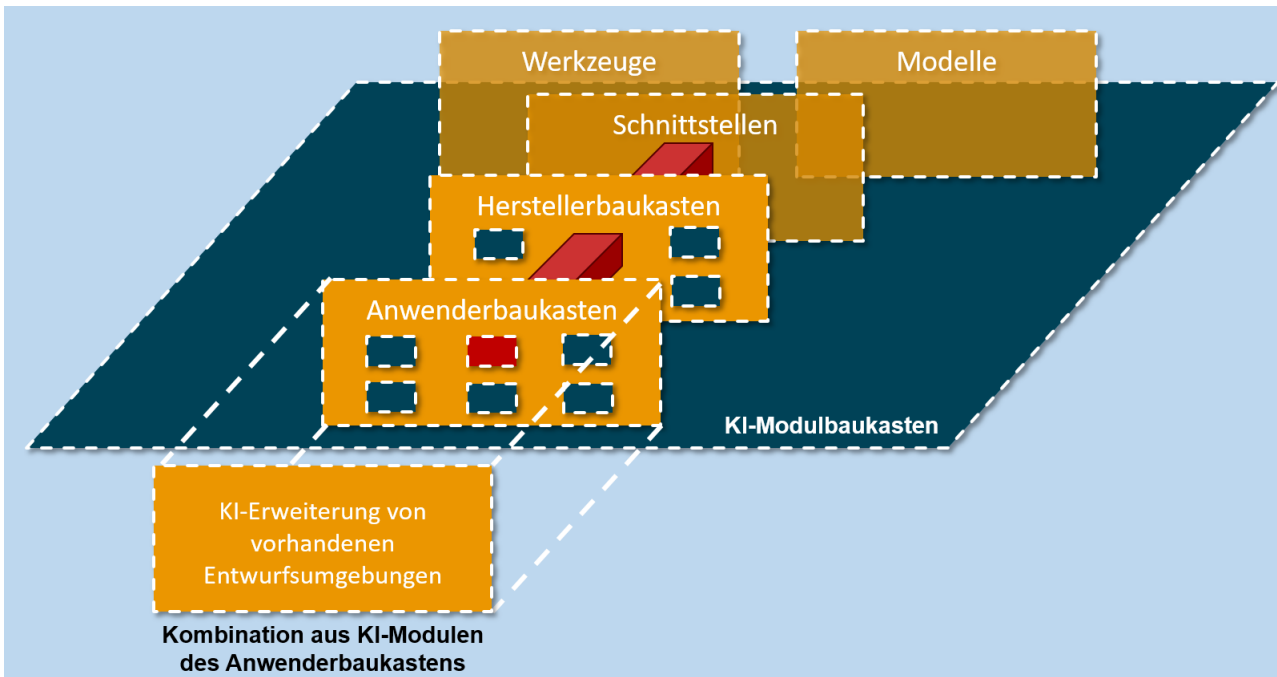


Abbildung 2: Prinzipieller Aufbau eines KI-Modulbaukastens

## 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 3) in den Entwurfsprozess vermehrt eingehen müssen. Diese sogenannten Nebeneigenschaften gewinnen immer mehr Einfluss auf die funktionale Sicherheit eines Systems und entwickeln sich vermehrt zum Kostentreiber.

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

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

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

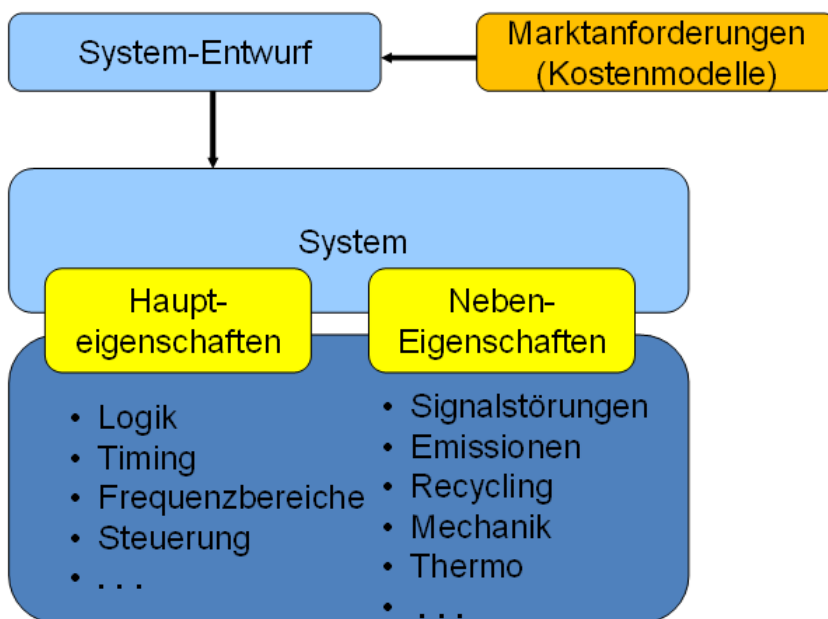


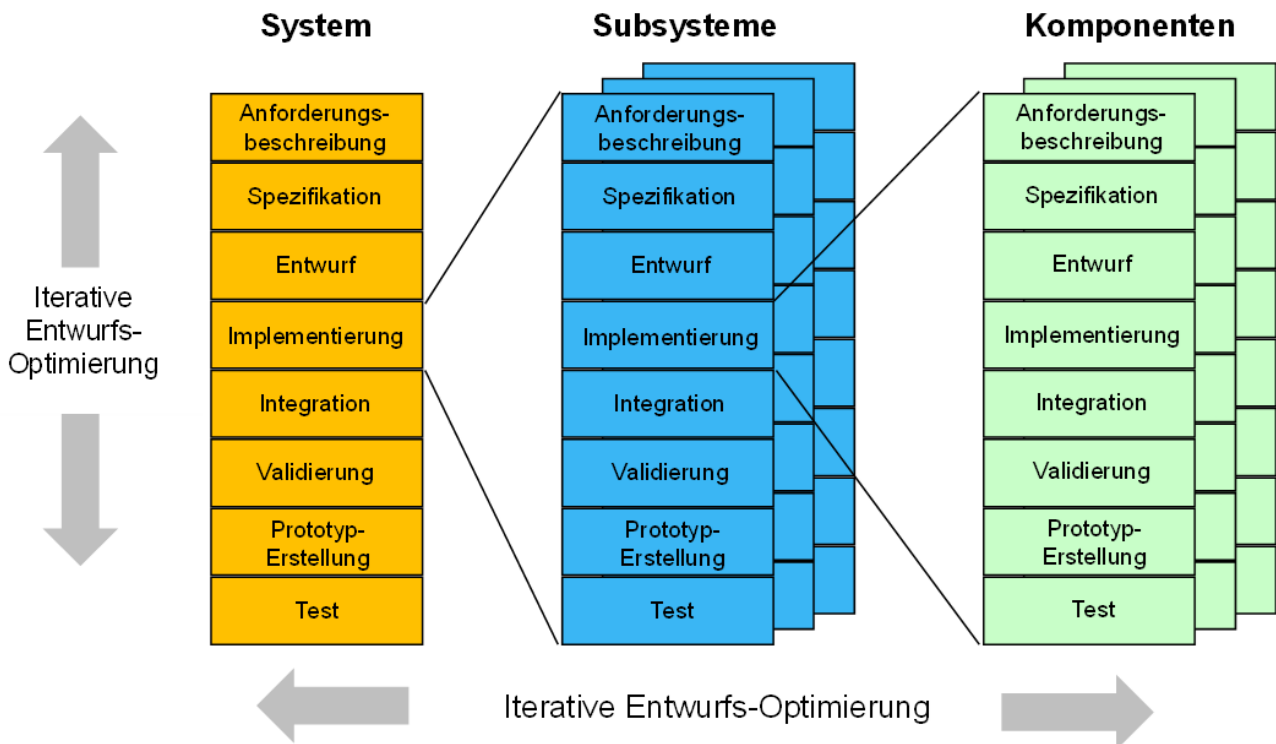
Abbildung 3: Gliederung eines mikroelektronischen Systems in Haupt- und Nebeneigenschaften

### 2.2.5.1 Allgemeiner Entwurfsprozess

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

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

Abbildung 20 zeigt ein weiterentwickeltes Prozessmodell für den Entwurf elektronischer Systeme. Die jeweiligen Phasen dienen der Strukturierung der zu beschreibenden Entwicklungsprozesse und müssen evtl. auch zeitlich überlappend abgearbeitet werden. Beginnend mit der |Anforderungsbeschreibung| werden die darauffolgenden Phasen bis zum |Test| auf der Systemebene durchlaufen. Die Definition der angedeuteten Systemhierarchie ergibt sich zwangsläufig aus der geforderten Funktionalität. Entsprechende Abläufe müssen deshalb auch für die Ebenen Subsysteme und Komponenten betrachtet werden. Es wird auch deutlich, dass eine Optimierung des Zielsystems auf den unterschiedlichen Entwurfsebenen üblicherweise nach dem sog. JoJo-Prinzip erfolgt. Allerdings muss zusätzlich eine Optimierung der Subsysteme und Komponenten auf horizontalen Ebenen erfolgen. Bei allen Schritten zur Entwurfsoptimierung fallen erhebliche Datenmengen unterschiedlicher Natur an (z.B. Spezifikationsdokumente; Simulationsergebnisse; Messergebnisse; Berichte aus dem Feld; ...). Da die allermeisten Entwürfe in sog. Wertschöpfungsketten (z.B. Systemhaus - Tier1 - Tier2) erfolgen, wird deutlich, dass eine zukünftige KI-Unterstützung wertschöpfungsketten-übergreifend erfolgen muss.



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

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

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

### 2.2.5.2 Funktionale Sicherheit

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

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



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  $\acute{o}$  abhängig von der Granularität der Modell-Hierarchie).

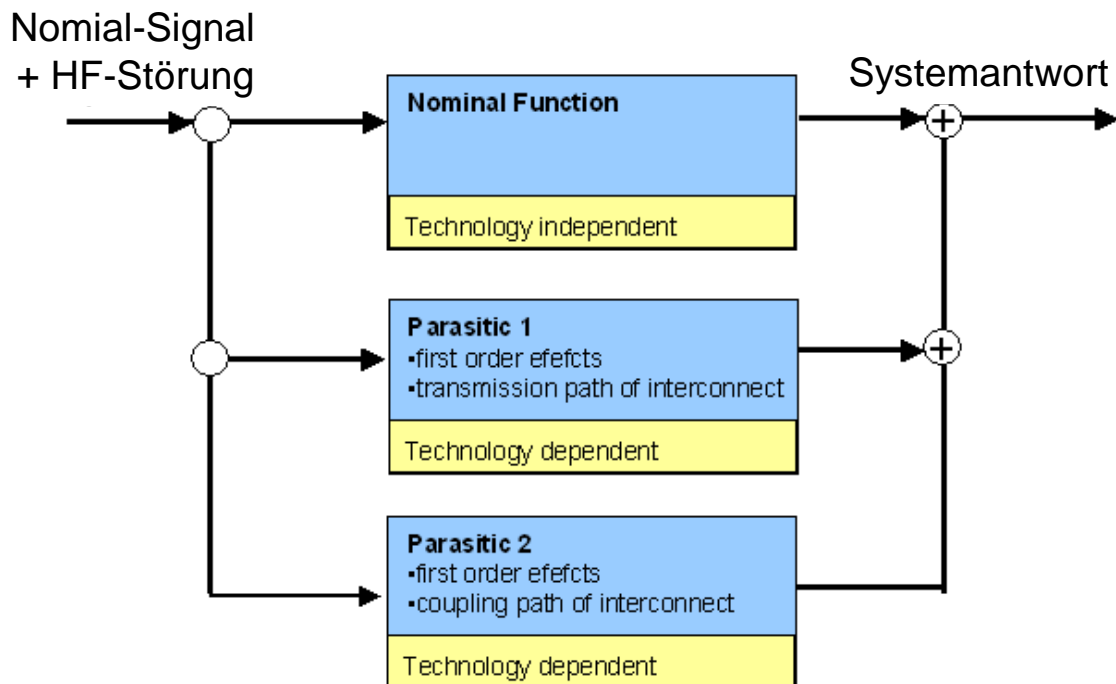


Abbildung 6: Ansatz zur Einführung von Modellhierarchien für eine Fehleranalyse durch Simulation

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

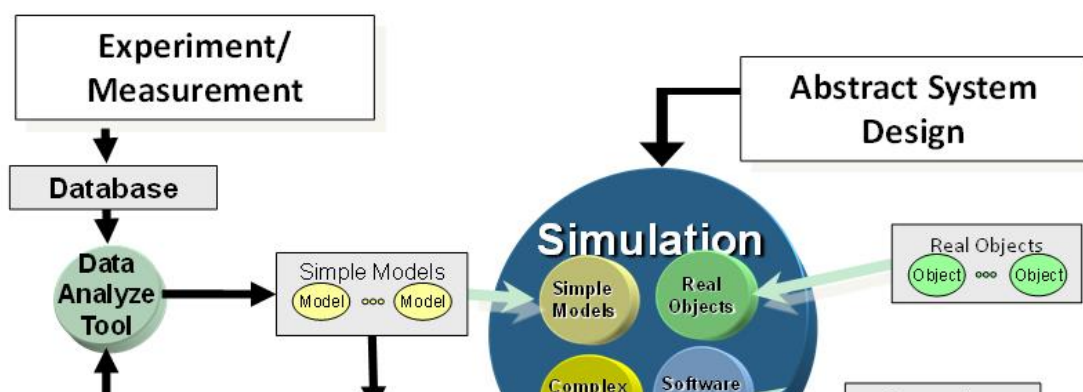
Für die Anwendungsebene #1 (PCB-Entwurf) bedingt diese Art der Vorgehensweise zum Beispiel unmittelbar die Einführung eines geeigneten Fehlermodells (z.B. frequenz-/zeitabhängige Strom- und/oder Spannungsquellen) und einer Empfindlichkeitsmatrix für die elementaren Schaltungsblöcke eines Bauelementes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

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

**Cost Saving: Virtual Prototypes - Error Prevention**



**Time Saving: Concurrent Design – Reduced Number/Shorter Cycles**



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

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

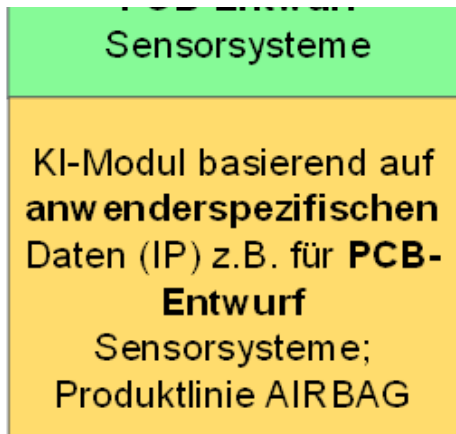
Durch den frühen Einsatz von Simulationsverfahren und -prinzipien lassen sich die notwendigen Iterationsschritte in der Entwicklung deutlich reduzieren (Abbildung 23). Zukünftig ist besonders wichtig, dass hinsichtlich einer effizienten Entwurfsunterstützung die erforderlichen Konnektoren zu KI-Modulen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

#### **2.2.6 IP-Schutz und Interoperabilität**

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

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

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



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

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

## 2.2.7 Darstellung der wesentlichen Projektinnovationen

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

#	Vorwettbewerbliches Innovationselement	edaKI-Einsatzgebiet
IE.1	KI-Einsatz zur 20%igen Reduktion der zukünftig aufzuwendenden Ressourcen (Zeit, Personal, Kosten) für den Entwurf funktional-sicherer elektronischer KFZ-Systeme.	Entwurfsprozess; Objekt 1 bis Objekt 8; siehe auch Abbildung 10.
IE.2	Entwicklung einer neuartigen, modular aufgebauten sowie flexibel einsetzbaren KI-Plattform zur direkten Abdeckung der System-Entwurfsebenen  PCB-Entwurf  und  IC-Entwurf/Intelligente Sensorik .	Entwurfsprozess; Objekt 1 bis Objekt 8; siehe auch Abbildung 10.

IE.3	Entwicklung von sicheren, verschlüsselten und intelligenten Konnektoren zu den einzelnen (verteilten) Modulen und Subsystemen der modularen KI-Plattform.	IP-Schutz/Interoperabilität/KI-Interaktionsmodelle; siehe Abbildung 11; Abbildung 24.
IE.4	Portabilität und Übertragbarkeit der technischen Lösungen auf die individuellen Entwurfsprozesse durch Anordnung domänen- und applikationsspezifischer Konnektoren um einen leistungsfähigen KI-Kern.	KI-Module aus den 3 Segmenten Machine Learning (ML) – Deep Learning (DL) – Selbstlernende Prozesse (SP); siehe Abbildung 17.
IE.5	Erforschung neuartiger Konzepte für den kooperativen Betrieb von KI-Systemen in industriellen Entwurfsabläufen.	<ul style="list-style-type: none"> <li>❑ Anwendungsebene #1: PCB-Entwurf; siehe Abbildung 11 + Abbildung 12.</li> <li>❑ Anwendungsebene #2: IC-Entwurf/Sensorik; siehe Abbildung 15.</li> <li>❑ Neuartige KI-basierte Unterstützung des Prinzips der Variantenkonstruktion.</li> </ul>
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 <b>1</b> ; Objekt <b>2</b> Entwurfsebene Anforderungen/Spezifikation; Auswertung Datenblätter (Textverarbeitung); siehe auch Abbildung 10: Typischer SchematicAufbau; siehe auch Abbildung 5:

IE.11	Entwicklung einer standardisierten Topologiebeschreibung, einer standardisierten Geometriebeschreibung und eines standardisiertes Datenbankformat für die Spezifikation elektronischer/elektrischer aktiver/passiver Bauelemente für den Entwurf elektronischer Systeme zur internen Darstellung für die geplanten KI-Plattformen.	ECU-Schaltbild (Quelle: ZUKEN); Typischer SchematicAufbau; siehe auch Abbildung 5. MOSTCheck AnwenderWorkflow (Quelle: 05-MCHP); siehe auch Abbildung 12.
IE.12	Entwicklung einer vollständigen Darstellung der Systemtopologie durch Netze; direkt in der von TensorFlow genutzten Repräsentation.	ECU-Schaltbild (Quelle: ZUKEN); Typischer SchematicAufbau; siehe auch Abbildung 5. MOSTCheck AnwenderWorkflow (Quelle: 05-MCHP); siehe auch Abbildung 12
IE.13	Alleinstellungsmerkmal durch Quantisierung von Lernerfolgen (Metrisierung) zur Qualitätskontrolle für maschinelles Lernen.	Modular, strukturierte KI-Plattform/Training und Applikation; siehe auch Abbildung 16.
IE.14	Neue Verfahren zur Bewertung und Absicherung der Qualität von Trainings- und Lernprozessen für KI-Module.	Modular, strukturierte KI-Plattform/Training und Applikation; siehe auch Abbildung 16.

**Tabelle 2: progressivKI-Innovationselemente gemäß Schumpeter-Definition\***

\*Zitat aus [E. Borbély; J. A. Schumpeter und die Innovationsforschung; MEB 2008 – 6th International Conference on Management, Enterprise and Benchmarking May 30 - 31, 2008 Budapest, Hungary]: Neue Verfahren zur Bewertung und Absicherung der Qualität von Trainings- und Lernprozessen für KI-Module.: *Schumpeter definiert die Innovation als die Umsetzung neuer Kombinationen in die Realität: |The doing of new things or the doing of things that are already done, in a new way|<sup>1</sup>, wobei er immer an die erstmalige Durchführung einer Neuerung denkt. Innovationen sind also neue und andersartige Kombinationen der zur Verfügung stehenden |Dinge und Kräfte|, wobei Produktion die übliche Kombination vorhandener Dinge und Kräfte ist – die einmal wahrscheinlich auch neuartig waren<sup>2</sup>.*

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“ [Sutton] 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) [Kavasidis], [Silva], Fully Convolutional Networks (FCNs) [Schreiber], oder semantischen Region-based Convolutional Neural Networks (R-CNNs) [Gilani] unter Verwendung von euklidischen Abstands-Merkmalen. Insbesondere im Bereich der Named Entity Recognition (NER) hat es im letzten Jahrzehnt viele neue Lösungsansätze und technische Fortschritte gegeben [Dernoncourt], [Yadav], [Lample]. Bei der Entitäten-Extraktion werden in einem unstrukturiertem Text 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 [Aggeri], [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 Erlernenen 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**

### **20-HSHL**

#### **Unternehmensvorstellung**

2009 wurde mit der Gründung der staatlichen Hochschule Hamm-Lippstadt das Fundament für eine Hochschule neuen Profils gelegt. Mit einem Team praxiserfahrener Professorinnen und Professoren wurde ein innovatives Studien- und Forschungsangebot mit Fokus auf Ingenieurwissenschaften, Naturwissenschaften, Informatik und Wirtschaft entwickelt. Besonderen Wert legt die Hochschule auf interdisziplinäre Ausrichtung, Marktorientierung und hohen Praxisbezug in Lehre und Forschung.

#### **Projektbezogene Kompetenzen und Schwerpunkte**

Mit den Neubauten in Hamm und Lippstadt bietet die Hochschule modernste Gebäude, rund 15.000 Quadratmeter Laborflächen, Hochleistungsrechenzentren und damit ideale Bedingungen für die Ausbildung kreativer Fachkräfte und die Forschung. Ein Forschungsschwerpunkt liegt auf der Entwicklung von Neuronalen Netzen zur Automatisierung medizinischer Diagnosen auf der Grundlage von bildgebenden Verfahren.

#### Relevante Vorgängerprojekte

Im Projekt „ImmunePredict“ werden ML- und DL-Verfahren für die automatische bildbasierte Erkennung genutzt, wie bestimmte Medikamente auf verschiedene Krebszellen einwirken. Im BMBF-geförderten Projekt „Integrative Datensemantik“ beschäftigt sich die HSHL mit dem Datenmanagement, der Auswertung und der Visualisierung von medizinischen und Omics-Daten auf der Grundlage von Deep-Learning Algorithmen. Die gesammelte Erfahrung und Expertise wird in progressivKI eingesetzt. Darüber hinaus hat die HSHL schon in der Wettbewerbsphase von modularKI an der Konzeptionierung der modularen KI-Plattform mitgewirkt.

## 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>



Abbildung 9: Abhängigkeiten und Interaktion der progressivKI-Arbeitspakete

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

**Ausgangslage:** Mit progressivKI wurde ein hochgradig modularer Ansatz verfolgt, der durch KI-basierte Automatisierung die Effektivierung der Entwurfsprozesse einer umfassenden Wertschöpfungskette unterstützt. Die große damit verbundene Wertschöpfung kann dank der modularen Struktur von Nutzern sowohl systemübergreifend umgesetzt werden als auch im Rahmen von spezifischen Einzelaufgaben entlang der betrachteten Wertschöpfungskette. Damit progressivKI die vorgesehene umfassende Anwendbarkeit und das entsprechende TRL erhält, war eine präzise Analyse des Systems der Requirements erforderlich, die entlang der betrachteten Wertschöpfungskette gelten, sowie eine transparente Darstellung aller verwendeten Formate und Schnittstellen. Diese wichtige Aufgabe wurde im AP1 geleistet zusammen mit der Definition der daraus abgeleiteten Anforderungen an progressivKI und die im Projekt zu bedienenden Formate, Protokolle und Schnittstellen. Derzeit sind gestützte Entwurfsprozesse von (Teil-) elektronischen Systemen mit Constraints (wie z.B. Applikations- oder IC bzw. OEM-Hersteller-Vorgaben) in der Regel vom jeweiligen Entwickler durchgeführte manuelle Prozesse mit mehr oder weniger formalisiertem Entwurfsziel, zum Teil mit Analyseunterstützung durch EDA/CAD-Werkzeuge. Diese Prozesse sind zeitaufwendig und oft auch fehlerbehaftet. In diesem Arbeitspaket wurden die Spezifikationen für das Projekt im Hinblick auf Schnittstellen zwischen Entwurfsabläufen und den KI-Modulen erarbeitet. Weiterhin wurden Anforderungen an die Datensammlung sowie an die KI-Module definiert. Darüber hinaus musste analysiert werden, ob Synergien zwischen unterschiedlichen KI-Algorithmen nutzbar gemacht werden können.

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

Dieses Arbeitspaket definierte und lieferte:

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

**Geplante Ergebnisse von AP1 waren:**

- Im Rahmen dieses Arbeitspakets waren mehrere Schlüsselergebnisse vorgesehen. Zunächst erfolgte die Definition und Spezifikation der erforderlichen KI-Algorithmen, wobei der Schwerpunkt auf der funktionalen Sicherheit für die zu automatisierenden Entwurfsabläufe lag. Gleichzeitig wurden die Schnittstellen und Datenformate spezifiziert, um einen sicheren und effizienten Datenaustausch zu gewährleisten.
- Des Weiteren wurden KI-verwertbare Regelwerke erstellt, basierend auf Entwurfs- und Designregeln. Hierbei erfolgte die Spezifikation der Datenaufbereitung und die Festlegung von Anforderungen an die KI-Module aus der Perspektive der Entwurfsprobleme, die sich aus den Use Cases der beiden Anwendungsebenen ergaben.

- Eine umfassende Analyse verschiedener Open-Source KI-Frameworks wurde durchgeführt, wobei der Fokus auf den Eingangsdatenformaten lag. Dabei wurden Synergien zwischen den genutzten Frameworks herausgearbeitet, und die KI-Algorithmen wurden spezifiziert.
- Die Ergebnisse aus den Arbeitsschritten AT1.1 bis AT1.3 sowie AT 2.1 dienten als Grundlage für die Spezifikation der Anwendungsebenen und ihrer Strukturen. Zusätzlich wurden nutzbare Datenquellen der KI-Plattformen analysiert und klassifiziert, um eine umfassende Grundlage für die weiteren Entwicklungsphasen geschaffen zu haben.

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

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

Die folgenden Themen mussten im Detail bearbeitet werden:

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

Keine Arbeiten.

### **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 1.2.20 Aufstellung eines gemeinsamen KI-adäquaten Regelwerks, basierend auf im Vorhaben vorhandenen Entwurfsregeln**

#### **Ziele**

Analyse von Integrations-Strategien für Design-Regeln aus AW#1 - #2. Festlegung der Integrations-Strategie

#### **Problemstellung**

Bereits vorhandenes Domänenwissen sollte formalisiert und nutzbar gemacht werden, sodass dieses in Kombination mit den KI-Ansätzen genutzt werden kann. Dieses Domänenwissen sollte in der maschinenlesbaren Form die Erfahrung der Entwickler festhalten und verarbeitbar machen, z.B. durch Regelwerke.

#### **Lösungsweg und Ergebnisse**

Dieser Teilbeitrag wird auf QI/22 und QII/22 verschoben, da derzeit in den UC#3-5 nicht genügend Entwurfsregeln abgeleitet wurden. Mit dem Fortschreiten der UC werden die Entwurfsregeln erfasst und im Rahmen dieses Teilbeitrages zu einem späteren Zeitpunkt dargestellt.

Zunächst wurde Teilbeitrag auf die Quartale 1 und 2 des Jahres 2022 verschoben, da in den Use-Cases 3-5 noch nicht genügend Entwurfsregeln abgeleitet wurden.

Durch das Voranschreiten in den Use-Cases 3-5 und den involvierten, aus der EDA-Domäne kommenden Partnern wie 01-BOSCH, 04-IFAG, 05-MCHP, 13-EMC oder 18-HSU, wurde sich darauf verständigt, keine starren Regelwerke innerhalb des Projektes zu verwenden. Der Einsatz von KI-Modellen widerspricht dem Ansatz, Regeln in einer starren Form zu integrieren. Daher wurde sich dazu entschieden, Designregeln in Form von Trainingsdaten zu aggregieren. Durch das Bereitstellen von gelabelten Trainingsdaten eines Domänen-Experten fließt das vorhandene Wissen in die KI-Modelle mit ein. Der Experte befindet sich ebenfalls in der Schleife des KI-Workflows, sodass mit den Daten trainierte Modelle evaluiert und ggfs. In einer weiteren Iteration angepasst werden können. Die Design-Regeln können in verschiedenen Formen wie Bilddaten oder Spektralmessungen codiert sein.

Im weiteren Verlauf des Projektes ist mithilfe der Domänen-Experten allerdings in bestimmten Fällen von Use-Case 5 auf explizites Regelwissen zurückgegriffen worden. Während des Pre-Processings der simulierten Daten in diesem Use-Case mussten bestimmte Samples gefiltert und transformiert werden, sodass sie in den Wertebereich der Realdaten "passen". Darüber hinaus ist

das Simulationsdatenset mit diesem Wissen angepasst wurden, um es zu balancieren (bestimmte Klassen waren überrepräsentiert). Diese Regeln aus der Domäne sind in die Erstellung eines Auto-Encoders eingeflossen. Die nachfolgende Abbildung zeigt die Verteilung einiger beispielhaften Klassen, wenn man Simulations- und Realdaten zusammenfasst.

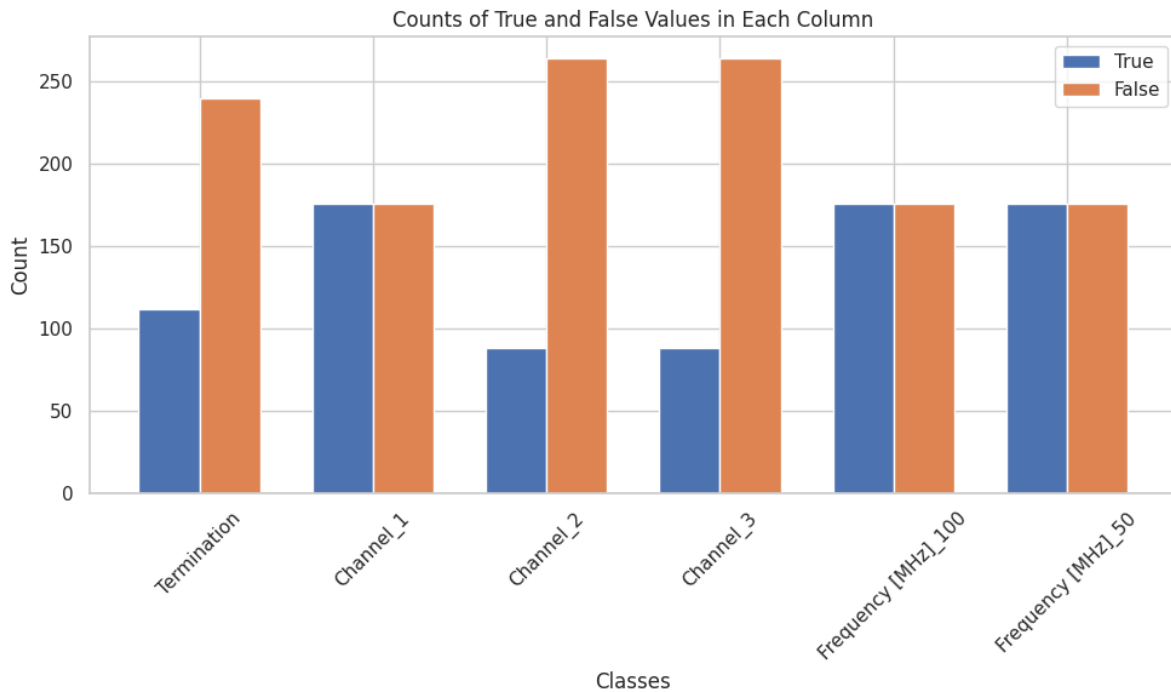


Abbildung 10: Verteilung beispielhaften Klassen

### 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 1.2.20: Test und Analyse von KI-Algorithmen mit Bezug auf Synergien mit prädiktiven Algorithmen (20-HSHL)

### Ziele

Festlegung der Klassen von KI-Algorithmen, welche die optimale Einbindung von Regelwerken erlauben. Ermittlung der Synergien, die sich aus der Verwendung von Regelwerken und selbstlernenden Algorithmen ergeben.

### Problemstellung

In diesem Beitrag sollte untersucht werden, wie sich KI-Algorithmen potenziell mit Regelwerken oder statischen Informationen verbinden lassen. Obwohl – wie in TB 1.2.20 erwähnt - keine umfassenden, starren Regelwerke entwickelt werden konnten, gibt es Stellen im KI-Prozess, an denen explizites, meist händisch kodiertes Wissen eine Optimierung erbringen kann.

### Lösungsweg und Ergebnisse

Um die Pipeline-Schritte bei der Datenverarbeitung und beim Training zu standardisieren und zu harmonisieren, wurde ein erweiterbarer Satz abstrakter Problem-/Datenklassen konzipiert. Diese Klassen bieten einen strukturierten Ansatz für die Datenverarbeitung, indem sie klare Eingabe- und Ausgabeformate definieren und so die Kompatibilität zwischen den verschiedenen Phasen einer Datenpipeline sicherstellen. Die Klassen zielen darauf ab, Datenverarbeitungs- und Trainingsaufgaben in breitere Kategorien zu verallgemeinern, um eine optimierte Implementierung und Skalierbarkeit zu ermöglichen. Nachfolgend finden Sie eine Übersicht über diese Klassen:

Tabelle 3

Klasse	Objektiv	Anwendung	Beispiel
Representation	Transformieren Sie Daten in eine andere Darstellung, indem Sie ihre Dimensionalität ändern	Wird für Aufgaben verwendet, bei denen Daten vereinfacht oder in einem informativeren Raum dargestellt werden müssen.	Principal Component Analysis (PCA), Autoencoders, Locally Linear Embedding (LLE), Matrix Factorization, and other embedding techniques
Clustering	Gruppieren Sie Datenpunkte so, dass Objekte innerhalb des gleichen Clusters höhere	Identifizieren zugrunde liegender Muster oder natürlicher Gruppierungen innerhalb von Daten ohne vordefinierte Bezeichnungen.	K-Means, DBSCAN, Hierarchical Clustering
Classification	Ordnen Sie neue Beobachtungen auf der Grundlage von Trainingsdaten	Wird häufig für überwachte Lernaufgaben verwendet, bei denen	Decision Trees, Neural Networks, U-Net, Edge Detection, Label Propagation.

	vordefinierten Kategorien zu.	das Ziel darin besteht, Datenpunkte zu beschriften oder zu kategorisieren.	
Regression	Prognostizieren Sie kontinuierliche Werte oder zukünftige Datenpunkte auf der Grundlage historischer Daten.	Geeignet für die Prognose und Modellierung von Zeitreihen oder kontinuierlichen Ergebnissen.	Gated Recurrent Units (GRU), Long Short-Term Memory (LSTM), Transformers
Variate Data Processing	Techniken, die die Dimensionalität der Daten ändern, indem sie sie entweder erhöhen oder verringern.	Wird für Vorverarbeitungsschritte verwendet, die Daten transformieren, um die weitere Analyse zu erleichtern.	Rescaling, Resampling, Feature Extraction
Invariate Data Processing	Techniken, die beim Anwenden von Transformationen die ursprüngliche Dimensionalität der Daten beibehalten.	Bereinigen, Verbessern oder Normalisieren von Daten, ohne ihre grundlegende Struktur zu verändern.	Fast Fourier Transform (FFT), Convolutions, Noise Reduction, Normalization, Addition, Subtraction
Generative Modelling	Erstellen Sie Modelle, die neue Datenproben generieren können, die die Verteilung oder Merkmale der Trainingsdaten widerspiegeln.	Zur synthetischen Datengenerierung, Datenerweiterung und kreativen Anwendungen wie der Generierung realistischer Bilder oder Audiodaten.	Generative Adversarial Networks (GANs), Generative Pre-trained Transformers (GPT), Text-to-Speech systems.

Weitere Klassen:

- Entscheidungsfindung: Umfasst Algorithmen und Modelle, die darauf abzielen, fundierte Entscheidungen auf der Grundlage von Datenanalysen zu treffen. Dieser Kurs unterstützt Verstärkungslernen und Optimierungsprobleme.
- Konvertierung: Deckt Schritte ab, die mit dem Ändern von Datenformaten oder dem Konvertieren zwischen verschiedenen Datendarstellungen verbunden sind, um die Kompatibilität über verschiedene Verarbeitungsphasen hinweg sicherzustellen.
- Visualisierung: Umfasst Techniken, die die grafische Darstellung von Daten und Ergebnissen erleichtern und so zu einem besseren Verständnis und einer besseren Interpretation beitragen.

Zunächst wurden innerhalb des Keras-Framework, welches gut definierte Schnittstellen zu 'tensorflow' (oder wahlweise 'theano') exponiert, verschiedene Ansätze im Bereich des "Deep

Learning" getestet, um unter anderem Regressions-Probleme von PCB-Darstellungen auf Frequenzspektren (UC#3) und Klassifizierungs-Probleme von spektralen Feld-Messungen auf spezifische Problemklassen im Bereich der EMV zu lösen (UC#5). Die eigentliche Festlegung der Klassen im Sinne der TB-Definition konnte zu diesem Zeitpunkt nicht getroffen werden, da die weitere Behandlung und Fortentwicklung der UseCases und die Ableitung geeigneter, evaluierter Prozesse erfolgen müssen. Der Prozess der Ableitung von Algorithmen wurde als ein kontinuierlicher Prozess verstanden, der schließlich konvergiert und dann eine wirkliche Festlegung erlaubt. An dieser Stelle wurde festgestellt, dass für die weitere Untersuchung und Fortentwicklung der Use-Cases das Datenaufkommen und –prozessieren erheblich zunehmen musste. Dies wurde mit einem Monitoring der auftretenden Schwierigkeiten und Effekte forciert.

Parallel dazu sind Arbeiten an der generellen Integration von Regeln in die KI-Prozesse in den verschiedenen Use-Cases durchgeführt worden.

KI-Algorithmen und Regelwerke können auf verschiedene Arten kombiniert werden. Ein regelbasiertes System besteht aus einer Menge von Wenn-Dann-Bedingungen; so codiertes Wissen ist in der Regel händisch erfasst und stellt explizit Erfahrung eines Experten dar. Allerdings ist es sehr schwierig zu prüfen, ob die Menge dieser Regeln vollständig ist oder ausreichend viele Fälle abdeckt. Ein einfaches regelbasiertes System könnte so aussehen:

```
cap_1: Capacitor
cap_2: Capacitor
soc_1: SystemOnChip
wire_1: Wire
If not connected(cap_1, cap_2, wire_1) AND onSoc(cap_1, cap_2, soc_1) then:
    error: DesignValidationError("Caps are not connected")
return error
```

**Abbildung 11**

Darüber hinaus kann ein KI-Modell mit einem solchen Regelwerk verknüpft werden. Wie z.B. in Use-Case 6 gezeigt, bestimmt das KI-Modell die Positionen von Widerständen, Kondensatoren und deren Verbindungen. Diese Positionsinformationen (Relationen) können dann gegen ein Regelwerk geprüft werden. Abschließend kann dieses Regelwerk auch gänzlich durch die KI ersetzt werden. Dazu versieht man die Eingabedaten mit dem vorher erfassten Regelwissen (Labeln) und lässt die KI direkt lernen, ob z.B. bestimmte Relationen zu Designfehlern führen.

Des Weiteren sind Experimente mit dem Einsatz von Chatterbot in Use-Case 5 durchgeführt worden. Diese Python-Bibliothek ermöglicht es, einfache Chatbots zu bauen. Die Idee hier war, dass die Software so mehr Informationen über die zugrundeliegende Fehlerklasse (mithilfe festgelegter Regeln) ausgeben kann. Chatterbot erfordert einen definierten Satz von Fragen und Antworten und kann damit trainiert werden. Eine Interaktion könnte dann so aussehen:

Für Use-Case 6 können Regelwerke bei komplexeren Schematics helfen. Eine Liste von Kriterien wurde festgelegt, nach der die Komplexität differenziert wird. Dementsprechend können bestimmte Regeln angewandt werden. In diesem Fall können Regeln für die Texterkennung in den Schematics verwendet werden. Um zu bestimmen, welcher Text (Beschreibung) zu welcher

Komponente gehört. Manchmal ist es auch für den Menschen nicht direkt ersichtlich, ob eine textuelle Beschreibung zum Beispiel zu einem Widerstand links oder rechts von diesem gehört.

- Der Nutzer lädt die Messungen hoch
- Das KI-Modell gibt aus, welcher Designfehler am wahrscheinlichsten ist
- Der Chatbot kann, basierend auf dem Designfehler, verschiedene "Standard-"Lösungsvorschläge anbieten

Wenn ein Text erkannt wird, der durch seine Distanz zu einem Widerstand gehören könnte, aber ein Farad-Zeichen beinhaltet, kann eine Zugehörigkeit hier ausgeschlossen werden.

Besondere Bedeutung hatte hier die Entwicklung des Softwaremoduls zur Fusion der einzelnen geometrischen Informationen der Schematic hin zu einer Netzliste. Dieses Modul nutzt die mittels KI erkannten Linien, Komponenten und Texte und ihre Koordinaten im Bild, um die Topologie zu rekonstruieren. Hier können viele Regeln eingebracht werden, wie z.B. die vorher genannte Text-zu-Komponente Regel oder wie sich überlappende oder in der Tat kreuzende Verbindungslinien unterscheiden. Diese in einem abstrakten Format generierte Topologie konnte im Anschluss in ein ausgewähltes Format für Netzlisten exportiert werden.




Abbildung 12

Die Abbildung zeigt die erkannten Textboxen wie "C802", "10uF" und "0805" auf der linken Seite neben einem Kondensator, wobei zu sehen ist, dass "10uF" semantisch zu einem Kondensator passt. Neben dem Widerstand finden sich die Textboxen "R809", "1k", "0805", wobei "1k" hier ein Indikator für die Einheit des Widerstandes ist. Weitere Widerstand-Texte können mit dem regulären Ausdruck  $\backslash\text{b}\backslash\text{d}+[\text{kKmM}]?\text{[Rr]}\backslash\text{d}*\backslash\text{b}$  gefunden werden, welcher Werte wie "1K", "20R", "33R", "4k7", "2M" oder "3k3" erlaubt. Für Kondensatoren kann der reguläre Ausdruck  $\backslash\text{b}\backslash\text{d}+(\backslash\text{d}+)?[\text{pPnNuUmMfF}]\backslash\text{d}*\backslash\text{b}$  genutzt werden. Dieser findet Werte wie numerische Werte gefolgt von Einheiten wie "p" für Picofarad, "n" für Nanofarad, "u" für Mikروفarad oder "m" für Millifarad.

Die eingearbeiteten Regeln für die Use-Cases 3-6 sind mithilfe der Partner 01-BOSCH, 05-MCHP, 13-EMC, und 15-FIT/ENAS erarbeitet worden.

### **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 1.4.20: Spezifikation der Strukturen der Anwendungsebenen zur Implementierung von KI-gestützten Bildverarbeitungs-Algorithmen (20-HSHL)**

##### **Ziele**

Strukturierung der Anwendungsebenen zur optimalen Integration der KI-Bildverarbeitungsalgorithmen in den Workflow.

##### **Problemstellung**

KI-Bildverarbeitungsalgorithmen finden in verschiedenen Use-Cases Anwendung. Dabei handelt es sich meist um komplexe Pipelines, die auch softwaretechnisch von einer Vielzahl von Parametern abhängen; weitere Softwarebibliotheken als Abhängigkeiten, Betriebssysteme, Treiber, Prozessorleistung und vieles mehr. Darüber hinaus sind auch vortrainierte Modelle auf die eigenen Daten zu adaptieren, was wiederum die Integration der o.g. Parameter erfordert. Ziel ist es deshalb, die komplexe algorithmische Pipeline sowohl inhaltlich als auch softwaretechnisch möglichst einfach nutzbar, wartbar und transferierbar zu gestalten.

##### **Lösungsweg und Ergebnisse**

Die in verschiedenen Teilprojekten verwendeten "KI-gestützten Bildverarbeitungs-Algorithmen" waren zunächst noch einfach gehalten: Die erhaltenen Daten wurden vektorisiert und teilweise einer "Principal Component Analysis" (PCA) zur Dimensionsreduktion unterzogen, um das Training

und Testen mit vollständig verbundenen ("Dense") DNNs zu ermöglichen. Dies reicht für erste Experimente, um die prinzipielle Funktionsweise der entwickelten Bildverarbeitungs-Komponenten schnell auf beliebigen Systemen (auch ohne starke GPU) zu überprüfen. In späteren Systemversionen sollte diese Strategie durch die Verwendung von "Convolutional Neural Networks" (CNNs) abgelöst werden. Diese sollten dann in der Lage sein, GPU-gestützt auch große Eingabedaten (bspw. UC#3/UC#6) in akzeptabler Zeit zu verarbeiten.

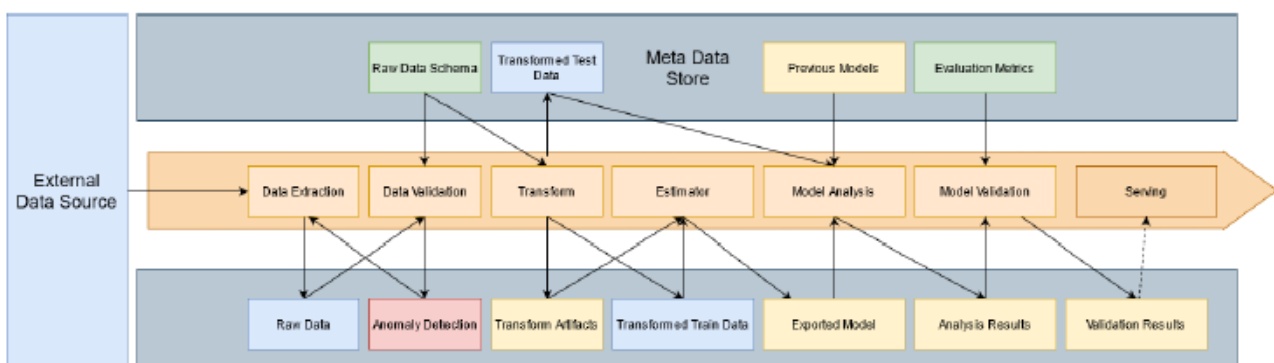
Dafür ist es notwendig, dass die Serverhardware (GPU-Server+Storage-Server) an der HSHL vorhanden ist und zur Realisierung einer verteilten Architektur mit den Serversystemen von 15-FIT, 18-HSU und 10-CAH verbunden wird. Dann erst konnten weitere Frameworks und Werkzeuge implementiert werden, die eine Verwendung und optimale Integration der Bildverarbeitungsalgorithmen erlauben.

Zur Überbrückung der Zeit bis zur Lieferung der Serverhardware und zur Realisierung der partnerübergreifenden und verteilten Serverarchitektur wurden sogenannte mobile Workstations (nicht finanziert aus dem Projektbudget!) mit starker CPU und vor allem GPU (RTX A 5000) beschafft. Diese Rechner sind mit 64 GB Ram ausgestattet. Es sollte so nicht nur eine zeitliche Überbrückung geschaffen werden, sondern vielmehr auch eine dauerhafte Preprocessing- und Testsituation umgesetzt werden, die es erlaubt, verteilte Architekturen zu „spielen“, testen und zu evaluieren. Ferner wurden diese Rechenmaschinen partnerübergreifend – da netzwerkübergreifend – eingesetzt, indem 2 Rechner im HSHL-Team und 2 Rechner im FIT-Team etabliert wurden.

Zudem wurde mit dem Partner 15-FIT zusammen Kubernetes für das Container-basierte Anwendungsmanagement und Kubeflow für das Workflowdeployment untersucht und eingesetzt.

Für die bildbasierte Algorithmik wurde zudem ein Workflow entwickelt und auf älterer, bereits vorhandener Hardware von 15-FIT getestet und schließlich implementiert. Dazu wurden vortrainierte Netze eingesetzt und erfolgreich mit Testdaten beschickt.

Der implementierte Workflow ist in nachfolgender Abbildung gezeigt und kombiniert etablierte Prozesse.



**Abbildung 13: Der implementierte Workflow**

Die GPU-Server für die HSHL befanden sich anschließend weiterhin in der Anschaffung. Bisher ist das Training der KI-Modelle auf den lokalen, dennoch leistungsstarken Entwicklerlaptops durchgeführt worden. Um eine Konsistenz zwischen verschiedenen Hardware-Umgebungen und verwendeten (vor-) trainierten Netzen zu schaffen, wurde sich dazu entschieden, die Modelle in Docker-Containern zu entwickeln. In diese Container können sämtliche Abhängigkeiten abgekapselt installiert werden. Solange sie auf einem Nvidia-Cuda-Image basieren, ist auch die Anbindung der GPU des Hosts möglich. Für Algorithmen, die z.B. CNNs zur Bilderkennung nutzen, gibt es in der

Regel bereits vorgepackte Container für die gängigsten Frameworks (Tensorflow, Pytorch...). Diese Frameworks können beispielsweise in Use-Case 3 oder 6 genutzt werden, um auch auf vortrainierten, frei verfügbaren Netzen aufzubauen und diese an das jeweilige Problem anzupassen.

Nach der verspäteten, aber erfolgten Lieferung der GPU-Server für die HSHL befanden sich diese im Aufbau bzw. der Inbetriebnahme. Um die Bildverarbeitungs-Algorithmen so vorzubereiten, dass sie relativ einfach zwischen verschiedenen Plattformen und Zielsystem transferiert werden können, wurde weiterhin Containerisierung mithilfe von Docker genutzt. Damit kann die algorithmische Pipeline auf einem Entwickler-Rechner bereits containerisiert aufgesetzt und getestet werden, bevor ein Training mit mehr Epochen oder größeren Datenmengen auf dem Server stattfindet. Abhängigkeiten, die für den implementierten Bildverarbeitungs-Algorithmus nötig sind, müssen vom Entwickler selbstständig eingetragen und wenn nötig im Dockerfile ergänzt werden, wenn es sich um komplexere Setups handelt. Trainierte Modelle wurden anschließend mit einer REST-Schnittstelle versehen, um sie an verschiedene Ziel-Anwendungen "anzukoppeln". Im bisherigen Workflow wurde nicht auf vorgefertigte Container für bestimmte Frameworks, z.B. Pytorch zurückgegriffen - diese werden im Sinne der von 15-FIT entwickelten Struktur der Service-Plattform pro Projekt spezifisch erstellt.

Durch die bereits frühzeitig integrierte Containerisierung der KI-Modelle und Pipelines ließen sich bereits bestehende Projekte mit geringem Aufwand auf die neuen Server migrieren. Bisherige Deep-Learning-Frameworks inklusive GPU-Anbindung ließen sich gut in einen containerisierten Workflow einbinden.

Durch den Service-Plattform-Ansatz, den gesamten Workflow von Beginn an zu Containerisieren, ist die Integration von Bildverarbeitungs-Algorithmen in den Workflow mit wenig Aufwand umzusetzen. Einzelne, "ressourcenhungrige" Modelle können als separater KI-Service angeboten und von mehreren weiteren Modulen genutzt werden, sodass diese Modelle nur einmal instanziiert werden müssen. Notwendige Anpassungen, um verfügbare Modelle mit eigenen Daten kompatibel zu machen und ein Fine-Tuning zu ermöglichen, sind spezifisch für jedes integrierte Modell wie z.B. YOLOv7 separat durchgeführt worden.

## **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 Rechte-Managements 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 2.1.20: Entwurf der Schnittstellenarchitekturen für die Anwendungsebene #2 (20-HSHL)**

### **Ziele**

Anforderungen an Portabilität externer und interner Schnittstellen.

### **Problemstellung**

Um einzelne KI-Komponenten in größeren Zielsystemen zusammensetzen, bedarf es definierten Schnittstellen. Das gilt sowohl für die internen Schnittstellen untereinander, also zwischen (falls benötigt) mehreren KI-Komponenten, als auch für die externen Schnittstellen zu anderen Systemen. Diese können Anfragen mit Daten an die KI-Modelle stellen und das Ergebnis wiederum weiterverarbeiten. Potenzielle Zielumgebungen im Rahmen des Projektes können sehr vielfältig und unterschiedlich sein. Daher ist es wichtig, die Portabilität dieser Komponenten zu gewährleisten.

### **Lösungsweg und Ergebnisse**

Zunächst wurde ein erstes System für die Verarbeitung von zur Verfügung gestellten Datensätzen aufgesetzt. Dabei ist eine Idee, den Systemkern konsistent zwischen verschiedenen Anwendungsfällen zu halten, wobei spezielle Importer Unterschiede in den zur Verfügung gestellten Datensätzen vor dem Systemkern abschirmen sollen. Ein entsprechender "vereinheitlichender" Ansatz ist allerdings aufgrund der teilweise starken Heterogenität der vom System zu verarbeitenden Datensätze, noch nicht realisiert und sollte in zukünftigen Systemversionen in den Fokus rücken (UC#3,UC#4,UC#5).

Zur Anbindung des Lernsystems an die einzelnen Projekte wurden die Importer an den jeweiligen Anwendungsfall angepasst: Für die Regression von PCB-Layouts auf Frequenzspektren (UC#3) erhält das System vom Projektpartner erzeugte Bilddaten als Eingabe, welche mittels des Importers in für Deep Learning (DL)-Methoden verständliche Eingangsvektoren umgewandelt werden. Die zu den PCBs gehörigen Frequenzspektren wurden durch einen weiteren Import-Prozess ebenfalls vektorisiert und so für das Training von DL-Modellen verfügbar gemacht.

Im Fall der Klassifizierung von EMV-Klassen aufgrund von Frequenzspektren liest ein spezialisierter Importer die erhaltenen Spektren ebenfalls in einen Vektor ein und macht sie dem DL-System zugänglich. Die Ausgabe-Schnittstellen waren alsdann für jeden Anwendungsfall, aufgrund der Unterschiedlichkeit der jeweiligen Anforderungen, individuell aufgesetzt. Zu diesem Zeitpunkt war noch nicht erkennbar, ob die Unterschiede in den Ausgaben für die einzelnen Teilprojekte vereinheitlicht werden können; die Beantwortung dieser Frage sollte in zukünftigen Systemversionen in den Fokus rücken. Ferner gilt auch hier, dass sich die UseCases zunächst weiter entwickeln mussten und die neue Hardware (mindestens die mobilen Workstations) vorhanden sein musste.

Durch die voranschreitende Architektur der Service-Plattform wurden wenige Einschränkungen an die eingehende Datenformate gestellt. Hier wird lediglich vorausgesetzt, dass es sich um Dateien handelt. Diese Dateien werden dann in einem Use-Case-spezifischem Prozess entsprechend eingelesen und für die Weitergabe an das KI-Modell aufbereitet. Durch die hohe Heterogenität der Eingabedaten (Bilder, numerische Werte, verschiedene Dimensionen) konnte bisher kein gemeinsames Importer-Format gefunden werden. Durch die Modularität der Service-Plattform und das Zerlegen der Use-Cases in einzelne Prozesse blieben die entsprechenden Importer-Schnittstellen zwischen Eingabedaten und KI-Modell (Vektorisierung der Daten) relativ übersichtlich und gering. Auch die Rückgabe der Ergebnisse lässt sich nicht über alle Use-Cases hinweg vereinheitlichen; Da zum Teil Regressions-, aber auch Klassifikationsprobleme vorliegen und das auf numerischen wie auch Bilddaten, ist mit Bezug auf die Service-Plattform lediglich eine übergeordnete Schnittstelle (REST-API) vorgeschlagen worden, die das Aufruf- und Antwortverhalten spezifiziert, jedoch das Format der über die Schnittstelle übertragenen Nutzdaten für den jeweiligen Anwendungsfall offenlässt.

Im Anschluss wurde weiterhin mit Use-Case-spezifischen Schnittstellen verfahren. Durch die hohe Heterogenität der Daten und den iterativen Prozess, in welchem auch neue Modelle- und Architekturen evaluiert wurden, konnte sich nicht einmalig auf eine bestimmte Schnittstelle festgelegt werden. Die Arbeiten z.B. in Use-Case 6 zeigen, dass beim Austausch von trainierten Modellen – eben je nach verwendetem, unterliegendem Modell – zusätzliche Parameter mitgesendet werden müssen. Hier ist lediglich die Einschränkung gegeben, dass standardmäßig eine REST-API von einem Modell bereitgestellt werden soll. Durch die Containerisierung der Modelle bleiben die verwendeten Schnittstellen ebenfalls portabel.

Nach Außen können Modelle jedoch in verschiedenen Varianten mit Schnittstellen versehen werden. Zum einen kann ein trainiertes Modell in einen sogenannten App-Container "verpackt" und mit einer REST-Schnittstelle versehen werden (im Workflow der Service-Plattform von 15-FIT). Darüber hinaus kann ein trainiertes Modell auch ohne Laufzeit-Umgebung (Container) in einer Art Rohversion auf dem Storage-Server abgelegt und für andere Entitäten verfügbar gemacht werden. Zudem fanden Experimente mit dem Tool "mlem" statt, welches ein trainiertes Modell automatisiert "packen" kann und es mit verschiedenen Schnittstellen ausstattet: REST-API, RabbitMQ und Streamlit, und das sowohl containerisiert als auch nativ. Die Schnittstellen werden automatisch anhand von Beispieldaten erzeugt und können ebenfalls pre- und postprocessing-Schritte beinhalten.

Die Untersuchungen hinsichtlich des Einsatzes des Tools mlem sind allerdings abgeschlossen worden, da diese Software nicht mehr weiterentwickelt wurde. Daher wird final der o.g. Workflow über die App-Container umgesetzt.

Des Weiteren fand eine kontinuierliche Anpassung der Schnittstellen bei Bedarf statt. Zum Beispiel erforderte die Integration der KI-Backends mit einer grafischen Oberfläche Anpassungen in den bisherigen Schnittstellen.

### 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.

Keine Arbeiten.

### **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 2.3.20: Klassifikation von Bilddaten anhand von Metadaten und semantischen Annotationsprozessen (20-HSHL)**

#### **Ziele**

Metadaten und Regelwerke können einen großen Beitrag zur Klassifikation der Bilddaten liefern und werden in die verschiedenen Module der Plattform integriert.

#### **Problemstellung**

Um das Training von KI-Modellen zu ermöglichen, wird eine große Anzahl von gelabelten Trainingsdaten benötigt. Die vorliegenden Bildverarbeitungs-Probleme sollen mithilfe von Supervised-Learning (Überwachtes Lernen) und bereits vortrainierter Deep-Learning-Modelle gelöst werden. Zwar bringen die Partner (z.B. 05-MCHP) potenzielle Trainingsdaten mit ein, allerdings müssen diese noch mit Annotationen versehen werden. Des Weiteren sollen auch Metadaten genutzt werden, um den Annotationsprozess zu unterstützen oder teilweise zu automatisieren.

## Lösungsweg und Ergebnisse

Gelant war zunächst für die automatisierte Requirements-Analyse Datenblätter nach Textpassagen, Schaltplänen und Tabellen mittels "Deep-Learning"-Verfahren zu durchsuchen (UC#6). In Absprache mit den Projektpartnern mussten dafür zunächst gelabelte Trainings-Daten zur Verfügung stehen. Diese sollten mit Hilfe eines entsprechenden Label-Werkzeugs generiert werden. Zu diesem Zweck hatte HSHL als ersten Vorschlag eine selbstentwickelte Labeling-Lösung aufgesetzt. In Abstimmung mit den Projektpartnern wurde diese Lösung dann allerdings zugunsten eines web-basierten Labeling-tools ("Label Studio") obsolet (siehe <https://labelstud.io/guide/index.html>). Die OpenSource-Version von Label Studio ist als Netzwerkversion durch 15-FIT installiert worden und steht den Partnern 20-HSHL und 15-FIT zur Verfügung. Die Verfügbarkeit wurde über mehrere Use-Cases für weitere Partner angepasst.

Im Use-Case 6 wurde auf das Erkennen der Positionen von Kondensatoren oder anderen Bauteilen in den Schaltplänen durch Deep-Learning gesetzt. Eine Integration von explizitem Wissen in Form von händisch codierten Regeln findet aus bereits vorher genannten Gründen nicht statt. Allerdings beinhalten einige PDFs mit Schaltplänen Metadaten, die Rückschlüsse auf die Positionen der Bauteile oder anderen Blöcken innerhalb der PDF zulassen. Diese Metadaten werden als Labels genutzt, um die Abbildung Eingabebild -> Komponentenposition in der PDF zu lernen. Ein händisches Labeln der PDFs fand damit nicht mehr statt, außer für die ICs.

Die KI-Pipeline ist anfangs mit einem Detectron2-Modell aufgesetzt worden und 7 verschiedene Komponenten konnten erkannt werden. Darüber hinaus fanden erste Tests für die Linienerkennung mit dem Wireframe-Detector LCNN statt.

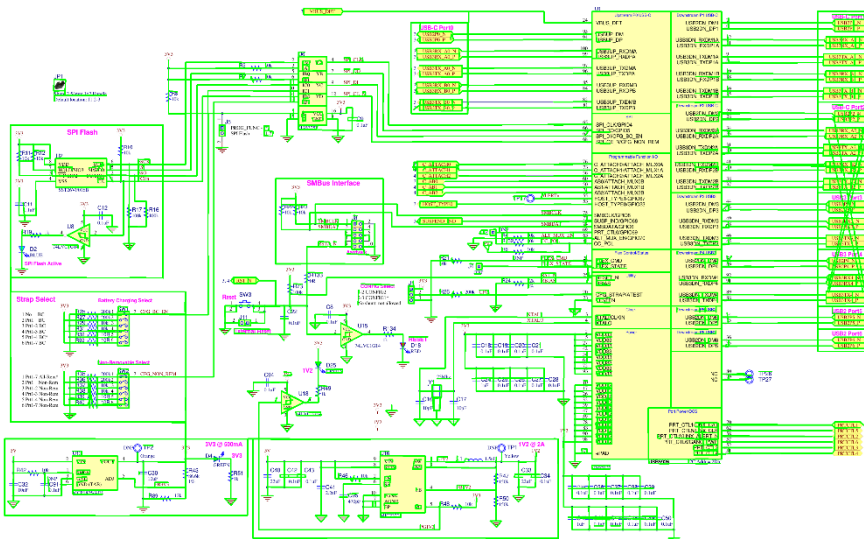


Abbildung 14

Die oben gezeigte Abbildung zeigt in grünen Linien die erkannten Verbindungen. Obwohl viele erkannt werden konnten, traten viele Überlappungen und Dopplungen auf. Dies machte eine anschließende Säuberung/Vereinheitlichung erforderlich.

Im weiteren Verlauf des Use-Cases 6 ist Detectron2 zugunsten von YOLOv7 abgelöst worden. Das Yolo-Modell verfügte über eine bessere Genauigkeit auf dem COCO-Referenzdatensatz. Zusätzlich

musste das Bild nicht in viele "kleinere Teile" zerlegt und im Anschluss rechenaufwändig wieder zusammengesetzt werden, da Detectron2 nur mit kleineren Bildausschnitten arbeiten kann.

Parallel wurde der automatische Annotations-Algorithmus für diesen Use-Case erweitert, um aus den PDFs nun auch Linien extrahieren und für das Nachtrainieren der Linienerkennung nutzen zu können. Für eine detaillierte Aufstellung sei auf das Paper "From Schematics to Netlists – Electric Circuit Analysis Using Deep-Learning Methods", geplant im Advances of Radio Science (2024) verwiesen.

In Use-Case 3 sind ebenfalls Bilddaten verwendet worden, um den Ground-Cutout zu optimieren. Hier herrschte bereits frühzeitig der Vorteil, dass entsprechende abgestrahlte Frequenzspektren vom Partner 01-BOSCH direkt in der Simulation mit erzeugt werden konnten. So mussten keine Daten von Hand annotiert werden oder eine Software zur Extraktion aus den Metadaten geschrieben werden. Allerdings war der Datensatz anfangs etwas ungleichmäßig verteilt, sodass in einem Vorverarbeitungsschritt neu aus dem Datensatz gesampled werden musste.

### **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 Probleminstance 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 Probleminstance 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 Probleminstance 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 Probleminstance 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 2.4.20: Integration Qualitätskontrolle in KI-gesteuerte Work-Flows (KI-Modul-Plattform) (20-HSHL)**

##### **Ziele**

Erstellung der Anforderungen an die Integration der Qualitätskontrolle (generalisierte Metaalgorithmen und Qualitätsmatrizen für die modulare KI-Plattform)

##### **Problemstellung**

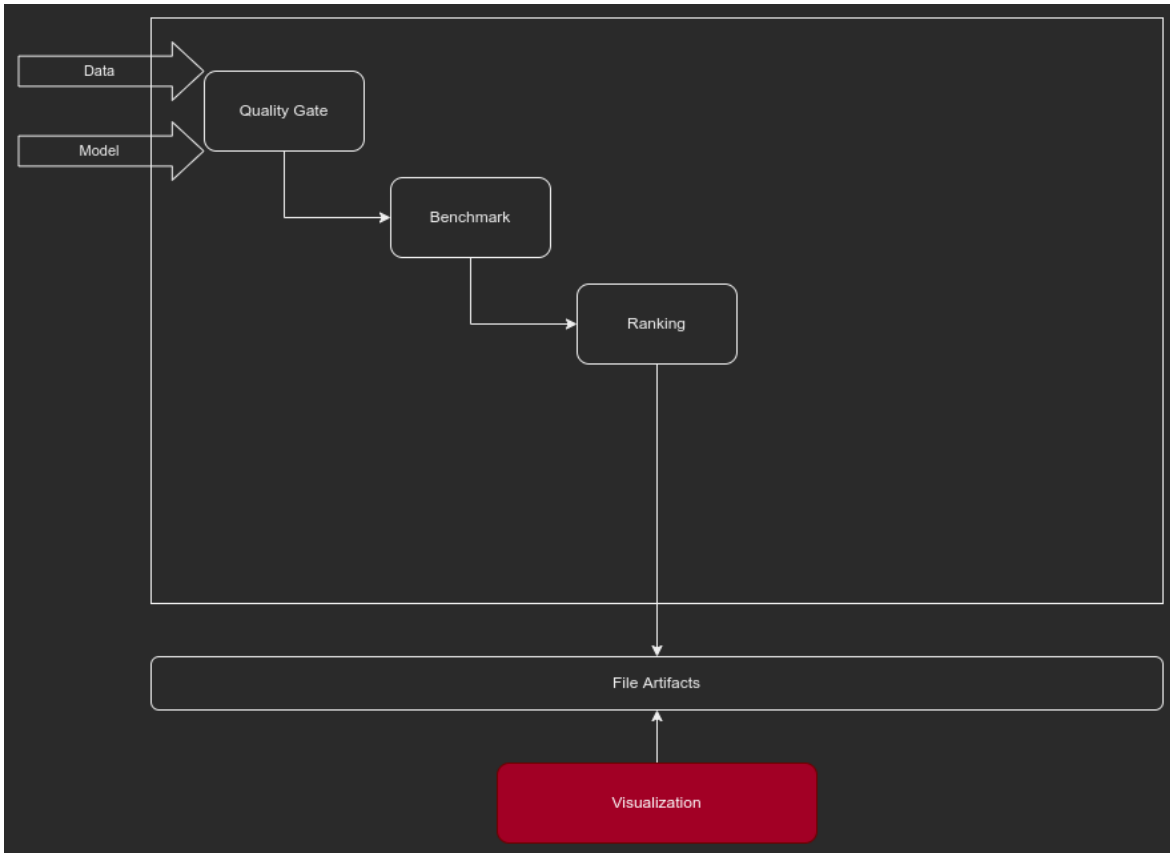
Die Entwicklung von KI-Modulen erfordert eine ständige Überwachung der Performance und Qualität. Diese Modelle haben oft viele Hyperparameter, die optimiert werden können. Orthogonal dazu hängt die Performance auch immer von den verwendeten Daten ab. Um nicht den Überblick zu verlieren, welche Daten und welche KI-Konfiguration zu welchem Ergebnis geführt hat, bedarf es einer automatisierten Überwachung bzw. Qualitätskontrolle.

##### **Lösungsweg und Ergebnisse**

Mit den Arbeiten zu diesem TB wurde in QII/22 in Kooperation mit dem Partner 15-FIT und 18-HSU begonnen. Die Vorarbeiten dazu wurden in drei Gruppenübergreifenden VIKOs gemacht. Diese VIKOs fanden ab Q1/22 wöchentlich statt.

In der Planung der Service-Plattform innerhalb des Use-Case 8 ist bereits die Integration von Mechanismen zur Qualitätskontrolle vorgesehen worden, welches die nachfolgende Grafik

veranschaulicht.



**Abbildung 15**

In diesem Ablauf können Modelle gegen verschiedene Daten getestet werden. Sowohl Modelle als auch Datensätze können auf bestimmte, projektabhängige Qualitätskriterien untersucht werden. Im Benchmark kann dann die Performance des Modells gegeben eines Datensatzes und bestimmten Metriken untersucht werden. All diese Informationen zu kombinieren und ein übersichtliches "Ranking" der Modelle zu erstellen ist ebenfalls Teil des Projektes *progressivKI*. Zunächst war dieser Teil nur konzeptioniert; die Umsetzung wurde im weiteren Verlauf des Projekts verfolgt, auch mit Hinblick auf die zu erwartende Reife der Modelle aus den Use-Cases 3-6.

Darüber hinaus fügt die Service-Plattform nach jedem Training auf dem Server einen "Report" an den entsprechenden Commit. So kann übersichtlich und nachvollziehbar gesehen werden, welche Modellkonfiguration zu welchem Ergebnis führt. Regressionen in der Performance können so auch automatisiert erkannt und das Live-Schalten eines schlechteren Modells verhindert werden.

Commit e472d6cd authored 19 hours ago by dennis.hemker

1 | Browse files | Options

### Train: Remove non-altium schematics

parent 59d14176 train/develop

No related merge requests found

Pipeline #102454 passed with stages in 573 minutes and 9 seconds

Changes 2 | Pipelines 1

Showing 2 changed files with 13 additions and 12 deletions

Hide whitespace changes | Inline | Side-by-side

data/inbox.dvc		+7 -7	View file @e472d6cd
1	-	md5: 23b2e4e6e2dbcdeb0fb0a5792b6e1fd	
1	+	md5: 0fd176fe9b958ba75c1192eca4714507	
2	2	frozen: true	
3	3	deps:	
4	-	md5: 37f4612e3df33971cc7b01a7f262c579.dir	
5	-	size: 121952594	
6	-	nfiles: 73	
4	+	md5: 23e4bd761f6db093ce763043b076f249.dir	
5	+	size: 98633680	
6	+	nfiles: 67	
7	7	path: remote://inbox	
8	8	outs:	
9	-	md5: 55c9d72940e32f3c9e208f90d24afafa.dir	
10	-	size: 121952594	
11	-	nfiles: 73	
9	+	md5: cb05b84a73779bd0a0db6a6f98bd9ff3.dir	
10	+	size: 98633680	
11	+	nfiles: 67	
12	12	path: inbox	

Abbildung 16

The image shows a code editor with a `dvc.yaml` file and a screenshot of a 'Training Report' from a chat interface.

**dvc.yaml content:**

```

1 | 1 | stages:
2 | 2 |   extract_images:
3 | 3 |     - cmd: python src/image_extractor.py data/inbox data/extracted
4 | 4 |     + cmd: python src/image_extractor.py data/inbox/altium data/extracted
5 | 5 |     deps:
6 | 6 |       - data/inbox
7 | 7 |       + data/inbox/altium
8 | 8 |       - src/image_extractor.py
9 | 9 |     params:
10 | 10 |     - extract_images
11 | 11 |     outs:
12 | 12 |     - data/extracted
13 | 13 |   parse_pdf:
14 | 14 |     - cmd: python src/parse_pdf.py data/inbox data/extracted data/coco
15 | 15 |     + cmd: python src/parse_pdf.py data/inbox/altium data/extracted data/coco
16 | 16 |     deps:
17 | 17 |       - data/inbox
18 | 18 |       + data/inbox/altium
19 | 19 |       - data/extracted
20 | 20 |       - src/parse_pdf.py
21 | 21 |     params:
22 | 22 |     @ -32,8 +32,9 @@ stages:
23 | 23 |     outs:
24 | 24 |     - model/
25 | 25 |     test:
26 | 26 |     - cmd: python src/test.py data/inbox
27 | 27 |     + cmd: python src/test.py data/inbox/altium
28 | 28 |     deps:
29 | 29 |       - data/inbox/altium
30 | 30 |       - model/
31 | 31 |       - src/test.py
32 | 32 |       - src/predict.py

```

**Training Report Metrics:**

Path	bbox/AP	bbox/AP-Capacitor	bbox/AP-Connector	bbox/AP-Diode	bbox/AP-IC	bbox/AP-Led	bbox/AP-Resistor	bbc Tra
metrics/train.json	85.02582	87.68978	84.43984	84.94286	91.21535	82.72477	73.04002	91.1

**Abbildung 17**

Mit dvc als Bestandteil der Service-Plattform können Metriken zwischen Commits verglichen und getracked werden, wie in den vorher gezeigten Abbildungen zu sehen ist.

Dabei sind die Metriken stets projektspezifisch – solange sie in eine Datei geschrieben werden können, können sie mithilfe des Toolings und dvc veranschaulicht und verglichen werden. Zu diesem Zeitpunkt wurde das Open-Source-Tool „mlem“ untersucht; damit konnten auch Datensätze „verpackt“ und mit Metainformationen versehen werden. So sollten dann mlem-kompatible Modelle und Daten automatisiert miteinander „verrechnet“ werden. Das Modell kann als Metadaten die Informationen über die Trainingsmetriken beinhalten, welche dann mithilfe des Meta-Algorithmus gegen die Metriken beim Anwenden eines anderen, kompatiblen Datensatzes verglichen werden. Leider wurde die Entwicklung dieses Tools während der Projektlaufzeit eingestellt. Nachfolgende Abbildung zeigt die Performanceänderung nach dem Einsatz eines Multi-Gpu-Trainings.

## Use multi-gpu tag

parent 9d540a2f

Branches > Branches containing commit

No related merge requests found

Pipeline #138088 canceled with stage in 5 minutes and 10 seconds

Changes 1 | Pipelines 26

Showing 1 changed file with 4 additions and 0 deletions

Hide whitespace changes | Inline | Side-by-side

.gitlab-ci.yml

+4 -0 | View file @dfcd596a

```
... .. @@ -2,6 +2,10 @@ include:
2 2 - project: 'symila/progressiveai/serviceplatform/ci-templates'
3 3   file: gitlab.yml
4 4
5 5 + dvc-exp:
6 6 +   tags:
7 7 +     - multi-gpu
8 8 +
5 9 prepare-docker-app:
6 10   variables:
7 11     MODEL_PATH: model/yolov7/weights/best.pt
... ..
```

cml @group\_1028\_bot · 2 days ago

Developer | ⌵ | ✎ | ⋮

### Experiment Report


- Date: Sat 22 Jul 2023 02:09:34 AM UTC
- Command: `dvc exp run --pull`

### Metrics

#### DVC Metrics

Path	map50.Capacitor	map50.Crystal	map50.Diode	map50.Inductor	map50.Mosfet	map50.all	map95.Cap
metrics/yolov7/test/test_metrics.json	0.98522	0.84053	0.89974	0.9029	0.94377	0.91443	0.83654

Abbildung 18




**Abbildung 19**

Das Tooling der Service-Plattform sucht automatisch nach abgelegten Bildern und weiteren Metriken im Markdown-Format und fügt diese automatisch an ein Trainings-Experiment hinzu. Diese Informationen verbleiben langfristig am Git-Commit und sind für alle Team-Mitglieder nachvollziehbar. Zunächst fehlte die Integration einer Kontrolle, damit Modelle mit schlechterer Performance nicht auf den "Main-Branch" gemerged werden und somit live gehen können. Hier befanden sich verschiedene Ansätze in der Evaluation, um dies sicherstellen zu können. Darüber hinaus können bestimmte, wiederkehrende Metriken für ein gegebenes Framework automatisiert erzeugt werden.

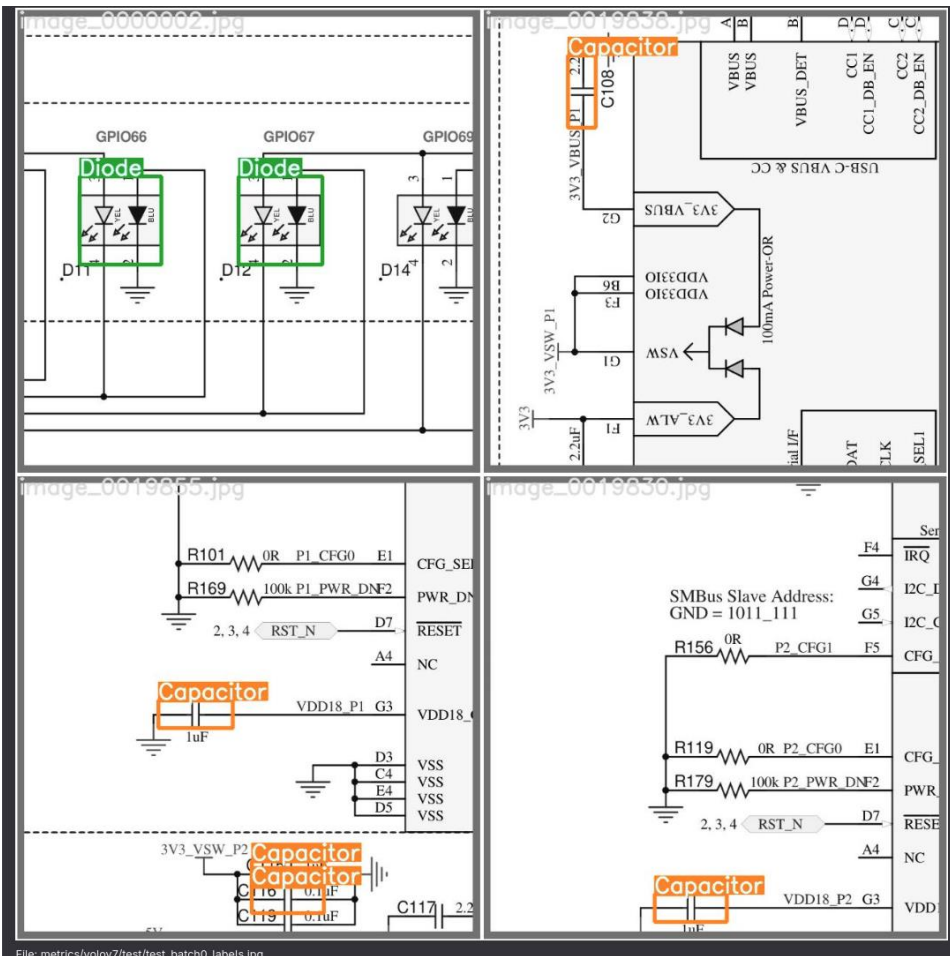
Im Anschluss fand eine stärkere Integration der dvc experiment-Funktionalität statt, sodass "von außen" nun Trainings mit Parameter-Sweeps oder einzelnen Parameteränderungen einfach und skalierbar ausgeführt werden können. Jedes Experiment wird zum Git-Commit, auf dem es basiert, hinzugefügt und samt Metriken und spezifischen Plots oder Bildern persistiert. Über dvc lassen sich diese Experimente einfach auf Entwicklungsrechner übertragen, inspizieren und auf den Produktivbranch mergen.

Die nachfolgenden Abbildungen zeigen einen Ausschnitt aus den integrierten, projektspezifischen und verfügbaren Metriken und Plots für den Use-Case 6.



File: metrics/yolov7/test/confusion\_matrix.png

Abbildung 20



File: metrics/yolov7/test/test\_batch0\_labels.jpg

Abbildung 21

Diese Metriken und Plots sind in Git bzw. Gitlab getrackt, sodass man Zustand und Performance der Modelle gesammelt an einem Ort hat. Für die Integration des Metaalgorithmus können diese projektspezifischen Metriken über weitere REST-Schnittstellen bereitgestellt werden, sodass sie vom Metaalgorithmus angefragt werden können.

Eine Bereitstellung ist durch eine Erweiterung des Tools sppc erfolgt, sodass diese Metriken von außen über eine Schnittstelle abgefragt werden können; dies ist vor allem für den Metaalgorithmus nützlich, um dynamisch die Modellperformance zu beurteilen. Nachfolgend ist ein Metrik-Beispiel abgebildet, was den Start eines "Remote"-Containers zeigt und das Abfragen der Trainingsmetriken:

```
(env) user@ubuntu:~/projects/progressivKI/use_cases/external/test [train/develop]$ sppc docker run --type remote
```

```
2024-08-01 16:56:11.897 | INFO | Parsing dvc.yaml in /home/user /projects/progressivKI/use_cases/external/test
```

```
2024-08-01 16:56:11.900 | INFO | Writing api file to /home/user/projects/progressivKI/use_cases/external/test/.sppc/docker/dvc_stages_api.py
```

```
2024-08-01 16:56:11.900 | INFO | Checking for CUDA availability
```

```
2024-08-01 16:56:11.983 | INFO | Detected CUDA version 12.2
```

```
2024-08-01 16:56:11.983 | INFO | Starting remote container test:train-develop-remote
```

```
=====  
== CUDA ==  
=====
```

CUDA Version 12.1.0

Container image Copyright (c) 2016-2023, NVIDIA CORPORATION & AFFILIATES. All rights reserved.

This container image and its contents are governed by the NVIDIA Deep Learning Container License.

By pulling and using the container, you accept the terms and conditions of this license:

<https://developer.nvidia.com/ngc/nvidia-deep-learning-container-license>

A copy of this license is made available in this container at /NGC-DL-CONTAINER-LICENSE for your convenience.

\*\*\*\*\*

\*\* DEPRECATION NOTICE! \*\*

\*\*\*\*\*

THIS IMAGE IS DEPRECATED and is scheduled for DELETION.

<https://gitlab.com/nvidia/container-images/cuda/blob/master/doc/support-policy.md>

INFO: Started server process [1]

INFO: Waiting for application startup.

INFO: Application startup complete.

INFO: Uvicorn running on http://0.0.0.0:8000 (Press CTRL+C to quit)

2024-08-01 14:57:24.031 | INFO | dvc\_stages\_api:metrics:278 - Received get metrics

2024-08-01 14:57:24.032 | DEBUG | dvc\_stages\_api:metrics:282 - Checking metrics file: metrics/train\_accuracy.json

2024-08-01 14:57:24.033 | DEBUG | dvc\_stages\_api:metrics:282 - Checking metrics file: metrics/train\_loss.json

2024-08-01 14:57:24.033 | DEBUG | dvc\_stages\_api:metrics:282 - Checking metrics file: metrics/test\_metrics.json

INFO: 127.0.0.1:53394 - "GET /metrics HTTP/1.1" 200 OK

Die Antwort auf einen Curl-Befehl "curl -X GET localhost:8000/metrics" sieht wie folgt aus:

```
{
  "train_accuracy.json": {
    "train": [
      {
        "accuracy": 0.4723333418369293
      },
      {
        "accuracy": 0.6853333115577698
      },
      {
        "accuracy": 0.7248333096504211
      },
      {
        "accuracy": 0.7431666851043701
      },
      {
        "accuracy": 0.7731666564941406
      }
    ]
  }
}
```

```
},
{
  "accuracy": 0.7919999957084656
},
{
  "accuracy": 0.7988333106040955
},
{
  "accuracy": 0.8015000224113464
},
{
  "accuracy": 0.8224999904632568
},
{
  "accuracy": 0.8309999704360962
}
]
},
"train_loss.json": {
  "train": [
    {
      "loss": 1.8130592107772827
    },
    {
      "loss": 0.8556488156318665
    },
    {
      "loss": 0.7205473780632019
    },
    {
      "loss": 0.6668226718902588
    },
    {
```

```

    "loss": 0.6058799624443054
  },
  {
    "loss": 0.5577669143676758
  },
  {
    "loss": 0.5593980550765991
  },
  {
    "loss": 0.5215964317321777
  },
  {
    "loss": 0.48772603273391724
  },
  {
    "loss": 0.46782535314559937
  }
]
},
"test_metrics.json": {
  "accuracy": 0.7983999848365784,
  "loss": 0.5908977389335632
}
}

```

Die Metriken für die Trainings- und Test-Stages können im maschinenlesbaren JSON-Format von anderen Modulen gelesen und ausgewertet werden. Der “Remote“-Container kann dann ein neues Training mit neuen Parametern – gesteuert von außen - durchführen.

### 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. angelernte 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 angelernter Algorithmen.

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

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

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

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

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

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

Bearbeitung der folgenden TA2.5-Themen:

- Review der bisherigen Arbeiten an den Trainingsmodulen für AW #1 und #2.
- Auswertung des KI-Trainingsmoduls AW#1
- Erstellung, Verwaltung und Validierung von Trainings-Pipelines zur Verbesserung von bereits fertiggestellten KI-Modellen
- Aufteilung und Aufbereitung der Eingangs- und Ausgangsdaten der Datenblätter von elektronischen Komponenten in einen Trainings-, Validierungs-, und Testdatensatz
- Training für KI-Anwendung Kontext von Requirements-Engineering-Methoden
- Schnittstellenmodelle für Datenbasierte Training-/Lernmodule zur Unterstützung des Entwurfs von Komponenten der Industrieelektronik
- Analyse Open-Source Algorithmen für datenbasierte Training-/Lernmodule
- Anpassung von KI-Modulen und Generierung von Trainings- und Lerndaten

- Bereitstellung spezifischer Simulations- bzw. Berechnungsverfahren zur Generierung von Lerndaten (z. B. Daten für Power-Ground-Kopplungen)
- Anpassung von Entwurfsdaten sowie Vorverarbeitung zur Nutzung für CNN und Transfer-Learning.

## Teilbeitrag 2.5.20: Anforderungsanalyse zur Datenanpassung + Vorverarbeitung zur Datennutzung für CNN sowie Transfer-Learning (20-HSHL)

### Ziele

Erstellung der Anforderungen an das Preprocessing von EDA-relevanten Bilddaten (bildliche Darstellung von Entwurfsdaten).

### Problemstellung

Um die vorhandenen Bilddaten für die KI konsumierbar zu machen, müssen diese bestimmte Vorverarbeitungsschritte durchlaufen. Das kann z.B. eine Reduktion der Auflösung/Größe sein oder eine Farbkonvertierung hin zu Graustufen. Diese Schritte hängen – vor allem bei Nutzung von vortrainierten neuronalen Netzen – von deren Architektur und Schnittstellen ab. Diese Modelle definieren selbst, ob sie mit RGB- oder Graustufenbildern arbeiten oder ob das Eingabebild auf den Wertebereich 0 – 1 normiert sein soll.

### Lösungsweg und Ergebnisse

Hier kann TB2.1.20 referenziert werden, was die notwendige Vorverarbeitung/Datennutzung angeht. Zunächst gab es zum Thema „*Transfer Learning*“ (TL) keine weiterführenden Erkenntnisse, da die Arbeit in den Use-Cases voranschreiten musste. Es war aber denkbar, dass ein solches TL sowohl im UC#3/UC#6 eingesetzt werden kann (Vortraining von CNNs), wobei sich die Frage stellte, ob auf natürlichen Bildern vortrainierte CNNs auf PCB-Layout-Abbildungen oder Datenblatt-Figures in jedem Fall einen zusätzlichen Nutzen erzielen werden, da sich die Bildstatistiken im UC#3/UC#6 vermutlich nicht unerheblich von den Statistiken natürlicher Bild-Daten unterscheiden könnten. Diese Untersuchungen setzten sich mit dem Voranschreiten der Use-Cases fort.

Für viele Probleme können komplexe, vortrainierte Modelle genutzt werden. Sie sind auf riesigen Datenmengen mithilfe hoher Rechenleistung trainiert worden und können mit den eigenen Daten meist mit weniger Rechenaufwand „nachtrainiert“ werden. Viele dieser Modelle sind bereits veröffentlicht und direkt in verschiedenen Frameworks nutzbar, z.B. in Tensorflow oder Pytorch.




Abbildung 23




Abbildung 22

Um vortrainierte Modelle auf eigene Datensätze anzupassen, muss das Modell zunächst lokal instanziiert werden und die Eingabedaten müssen exakt den geforderten Formaten entsprechen. Verschiedene Schichten können eingefroren werden und mit eigenen Ausgabeschichten ersetzt werden. So können Modelle für Regressionsprobleme auch auf Klassifikationsprobleme und andersherum angepasst werden. Viele bekannte Netze sind frei verfügbar, wie z.B. VGG16(Tensorflow), YOLO(Pytorch) und ALEXNET(Pytorch).

Für Use-Case 6 ist zunächst das bekannte SSD300(Pytorch) eingesetzt worden. Es erfordert eine strikte Eingabegröße der Bilder von 300x300 Pixeln, wobei die Label im COCO-Format vorliegen müssen.

In Use-Case 3 lagen die ersten Daten ebenfalls als PDFs vor. Sie mussten in Bildformate wie JPG umgewandelt werden und wurden nicht direkt für das Training eines Modells genutzt, sondern in den latenten Raum mithilfe eines Variational-Auto-Encoders transformiert. Diese latenten Variablen sind dann als Eingabe für den Optimierungsprozess (weiteres KI-Modell) genutzt worden.

Auch für Use-Case 6 lagen die Daten in PDF-Form vor. Dies erforderte ebenfalls eine Konvertierung in JPG, bevor verschiedene, vortrainierte KI-Modelle in Betracht kamen. Während in diesem Use-Case von SSD300 auf Detectron2 und anschließend auf das noch besser funktionierende YOLOv7 gewechselt wurde, sind die rohen JPG-Daten immer wieder durch verschiedene Vorverarbeitungs-Pipelines gelaufen bzw. diese wurden stetig angepasst.

In Use-Case 5 sind ebenfalls iterativ Anpassungen an die Vorverarbeitungs-Pipeline durchgeführt worden. Zwar sind hier keine Bilddaten verarbeitet worden, allerdings konnten bestimmte Techniken wie die Transformation in den latenten Raum mithilfe von Adversarial-Auto-Encoders aus anderen Use-Cases übertragen werden.

Abschließend lässt sich festhalten, dass man in diesem TB nur „grobe“ Anforderungen an die generellen Vorverarbeitungsschritte stellen konnte, z.B. dass PDFs in JPG-Bilddaten konvertiert werden müssen. Da während der Projektlaufzeit neue, vortrainierte und mächtige Modelle mit ihren eigenen Anforderungen an Daten verfügbar wurden, sind die Vorverarbeitungs-Pipelines iterativ angepasst worden, um diese Modelle nutzbar zu machen. Dem noch vorgelagerte Vorverarbeitungsschritte sind mit den entsprechenden Partnern 01-BOSCH, 05-MCHP, 13-EMC und 15-FIT/ENAS besprochen worden.

### **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 3.1.20: Anpassung von Algorithmen für verteilte Rechnernetze (20-HSHL)**

#### **Ziele**

Anpassung der KI-Algorithmen an die Vorgaben der installierten Rechnernetze

#### **Problemstellung**

Um lokal oder auf anderer Hardware entwickelte Algorithmen auf andere Zielsysteme und Netzwerke zu übertragen, muss eine gewisse Portabilität gewährleistet werden. Damit die Algorithmen auch über Netzwerke hinweg arbeiten können, sind bestimmte Voraussetzungen zu erfüllen, die Schnittstellentechnologie mit eingeschlossen.

#### **Lösungsweg und Ergebnisse**

Auch hier gilt, dass zunächst ein Rechnernetzwerk realisiert werden musste, um den TB bearbeiten zu können. Es war geplant, mit den Arbeiten in QII/22 zu beginnen.

Der HSHL-GPU Server befand sich anschließend längere Zeit in der Bestellung/Lieferung. Parallel wurden bereits Konzepte erarbeitet, wie man KI-Algorithmen auf verschiedenen Infrastrukturen nutzen kann. Durch die Abkapselung der Algorithmen in einen Docker-Container sollte es kein Problem darstellen, die Modelle auf verschiedenen Infrastrukturen zu deployen. Durch die Containerisierung wird von den eigentliche Hardwaregegebenheiten abstrahiert. Da zu diesem Zeitpunkt auf den lokalen Entwicklerrechnern bereits innerhalb von Docker-Containern trainiert wurde, ist der Schritt, eine andere Infrastruktur zu nutzen die ebenfalls Docker anbietet, nicht mehr so groß. Fragen, die es zu untersuchen galt, waren im weiteren Verlauf eher bei der Einrichtung der GPU-Server zu sehen; welche Tools sind nötig, um Container automatisiert laufen zu lassen?

Nach der Lieferung der GPU- und Storage-Server mussten diese noch in Betrieb genommen werden. Durch den Ansatz der Containerisierung war bereits eine Portabilität zwischen lokalen Entwicklungsumgebungen (Laptops, Workstations) und einer andersartigen Umgebung – z.B. für das Training auf einem Server oder das Deployment – gegeben. Algorithmen in den Use-Cases 3,4,5 und 6 sind bisher in Containern entwickelt worden und konnten so einfach auf die Zielplattform übertragen werden. Lediglich eine GPU-Beschleunigung (wenn nötig) musste über den Container vorhanden sein. Hat das Zielsystem eine z.B. andere CUDA-Version, kann im .gitlab-ci.yaml einfach eine neue Konfiguration über die Service-Plattform gebaut werden:

```

1  include:
2  - project: 'symila/progressiveai/serviceplatform/ci-templates'
3  file:
4    - 'gitlab/build-docker-python-dev-template.yml'
5    - 'gitlab/build-docker-python-app-template.yml'
6    - 'gitlab/train-docker-python-template.yml'
7    - 'gitlab/comment-results-template.yml'
8    - 'gitlab/copy-docker-template.yml'
9
10 stages:
11 - build-docker-dev
12 - train-docker-python
13 - comment-results
14 - build-docker-app
15 - copy-image
16
17 prepare-docker-app:
18 variables:
19   MODEL_PATH: model/model_final.pth
20
21 build-docker-app:
22 variables:
23   BASE_IMAGE: docker.io/nvidia/cuda:11.8.0-cudnn8-devel-ubuntu22.04

```

Abbildung 24

Andere Basis-Images sind ebenfalls möglich (Ubuntu 20.04, 21.\*, 22.\*, 24.\* etc.). Auf einem Entwicklungslaptop/-rechner kann die Zielarchitektur ebenfalls über die Kommandozeile oder das Dockerfile angepasst und somit lokal getestet werden. Die Arbeiten für diesen Teilbeitrag werden im Deliverable D3.1-Q06-03 "KI-Module auf unterschiedlichen Rechnernetzen/-architekturen initialisiert" konsolidiert. Durch die standardmäßige Nutzung einer REST-Schnittstelle für die Modelle ist auch ein einfacher Transfer über Netzwerkgrenzen hinweg ermöglicht worden (für dieser etablierten Webtechnologie muss lediglich ein Port geöffnet werden). Die Transferierbarkeit der Algorithmen ist auch in Zusammenarbeit mit 10-CAH auf deren Infrastrukturen überprüft worden.

### 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 3.2.20: Anpassung der Input- und OutputDaten an die zu etablierenden intermodularen Schnittstellen (20-HSHL)**

#### **Ziele**

Implementierung von Pre/Post-Processing Algorithmen zur Anpassung der Daten zwischen den einzelnen Modulen.

#### **Problemstellung**

Damit verschiedene KI-Module untereinander kommunizieren können, um z.B. aufeinander aufbauende Aufgaben zu lösen, müssen die Schnittstellen bekannt und kompatibel sein. Dafür kann es notwendig sein, die Daten vor dem weiteren Austausch zu transformieren und mit dem konsumierenden Modul kompatibel zu machen.

#### **Lösungsweg und Ergebnisse**

Die Arbeiten zur KI-Plattform wurden in Q1/22 begonnen und sind erst möglich geworden, nachdem erste gute Ergebnisse, Algorithmen und Analysetools (siehe TB 2.5.15-FIT und 3.2.15-FIT) aus den UC verfügbar waren. Auf der Basis der bislang erzielten Ergebnisse in den Use-Cases und der benutzten und abstrahierten Prozesse konnte ein erster Strukturvorschlag für die KI-Plattform gemacht werden. Dieser ist in nachfolgender Abbildung dargestellt.

# System overview

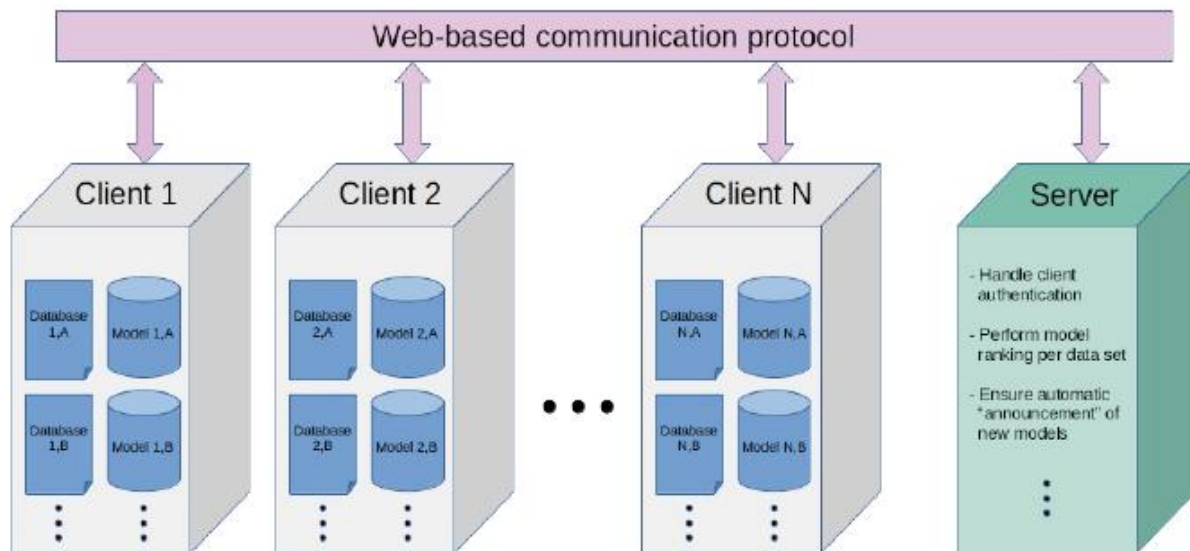


Abbildung 25: Strukturvorschlag für die KI-Plattform

Es werden Schnittstellen über die Datenbanken (DB) vorgesehen. Die DBs weisen definierte Schnittstellen und APIs auf die für einen Austausch prinzipiell Verwendung finden können.

Das Konzept zur Service-Plattform sieht für den Trainingsfall nur die Schnittstellenlimitierung auf "Dateien" vor. Durch die Heterogenität der Daten ist dies der kleinste gemeinsame Nenner – das Einlesen und Vorverarbeiten der Daten, um sie für das Modell aufzubereiten, findet Use-Case-spezifisch statt. Wenn ein Modell später deployt wird, kann es eine definierte Schnittstelle über REST anbieten, die z.B. ein Bild der Größe 100 x 100 als Vektor in transponierter Form erwartet. Welche Transformationen darüber hinaus nötig sind, um verschiedene deployte Modelle miteinander zu vernetzen, konnte erst zu einem späteren Zeitpunkt untersucht werden.

Manche Modelle enthalten bereits notwendiges Preprocessing in einer "versteckten" Schicht. Sollen mehrere "rohe" Modelle miteinander in einem Container kombiniert werden, sind Pre- und Postprocessing dort zwischen den Ein- und Ausgaben zu hinterlegen.

Zwischenzeitlich wurde das Tool mlem untersucht, um damit Modelle und Daten "verpacken" (serialisieren) zu können. Dieses Tool eignete sich potentiell auch dazu, Python-Funktionen (z.B. Pre- und Postprocessing) zu kapseln und als Container bereitzustellen. Bei einem ganzheitlichen Einsatz von mlem könnten dann Daten, Modelle und Funktionen entlang einer KI-Pipeline separat in einem einheitlichen Format abgespeichert und bereitgestellt werden. Wie bereits mehrfach erwähnt, wurde die Entwicklung dieses Tools während der Projektlaufzeit eingestellt, sodass weiter ein manuelles „Verpacken“ der nötigen Pipelines in die Container nötig war.

Vor allem im Use-Case 6 wurde mit dem Partner MicroChip weiter an einer möglichst effektiven Extraktion von Label-Informationen aus den bereitgestellten PDF-Daten gearbeitet. Die Möglichkeiten, sogenannte Vor-Annotationen aus den Daten zu generieren, wurde mithilfe von regulären Ausdrücken implementiert. Dabei wurde festgestellt, dass sich z.B. für ICs keine gemeinsame Menge an regulären Ausdrücken finden lässt, die alle Beispiele in den Trainingsdaten richtig vorannotieren. Dies musste gänzlich von Hand geschehen. Die Anpassung der Verarbeitungsschritte hin zu einem kollaborativen Ansatz zwischen den Partnern

(Domänenexperten und KI-Entwickler) inklusive Bereitstellung von Tooling und grafischen Oberflächen zum Labeln hat einige Zeit in Anspruch genommen.

In Use-Case 5 werden die Daten zunächst von den Partnern 13-EMC und 15-FIT/ENAS in ein textuelles Format überführt, welches das Ergebnis der realen Messtechnik bzw. Simulation ist. Darauf aufbauend ist ein Parser entwickelt worden, der die Daten einer weiteren Vorverarbeitung zuführt. Mithilfe von Auto-Encodern wurde die Dimension drastisch reduziert. Anschließend sind die Daten normalisiert worden, sodass sie in ein weiteres Klassifizierungs-Modell eingespeist werden konnten. Ähnlich wurde in Use-Case 3 und 6 verfahren. Die iterative Entwicklung in den Use-Cases erforderte eine kontinuierliche Anpassung der Vorverarbeitungsalgorithmen.

### **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 3.3.20: Untersuchung von ausgewählten KI-Algorithmen zur Verwendung in den geplanten KI-Modulen (20-HSHL)**

#### **Ziele**

Nutzung und Adaption von Open-Source verfügbaren Netzen. Es gibt eine Vielzahl von prämierten Netzen, die an die vorliegende Problemstellung (vor Allem im Bereich der Bildverarbeitung) adaptiert werden können. Implementierung von Transfer-Learning Trainingsmodulen zur Nutzung der ausgewählten vortrainierten CNNs. So kann bereits bestehendes Wissen genutzt und für progressivKI verfügbar gemacht werden. Vorverarbeitung der Bilddaten wie Schematics und Aufnahmen von PCBs zur Nutzung in den KI-Modulen. Die Daten werden adaptiv transformiert und projiziert um als Input zu dienen. Implementierung der Modulschnittstellen zur Nutzung von Ergebnissen als Input für weitere Module. Implementierung und Erforschung von Decision-Support auf der Basis von Cycle-GAN-Netzen. Ein NN (Generator) ist in der Lage ein Design zu entwickeln. Ein zweites, kombiniertes Netz (Diskriminator) kann das Design automatisiert bewerten und auf funktionale Richtigkeit und Sicherheit überprüfen. Erforschung des Reinforcement-Learnings in Bezug auf die implementierten KI-Module um eine teilautomatisierte, selbstlernende KI zu installieren die zur Optimierung des Designs beiträgt. Integration der erforschten KI-Module in den modularen Workflow der progressivKI-Plattform.

#### **Problemstellung**

Es existieren viele mächtige, vortrainierte und adaptierbare Open-Source Deep-Learning-Algorithmen, die auf die vorliegenden Probleme angepasst werden können. Das erfordert eine Recherche und Auswahl solcher Modelle. Darüber hinaus müssen eigenen, vorhandenen Daten an die vorgegebenen Schnittstellen dieser Modelle angepasst werden. Anschließend erfolgt eine Integration des gesamten Moduls. Es muss evaluiert werden, wie die Performance der ausgewählten, vortrainierten Modelle hinsichtlich Qualität, aber auch Laufzeiten und Effizienz ist.

#### **Lösungsweg und Ergebnisse**

Siehe dazu auch die Ergebnisse aus Use-Case 4 im TB 2.5.15-FIT und 2.5.20.

Transfer-Learning wurde in Use-Case 6 genutzt. Zu Beginn der Arbeiten ist das bekannte SSD300-Modell integriert worden. Dieses konnte allerdings nur Bildeingaben mit einer Größe von 300x300

Pixeln verarbeiten. Dazu musste ein Schematic „zerschnitten“ werden, partiell in die KI eingespeist und anschließend wieder zusammengesetzt werden, wobei doppelte Detektionen entfernt werden mussten. Dies führte zu langen Inferenzzeiten sowie instabilen Ergebnissen. Der Wechsel auf Detectron2 sowie später auf YOLOv7 ermöglichte die Erkennung von Komponenten auf dem Schematic als Ganzes. Dadurch verkürzte sich die Inferenzzeit enorm und nachgelagerte Post-Processing-Schritte wurden obsolete. Des Weiteren wurde der Wireframe-Detektor LCNN für die Linienerkennung integriert. Dieser konnte auf den eigenen Linien-Daten nachtrainiert werden. Auftretende Schwierigkeiten waren dabei vor allem Stellen, wo viele Verbindungslinien dicht an einem Punkt auftraten. Ein weiterer Wechsel hin zum Deep-LSD konnte auch hier Verbesserungen liefern.

Generell hängt das Integrieren von vortrainierten Modellen stark vom verwendeten Framework ab. In PyTorch und Tensorflow können in einer Konfigurationsdatei vortrainierte “Backends” ausgewählt werden. Die Frameworks laden diese dann in einen Cache-Ordner herunter und man kann diese dann Fine-Tunen. Darüber hinaus konnten in den Workflow der Service-Plattform auch externe Algorithmen durch Git-Submodule in die Pipelines integriert werden.

Durch die Service-Plattform unter Nutzung von dvc haben die Nutzer die Möglichkeit, verschiedene Konfigurationen beim Nachtrainieren auszuprobieren und zu tracken. Die gewählten Hyperparameter werden mit dvc geloggt und können als durchgeführte Experimente abgelegt und nachverfolgt werden.

Vor allem in Use-Case 6 ist Transfer-Learning verstärkt zum Einsatz gekommen. Eine Kombination und jeweils Adaption von YOLOv7, EasyOCR, Tesseract, LCNN and DeepLSD konnte die Hauptprobleme lösen.

Allerdings stellte sich vor allem die Texterkennung als größeres Problem heraus. Gerade in den Bereichen integrierter Schaltkreise, wo viel und kleiner Text vorhanden ist, hatten die gewählten Algorithmen Probleme. Um die Genauigkeit an dieser Stelle zu verbessern wurde ein zweistufiger OCR-Prozess implementiert:

- Bounding Box Detection: YOLOv7 erkennt die IC-Blöcke und berechnet die Koordinaten.
- Erster OCR-Durchlauf: Der Schaltplan als Ganzes wird mit EasyOCR/Tesseract analysiert.
- IC-Ausschnitt und zweiter Durchlauf: Der IC-Block wird an den Koordinaten ausgeschnitten und vergrößert. Danach erfolgt ein weiterer Durchlauf von EasyOCR/Tesseract.
- Duplettenentfernung: Da durch den zweiten OCR-Durchlauf doppelte Detektionen vorkommen können, wird Non-Max-Suppression (NSM) eingesetzt um diese Dopplungen zu entfernen. Dieser Algorithmus findet vor allem in Objekterkennungs-Algorithmen Anwendung. Er nutzt die Intersection-over-Union (IoU) Metrik um die relevantesten Textfragmente zu identifizieren und Überlappungen zu entfernen.

Durch diesen mehrstufigen Prozess konnten präzisere und stabilere OCR-Ergebnisse erreicht werden, besonders bei komplexeren, dichten Schaltplänen mit ICs.

In UC#5 werden mehrere Open-Source-Algorithmen zur Erstellung der Modelle verwendet. Dabei werden die Spektrogramme für nachfolgende Aufgaben vorbereitet. Zunächst werden die Spektrogramme normalisiert und anschließend in Trainings- und Testdatensätze aufgeteilt. Ein zentraler Teil dieser Phase ist die Datenerweiterung, bei der Trainings-spektrogramme geändert werden, um die Robustheit des Modells zu verbessern. Dazu gehört das Hinzufügen unterschiedlicher zufälliger Rauschpegel und das Anwenden zufälliger Grenzwerte auf Hoch- und Niederfrequenzbänder, um die Trainingsproben zu diversifizieren.

Um die Dimensionsreduzierung zu erleichtern, werden mehrere Modelle implementiert. Die Trainings- und Leistungsmetriken für diese Modelle werden im JSON-Format gespeichert und zur Qualitätsbewertung visualisiert. Die implementierten Modelle, die nach Bedarf erweitert werden können, umfassen:

- Autoencoder
- Locally Linear Embedding (LLE)
- Principal Component Analysis (PCA)
- Kernel PCA

In dieser letzten Phase werden Klassifizierungsmodelle mithilfe der verarbeiteten Spektrogramme und der entsprechenden Beschriftungen trainiert. Die Modelle werden mithilfe der aus der Verarbeitungsphase abgetrennten Testdaten validiert. Die Klassifizierungsergebnisse werden durch Konfusionsmatrizen angezeigt, während Trainingsverläufe grafisch dargestellt werden, um Einblicke in die Modellleistung zu geben. Der Trainingsverlauf und andere relevante Daten sind auch als JSON-Dateien für weitere Analysen verfügbar.

Die folgenden Klassifikatoren sind enthalten, mit der Flexibilität, bei Bedarf zusätzliche Modelle einzubinden:

- XGBoost
- Multi-layer Perceptron (MLP)
- Random Forest

Diese strukturierte und interaktive Pipeline ermöglicht es Benutzern, iterativ verschiedene Konfigurationen zu erkunden, um eine optimale Klassifizierungsleistung zur Identifizierung von EMV-Problemen zu erzielen und so einen umfassenden und anpassbaren Ansatz für die

### **3.3.4 Teilaufgabe 3.4: Implementation Domänenwissen**

In allen hier adressierten Entwurfssegmenten 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 3.4.20: 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 3.5.20: Unterstützung der Implementation der im Vorhaben entwickelten Meta-Algorithmen zur Qualitätssicherung der KI-Algorithmen durch Qualitätsmatrizen (20-HSHL)**

#### **Ziele**

Benutzung der Qualitätsmatrizen zur Qualitätssicherung der KI-Algorithmen.

#### **Problemstellung**


Wie die Qualität und Güte eines KI-Algorithmus bewertet werden kann, hängt hauptsächlich von dem zugrundeliegenden Problem ab. Nicht alle verfügbaren Metriken können mit allen KI-Modellen berechnet werden. Für Klassifizierungsprobleme kann beispielsweise die Accuracy, Precision oder Recall herangezogen werden, während für Regressionsprobleme R2-Score oder MSE in Frage kommen. Für Object-Detection-Aufgaben sind abermals andere Metriken vorhanden.

#### **Lösungsweg und Ergebnisse**

Anfangs fand die Gütebestimmung durch paralleles Arbeiten mit Datensätzen statt. So arbeiteten in Use-Case 4 wegen der Komplexität 18-HSU, 20-HSHL, 15-FIT und 16-FZI mit DL-Algorithmen an denselben Datensätzen parallel. Die Ergebnisse wurden jeweils diskutiert und einer kritischen Prüfung unterzogen, um so zu untersuchen, welche Prozesse und Algorithmen für das adressierte Problem in Use-Case 4 geeignet sind und inwieweit diese Erkenntnisse in eine einheitliche Gütebewertung von Modellen einfließen kann. Die entsprechende Behandlung der Qualitätsmatrizen konnte erst erfolgen, nachdem das bereits vertraglich gebundene Personal seine Arbeit in Q1/22 aufgenommen hatte.

Die Use-Cases bestimmten im weiteren Verlauf, welche Metriken sinnvoll zur Überprüfung der Qualität genutzt werden konnten. In Use-Case 4 handelte es sich um ein Regressionsproblem, bei welchem ein Modell einen maximalen Fehler minimieren sollte. Daher sind hier der "Max Error" und "Mean Absolute Percentage Error" in Frage gekommen.

Use-Case 5 ist ein Klassifikationsproblem. In diesem Fall ergab eine „Confusion-Matrix“ Sinn, welche visualisiert, wie akkurat das Modell die Klassen auseinanderhalten kann. Das Modell in diesem Use-Case hat zunächst auf den Simulationsdaten eine Eingabe von 100 Werten bekommen und konnte 22 verschiedene Klassen differenzieren (auf den ersten Simulationsdaten). Die nachfolgende Abbildung zeigt die entsprechende „Confusion-Matrix“.



**Abbildung 26**

In Use-Case 6 sind die die Metriken hauptsächlich der „Mean-Average-Precision“, der verschiedene weitere Metriken wie Accuracy oder „Intersection over Union“ für Object-Detection-Aufgaben kombiniert.

In Use-Case 3 sind neben den „Mean-Squared-Errors“ für das Trainieren der Autoencoder auch eigene Optimierungsmetriken eingeführt worden. Dabei wurde die Summe der verschiedenen S-Parameter und Spektrums-Abweichungen berechnet. Ein unplausibler Wert wird hoch bestraft, indem der Error auf einen sehr hohen Wert gesetzt wird. Optimiert wird hier hin zu einem Wert, der diesen eigens erstellten Loss minimiert.

```

if np.min(prediction_probe1)<0 or np.min(prediction_probe3)<0:
    return 2000000
if np.max(prediction_S11)>0:
    return 2000000
penalty = (np.sum(prediction_probe1)*self.alpha_probe1_max) + (np.sum(prediction_probe3)*self.alpha_probe3_max) +
           (np.sum(prediction_S11)*self.alpha_S) + (np.sum(prediction_S33)*self.alpha_S) + (distances*self.alpha_distance)
return penalty

```

**Abbildung 27**

Metriken können pro Use-Case definiert werden. Diese müssen als strukturiert in einer Datei (json, csv) abgelegt werden. Mit dem Tool dvc können dann Metriken zwischen verschiedenen Modell/-Coderevisionen verglichen und getracked werden.

Neben der jeweils passenden Metrik ist es ebenfalls nötig gewesen, um die Qualität zu gewährleisten, dass sich durch Anpassungen in der Modellpipeline keine Verschlechterungen der Metriken ergeben. Diese müssen lediglich strukturiert in einer Datei (json, csv) abgelegt werden. Mit dem Tool dvc können dann Metriken zwischen verschiedenen Modell/-Coderevisionen verglichen und getracked werden.

Path	Metric	f22e70ed415c5f25a4139ed848df23612995007b	workspace	Change
metrics/test_metrics.json	accuracy	-	0.99733	-
metrics/test_metrics.json	f1_score	-	0.99733	-
metrics/test_metrics.json	loss	-	0.02031	-
metrics/test_metrics.json	precision	-	0.99747	-
metrics/test_metrics.json	recall	-	0.99728	-
metrics/test_metrics.json	time_seconds	-	9.08204	-
metrics/train_metrics.json	accuracy	-	0.99978	-
metrics/train_metrics.json	f1_score	-	0.99978	-
metrics/train_metrics.json	precision	-	0.99987	-
metrics/train_metrics.json	recall	-	0.99966	-
metrics/train_metrics.json	time_seconds	-	891.14057	-
metrics/train_metrics.json	val_accuracy	-	0.99732	-
metrics/train_metrics.json	val_f1_score	-	0.99732	-
metrics/train_metrics.json	val_precision	-	0.99732	-
metrics/train_metrics.json	val_recall	-	0.99726	-

**Abbildung 28**

Hier sieht man die verwendeten Metriken in Use-Case 5 und einen Vergleich zwischen der Version im Workspace und einem anderen Commit. Dazwischen gibt es keine Unterschiede. Durch diesen Mechanismus kann das Mergen von Commits mit einer schlechteren Performance verhindert werden. Dabei handelt es sich jedoch lediglich um Metriken, die während eines Trainings erzeugt und bewertet werden. Damit über einen generelleren Meta-Algorithmus die Performance eines Modells gegeben eines z.B. neuen Datensatzes bewertet werden und dieses Modell dann ausgewählt werden kann, sind weitere Anpassungen und Integrationsarbeiten vor allem mit dem Partner 18-HSU notwendig gewesen.. Dazu werden verschiedene KI-Services als Container über die Service-Plattform „gebaut“ und über ein docker-compose-File bereitgestellt, sodass sie einfach heruntergeladen werden können. Beispielhaft sieht das compose-File so aus, es wurde im Laufe der KNV erweitert:

```

services:
  test1:
    image: registry.fit.fraunhofer.de/symila/progressiveai/metaalgorithm/test:train-develop-remote

```

```
container_name: test1
ports:
  - 8000:8000
test2:
  image: registry.fit.fraunhofer.de/symila/progressiveai/metaalgorithm/test:train-develop-remote
  container_name: test2
  ports:
    - 8001:8000
test3:
  image: registry.fit.fraunhofer.de/symila/progressiveai/metaalgorithm/test:train-develop-remote
  container_name: test3
  ports:
    - 8002:8000
```

Inhaltlich geben diese Container die Trainingsmetriken über eine REST-Schnittstelle aus, die in Abschnitt 2.4.20 definiert sind.

### **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 3.6.20: Integration der mathematischen Metriken zur Bestimmung von Qualität und Güte einzelner KI-Algorithmen (20-HSHL)**

### **Ziele**

Anwendung der mathematischen Metriken auf die Ergebnisse der Algorithmen und deren Kombinationen.

### **Problemstellung**

Die Schwierigkeit ist, die Leistung von Modellen des maschinellen Lernens effektiv zu bewerten und zu quantifizieren, insbesondere bei Aufgaben wie der Objekterkennung und Wireframe-Erkennung.

### **Lösungsweg und Ergebnisse**

Ein Ansatz zur Bewertung und Beschreibung des Modells besteht darin, eine Metrik zu erstellen, die seine Genauigkeit und Leistung quantifiziert. Einige dieser Metriken wurden in UC4 skizziert und erklärt und sind bereits mehrfach im Bericht benannt worden.

Diese Metriken können mit DVC (Data Version Control) protokolliert und innerhalb der DVC-Pipeline weiterverarbeitet werden.

In UC6 haben wir eine zusätzliche Metrik eingeführt, um die Leistung unseres Modells zu bewerten. Zusätzlich zur Verwendung von Intersection over Union (IoU) zur Verbesserung der Klassifizierungsgenauigkeit des YOLOv7-Netzwerks haben wir IoU als primäre Bewertungsmetrik übernommen. IoU ist ein kritisches Maß bei der Objekterkennung und -segmentierung, da es die Überlappung zwischen zwei Regionen quantifiziert und normalerweise die Grundwahrheit (GT) mit der vorhergesagten (erkannten) Region vergleicht.

Für das LCNN-Modell (Line Convolutional Neural Network) verwenden wir „jmap“ für Drahtgittererkennungsaufgaben. In diesem Zusammenhang ist eine „Knotenkarte“ eine Zwischendarstellung, die dabei hilft, Schlüsselpunkte oder Knoten innerhalb drahtgitterartiger Strukturen wie Gebäuden oder anderen Objekten zu identifizieren. Diese Knoten sind für die

Drahtgittererkennung von entscheidender Bedeutung, da sie wichtige Schnittpunkte oder Ecken von Linien markieren, welche die gesamte Struktur definieren.

## **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 Plattformausrüstungen (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 Plattformausrüstungen 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 Plattformausrprägungen #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 Plattformausrprägungen #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 erstellten KI-Module und die darauf basierenden KI-Modul Plattformen von Nutzern aus kleinen und mittleren Unternehmen zur Lösung ihrer Entwurfsaufgaben verwendet werden können.

Für diese Nutzer war im Vorhaben progressivKI vorgesehen:

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

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

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

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

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

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

- Erstellung von Test- und anwendungsbezogenen UseCases/Referenzsystemen (HW) zur Überprüfung der erreichbaren Entwurfsqualität.
- Die Spezifikation und der Entwurf der geplanten UseCases/Referenzsystemen (HW) erfolgt in Verbindung mit AP 1 - 3. Um die Effektivität der neuen KI-orientierten Entwurfsmethoden, der KI-Modelle nachzuweisen, sind mittels der UseCases/Referenzsysteme (HW) Simulations- und Messergebnisse (Ergebnisse aus AP 2 und AP 3) zu vergleichen (Gültigkeitsbereiche der Plattformausrüstungen für die Anwendungsbereiche #1 - #2).

- Nachweis des vorgegeben Systemverhaltens anhand). der ausgewählten Referenzsysteme (HW).
- Validierung/-verifikation der KI-Modelle (Festlegung der Testkonfiguration entsprechend Do-E-Prinzipien und Testdurchführung);
- Proof-of-Concept zunächst mit generischen und dann mit realen Fragestellungen
- Evaluationen und Iterationen von KI-Werkzeugen und KI-Modellen
- Einhalten von gesetzlichen Richtlinien durch die implementierten KI-Module bei Entwurfskonflikten
- Ergebnisüberprüfung hinsichtlich der mittels KI-Modulen gelieferten Analyse von Entwurfsentscheidungen
- Maschinelle Lernalgorithmen mit unterschiedlicher Komplexität auf Brauchbarkeit überprüfen (|maßgeschneiderte| Algorithmen)
- Überprüfung der direkten Übertragbarkeit angelernter Algorithmen auf andere Problemklassen
- Proof-of-Concept und prototypische Realisierung eines fachspez. Chatbots zur Unterstützung des PCB-Entwurfs (AW#1) im Rahmen der KNV
- Überprüfung, ob die erstellten KI-Module und deren Plattformausrprägungen insbesondere auch von Nutzern kleiner und mittlerer Unternehmen zur Lösung ihrer Entwurfsprobleme verwendet werden können. Gleichzeitig muss geprüft werden, ob die gewählten KI-Ansätze ausreichend modular sind, um sich auch an die Prozesse von Großkunden anpassen zu lassen.
- Umfassende Dokumentation der gefundenen Entwurfsentscheidungen hinsichtlich der für die UseCases erzielten Ergebnisse.

#### **Geplante Ergebnisse von AP4 waren:**

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

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

Dieses Teilarbeitspaket (TA) hatte die Entwicklung von der KI-Plattform Anwendungsebene #1 PCB-Entwurf zum Ziel. Der Einsatz von KI-Methoden zur Beschleunigung des PCB-Entwurfs in der Elektronik ist für die künftige Entwicklung von funktional-sicheren komplexen elektronischen Systemen (Stichwort Systemintegration Automotive bzw. Industrieelektronik u.a.) von entscheidender Bedeutung. Bedingt durch die zu beherrschende hohe Entwurfskomplexität wurde

hier ebenfalls eine deutliche Wirkung des KI-Einsatzes hinsichtlich der Entwicklungsziele |First Time Right| und |Time2Market| sowie |Sicherstellung der gewünschten Systemfunktion (funktionale Sicherheit)| erwartet.

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

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

Aus den zwei notwendigen Teil-Ansätzen, einem Entwurfs- und einem Analysesystem wurde dann ein kombiniertes System von KI-Modulen abgeleitet werden (progressiv KI-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 4.1.20: Bedarfsgetriebene Anpassung von KI-Algorithmen für die Anwendungsebene #1 PCB-Modul (20-HSHL)**

## Ziele

Die Algorithmen müssen so erweitert werden, dass die speziellen Datenformate (hier aus dem PCB-Bereich) analysiert und verarbeitet werden können. Synergieeffekte aus AW #2 aufbereiten und nutzen. Die heterogene Datenlage wird herausgearbeitet und bewertet.

## Problemstellung


Optimierung des Trainingsprozesses neuronaler Netze durch Anpassung an die effizientere Verarbeitung unterschiedlicher Datentypen und Entkopplung dieser Prozesse vom Rest der Pipeline.

## Lösungsweg und Ergebnisse


Dabei wurden konkrete Schritte unternommen, die die Bearbeitung von UC#3 (gemeinsam mit 15-FIT, 15-FIT/ENAS und 01-Bosch) zeigt:

Im UseCase#3 erhielten wir von den Projektpartnern den ersten Datensatz in Form von 401 Leiterplattenlayouts („Printed Circuit Boards“ – PCBs) in Bildgröße (852x436), wobei für jedes PCB die Stärke der elektrischen Feldverteilung (Dezibel über Frequenz) an der Position einer virtuellen Feldprobe mittels eines Simulators („CST“) ermittelt und ebenfalls zur Verfügung gestellt wurde. Das Frequenzspektrum wurde an 1001 Stützstellen, verteilt über den Bereich [0;6] GHz, abgetastet.

Als erster Schritt wurde in Absprache mit den Projektpartnern anhand der bereitgestellten Daten ein Deep Neural Network (DNN) trainiert, welches eine Regression von den vorgegebenen PCB-Layouts auf die entsprechenden Frequenzspektren durchführt. Zur Umsetzung des beschriebenen DNN-Konzepts wurde die weit verbreitete Softwarebibliothek Keras3 verwendet.



a) "Printed circuit board" (PCB), exemplarisch (bereitgestellt von 01-Bosch)



b) Frequenz-Spektrum, exemplarisch

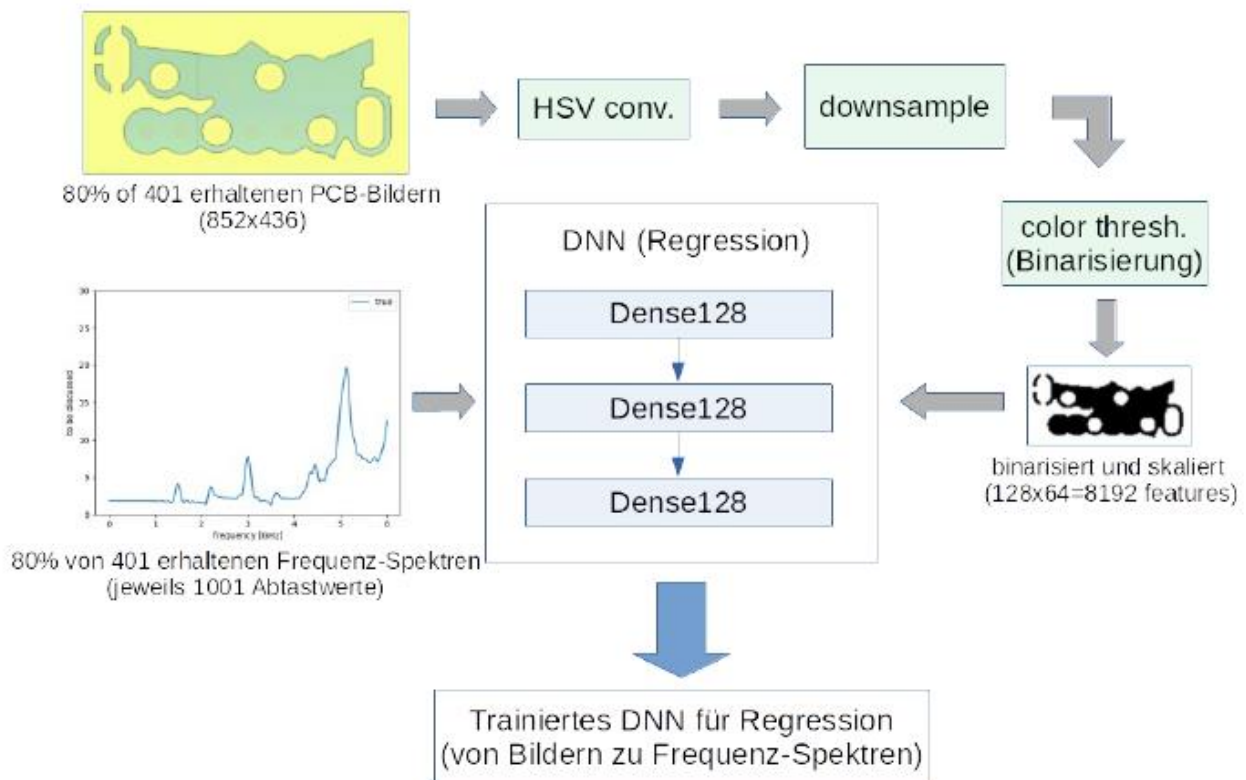
Abbildung 29

Aufbereitung der Trainingsdaten: Die PCB-Bilder wurden zunächst mittels einer HSV-Farbraumkonvertierung erstellt, gefolgt von einem Skalierungsprozess, der die Layouts auf die

Dimensionen (128x64) reduzierte, um deren Verarbeitung im DNN zu beschleunigen. Nach der anschließenden Binarisierung dienten die Layouts als Eingangsdaten („Features“) für ein dreischichtiges, voll verbundenes Deep Neural Network. Vor der Übertragung in das Netz wurden die Layoutdaten im Bereich [0;1] normalisiert und die Bildmatrizen in einen „Feature-Vektor“ der Länge 8192 „vektorisiert“. Abbildung 2 fasst die skizzierten Schritte schematisch zusammen.


Die einzelnen Schichten des DNN bestehen jeweils aus 128 „künstlichen Neuronen“ (Einheiten); als Aktivierungsfunktionen werden in den Zwischenschichten „hyperbolischer Tangens“ (tanh) und in der Ausgabeschicht eine lineare Aktivierung verwendet. Die Eingabeebene des DNN akzeptiert Eingabevektoren der Länge 8192, die Ausgabebene besteht aus 1001 Einheiten, die eine direkte Inferenz diskretisierter Frequenzspektren ermöglichen.

Um die Qualität der Inferenzleistung des DNN zu beurteilen, wurde das trainierte Netzwerk auf den Testdaten verwendet, um Frequenzspektren für jedes Test-PCB zu schätzen.



**Abbildung 30**

Durch den Vergleich der regressionsbasierten Schätzungen der Spektren mit den bereitgestellten „Ground Truth“-Simulationsergebnissen ist ersichtlich, dass die DNN-basierte Regression von PCB auf Frequenzgang für den erhaltenen Datensatz akzeptable Ergebnisse liefert. Hierbei ist zu beachten, dass „Ausreißer“ in den Daten vom System nicht präzise geschätzt werden können, was zu erwarten war.



**Abbildung 31**

Die verwendete Strategie des vollvernetzten neuronalen Netzes diente lediglich ersten Experimenten und wird durch „Convolutional Neural Networks“ (CNNs) ersetzt. Dadurch ließ sich eine Skalierung und der damit verbundene Verlust von Bildinformationen vermeiden. Des Weiteren wurden die bereitgestellten Daten hinsichtlich der Nutzbarkeit für das DNN-Training angepasst, um beispielsweise das Ausreißerproblem zu adressieren und die Regressionskapazitäten des DNN über einen größeren Eingangsdatenbereich nutzbar zu machen.

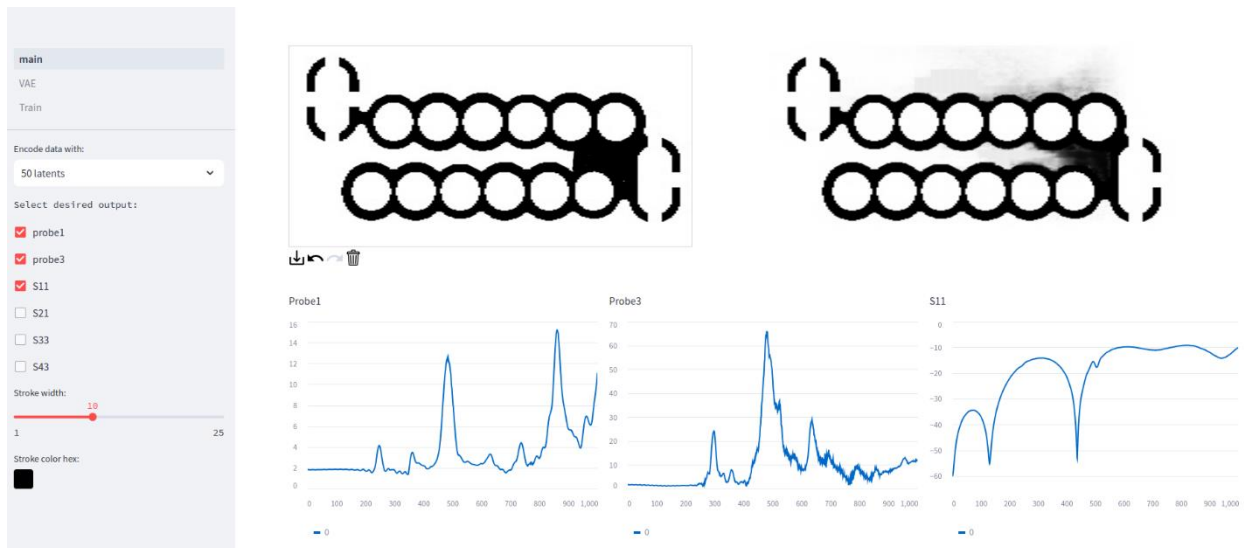
Innerhalb von UC #3 und #5 wurde noch an Algorithmen gearbeitet, die sowohl Bilddaten als auch numerische Daten verarbeiten können. Die Ergebnisse wurden laufend evaluiert, sodass bei unzureichender Performance oder Erweiterung des Problems (höhere Klassenanzahl etc.) auch neue vortrainierte Netze oder andere Algorithmen ausprobiert werden können. Die Eingangsdaten werden dabei stets in das für den Algorithmus benötigte Eingangsformat überführt. Bei Bilddaten bedeutet dies in der Regel eine Dimensionsreduzierung durch Skalierung oder Binarisierung, bei numerischen Daten eine Dimensionsreduzierung durch PCA oder VAE oder andere Merkmalsanalyse. Da neuronale Netzwerke von Natur aus numerische Daten verarbeiten können, beschränkt sich die Anpassung normalerweise auf Dimensionsreduzierung oder andere Vorverarbeitungsschritte, die den Datentyp nicht ändern.

Bei allen Prozessen wurde das Parsen der Ausgangsdaten vom Rest der Pipeline entkoppelt. Dies gibt uns mehr Kontrolle über die Rohdaten und ermöglicht es uns, dies als Ausgangsprozess beizubehalten, wenn der Benutzer weitere Daten bereitstellt. Bisher haben wir mit Daten in vielen Formaten gearbeitet, darunter PDF, TXT, CSV und JPG. Die Ausgangsdaten müssen eine Reihe von Kriterien erfüllen, um die Analyse der Rohdaten auszulösen.

Die Vorverarbeitungsphase unterscheidet sich erheblich von einem Datentyp zum anderen. Bei der Arbeit mit Bilddaten geht es bei der Vorverarbeitung darum, so viele Details und Auflösungen wie möglich beizubehalten und gleichzeitig die Bilddimensionalität zu reduzieren, um ein schnelles und effizientes Training und Inferenzen zu ermöglichen. Die Vorverarbeitung kann das Anwenden von

Bildfiltern, Größenanpassung, Zuschneiden und Verzerrern umfassen. Und natürlich ist die Datenbereinigung und Merkmalsextraktion ein großer Teil der Vorverarbeitungspipeline.

Die verschiedenen Phasen werden durch die Nutzung der Serviceplattform erleichtert, auf der wir die verschiedenen Phasen mithilfe von DVC steuern können. Für zukünftige Arbeiten sollten dedizierte Container für die verschiedenen Datenverarbeitungsphasen verwendet werden.



**Abbildung 32**

Die obige Abbildung veranschaulicht die Ergebnisse für UC #3 und zeigt die Integration unserer Modelle in eine benutzerfreundliche Oberfläche. Die GUI ermöglicht es Benutzern, ihre gewünschte Grundebene zu definieren, indem sie diese direkt auf die Oberfläche zeichnen. Sobald die Grundebene angegeben ist, aktiviert das System automatisch die relevanten Modelle, um die entsprechenden EMV-Emissionsdaten für den Benutzer zu generieren.

Ziel von UC#5 ist es, eine interaktive Pipeline zu erstellen, die es Benutzern ermöglicht, mit verschiedenen Konfigurationen zu experimentieren, um optimale Klassifizierungsergebnisse bei der Identifizierung von EMV-Problemen (elektromagnetische Verträglichkeit) auf der Grundlage von elektrischen Fernfelddaten zu erzielen. Für die Generierung von Trainingsdaten wird ein hybrider Ansatz verfolgt, der Fernfeld- und Nahfeldmessungen sowie elektromagnetische Feldsimulationen umfasst. Die größte Herausforderung besteht darin, die Datenformate zu standardisieren und die einzigartigen Merkmale jeder beteiligten Methode zu berücksichtigen.

Data Version Control (DVC) is utilized to construct, execute, and deploy this data pipeline effectively. DVC allows for the definition of sequential processing stages, where each stage has clearly defined input and output dependencies and configuration settings. By caching results, DVC minimizes redundant computations when inputs remain unchanged, optimizing performance and efficiency.

Below is an overview of the implemented pipeline and its stages:

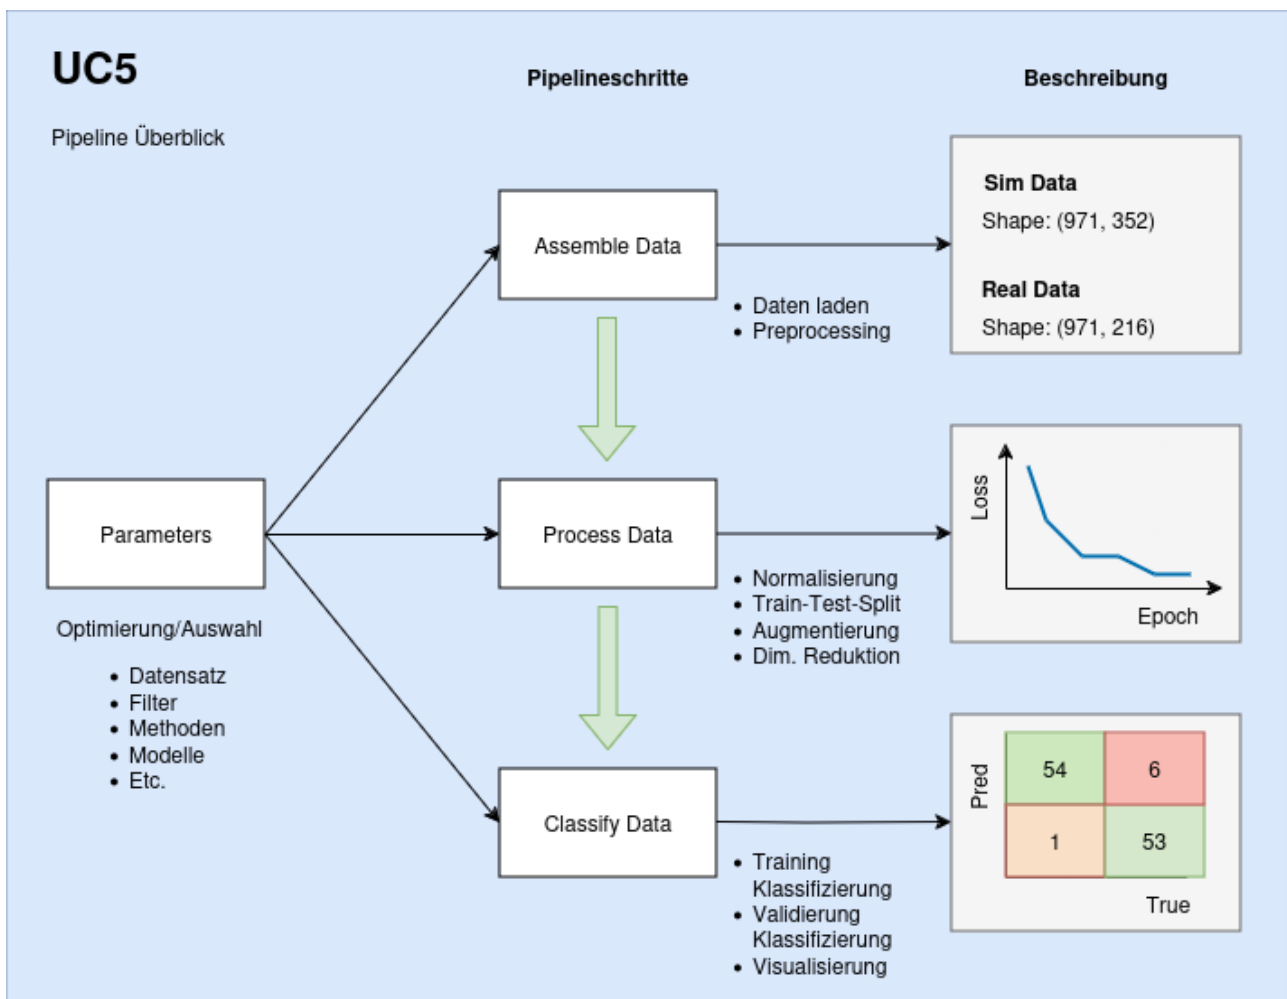


Abbildung 33

Der erste Schritt ist die Validierung aller Eingabeparameter auf der Grundlage strukturierter Datenklassen. Diese Phase gewährleistet eine robuste, effiziente und fehlerfreie Ausführung über die gesamte Pipeline hinweg und ermöglicht eine zuverlässige Datenverarbeitung und Modellschulung zur Identifizierung von EMV-Problemen.

In diesem Schritt werden Daten von einem angegebenen Speicherort (z. B. S3) gesammelt. Für UC5 werden zwei Arten von Daten berücksichtigt: simulierte und reale Messungen. Die Auswahl und das Laden dieser Datentypen hängen von den angegebenen Parametern ab, die zu Beginn der Pipeline validiert werden, um eine frühzeitige Fehlererkennung und eine optimierte Verarbeitung sicherzustellen.

Ein Vorverarbeitungsschritt harmonisiert die Daten, was aufgrund von Unterschieden in Abtastfrequenzen und Metadatenformaten unerlässlich ist. Darüber hinaus weisen reale Messdaten häufig Basislinienverschiebungen auf, die korrigiert werden müssen, um die Vergleichbarkeit zu gewährleisten. Die Ausgabe des Schritts „Daten zusammenstellen“ umfasst harmonisierte Spektrogramme aus simulierten und realen Daten sowie Beschriftungen, die durch die ausgewählten Parameter definiert sind.

### **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.

#### **Teilbeitrag 4.2.20: Bedarfsgetriebene Anpassung von KI-Algorithmen für die Anwendungsebene #2 IC/Sensorik (20-HSHL)**

##### **Ziele**

Die Daten aus dem Bereich des IC-Entwurfes sind von den bisher betrachteten Formaten verschieden, so dass auch hier eine Adaption der Algorithmik notwendig ist. Nur dann ist Einlesen von Datensätzen und damit die Verfügbarkeit der Daten für den eigentlichen KI-Prozess möglich.

##### **Problemstellung**

Sicherstellung einer klaren Trennung zwischen der anfänglichen Datenanalyse und den nachfolgenden Pipeline-Phasen.

### **Lösungsweg und Ergebnisse**

In UC#4 ist es das Ziel, gemeinsam mit unseren Partnern 03-IFAG, 16-FZI, 18-HSU und 15-FIT eine interne Serviceplattform zu schaffen, die auch die Integration von KI-Modulen zum Ziel hat. Dies ist zugleich ein wichtiger Test- und Demonstratorfall für die übergeordnete Serviceplattform, die in UC#8 umgesetzt wird. Zur Verifikation und Prozessentwicklung werden derzeit parallele neuronale Netze implementiert. Anwendungsfälle wie UC#6 und UC#4 verwenden heterogene Eingaben wie Bilddaten oder numerische Daten. Je nach Auswertung und neuem Modell fand eine ständige Anpassung statt. Erst wenn sich mehrere Anwendungsfälle auf einen bestimmten Algorithmus geeinigt hatten (und auch klar war, welche Modellarchitektur die besten Ergebnisse liefert), konnte geprüft werden, ob Vorverarbeitungs- oder Leseschritte für Daten standardisiert werden können. Ist dies jedoch nicht der Fall, bietet das Serviceplattformkonzept genügend Freiraum, um individuelle Lösungen auszuarbeiten.

In allen Operationen haben wir eine klare Trennung zwischen der anfänglichen Datenanalyse und den nachfolgenden Pipeline-Stufen umgesetzt. Diese Trennung bietet mehr Flexibilität und Kontrolle über die Rohdaten und ermöglicht es uns, zusätzliche, vom Benutzer bereitgestellte Daten effizient zu verwalten. Derzeit haben wir erfolgreich Daten in verschiedenen Formaten verarbeitet, darunter PDF, TXT, CSV und JPG. Die Analyse der Rohdaten wird jedoch selektiv ausgelöst, d. h. der Prozess wird nur aktiviert, wenn die Eingabedaten bestimmte Kriterien erfüllen. Dieser Ansatz stellt sicher, dass der Analyseprozess unter geeigneten Bedingungen gestartet wird, wodurch die Gesamteffizienz optimiert wird.

## **3.5 Arbeitspaket 5: Projektmanagement & Dissemination**

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

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

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

zusammenbringen; ....) auch über die Projektlaufzeit hinaus die erforderliche Beachtung geschenkt wird.

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

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

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

Ferner leisteten die Partner gemeinsam mit dem ProjektOffice Zuarbeit für die Ergebnisverbreitung und Akzeptanzgewinnung, die durch andere Teilprojekte federführend geleistet wurde (z.B. durch Bereitstellung von Anschauungsmaterial zur Funktionsweise der bereitgestellten KI-Algorithmen). Einen großen Anteil wurden die Forschungspartner zur Dokumentation der Projektergebnisse gegenüber der KI- und MikroelektronikCommunity durch Publikationen 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 5.2.20: Ergebnisvorbereitung zur OpenSource Nutzung (20-HSHL)**

#### **Ziele**

Nutzungsrecherche für OpenSource KI-Module. Dokumentationsmaterial in Text, Film und Internetpräsentation, Erstellung eines kompletten Lehrgangsmaterials für potentielle assoziierte Partner. Präsentation für Industrievertreter und Multiplikatoren. Durchführung wissenschaftlicher Workshops zur Ergebnisdiskussion. Forschungsergebnisse werden auf einschlägigen Konferenzen präsentiert und veröffentlicht.

#### **Problemstellung**

Um eine weitere Nutzung zu unterstützen sowie die Ergebnisse dem entsprechenden Fachpublikum näher zu bringen, sollen während der Projektlaufzeit passende Materialien und Veröffentlichungen bereitgestellt werden. Darüber hinaus sollte die Anfertigung von Papern und Workshops fokussiert werden. Lizenzformen der verwendeten Modelle muss laufend überprüft werden, um die Weiterverwertung nicht einzuschränken.

#### **Lösungsweg und Ergebnisse**

Diese Arbeiten konnten erst begonnen werden, nachdem entsprechende Ergebnisse in den Use-Cases vorlagen. Durchgeführt wurden mehrere Teilnahmen an Konferenzen mit anschließenden Publikationen, wie z.B. der „Kleinheubacher Tagung 2022/2023“ oder der „EMC Europe 2024“. Die Lizenzformen (z.B. Apache 2, MIT, AGPL) wurden laufend kontrolliert und überprüft, ob eine kommerzielle Verwertung der Ergebnisse behindert werden könnte. Poster und weitere Materialien wurden fortlaufend angefertigt bzw. aktualisiert und bei Bedarf bereitgestellt.

### **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**

### **20-HSHL**

#### **Ausgangslage**

Die Hochschule Hamm-Lippstadt betreibt zusammen mit der Fraunhofer-Gesellschaft e.V. , namentlich mit dem Fraunhofer-Institut FIT ein Anwendungszentrum, so dass die Arbeiten beider Partner – 15-FIT/ENAS und 20-HSHL eng abgestimmt laufen konnten und das, unter Ausnutzung von Synergien. Während zu Beginn des Projektes die in der KI durch die HSHL genutzten Bereiche vor allem die Bildverarbeitung war, konnte das Instrumentarium stark erweitert und auf andere Bereiche ausgedehnt werden. So darf an dieser Stelle erwähnt werden, dass der Aufbau von

Datenworkflows und Tollchains zur Bewertung von Daten in den Fokus gekommen ist – neben dem Ausbau der KI-gestützten (modernen) Bildverarbeitungsalgorithmen. Die Zusammenarbeit war vor allem eng mit folgenden Partnern: 15-FIT/ENAS, 18- HSU, 10-CAH, 13-EMCTest, 03-IFAG, 05-MCH.

### **Ergebnisse in progressivKI**

Im Projekt wurden die Bildverarbeitungsalgorithmen klassischer Art fast vollständig durch KI-basierte Algorithmen und Modelle ersetzt. An dieser Stelle wichtigstes Ergebnis ist sicherlich der Bunch von Möglichkeiten zur Übersetzung von Bilddaten, die ein Layout repräsentieren in eine digital verfügbare Netzliste als Input für eine Modellverbesserung. Ferner ist die HSHL an den Prozessketten (siehe 15-FIT/ENAS) beteiligt und zwar dort, wo Daten in Trainingssysteme einfließen und charakterisiert werden müssen. Aus diesem Grunde wurden durch die HSHL weitere charakteristische Daten von außen (UA-TUHH) in das Projekt hinein organisiert. Die Trainingsaktivitäten wurden dann vor allem durch den Partner 18-HSU ausgeführt. Die Ergebnisse (Modelle, KI-Umgebungen) sind sehr unterschiedlich, werden aber alle eingesetzt. Nicht alle Modell-Erzeugungsaktivitäten (Training neuronaler Netze) konnten nur mit Daten durch die Partner erzielt werden. Eine nicht unerhebliche Anstrengung floss in die Abbildung von Bedarfen und in die Prüfung und Einbeziehung von Daten aus dem Mittelstand (KMU). Neben der ostwestfälischen Region wurde vor allem auch der Bereich Südwestfalen mit seinen hidden Champions mit großem Engagement und Erfolg bearbeitet. Die dabei umgesetzten UA waren von sehr großem Nutzen und schlussendlich essenziell. Die erzielten Modelle sind anwendbar und decken den Bedarf von KMU, wenn eine Transformation der Ergebnisse in den Ablauf der KMU erfolgt.

### **Nutzen und Verwertbarkeit**

Die erzielten Modellergebnisse sind von hervorragender Qualität, was durch Veröffentlichungen unter Beweis gestellt werden konnte. Diese Ergebnisse werden in weiteren Projekten und Vorhaben, aber auch in der Lehre verwertet. Die sehr guten Modelle (EMV, Geometrieoptimierung, Digitalisierung von Bildern zu Netzlisten, Transformation von Requirements,...) können in einem Transformationsprozess in den Mittelstand hinein implementiert und so dort verwertet werden. Die an der Hochschule angesiedelten Transferprojekte und -Kanäle (z.B. Transferverbund Südwestfalen) werden verwendet, um eine Vielzahl von Firmen anzusprechen. Zusammen mit der HSHL-Akademie wird ein Format entwickelt, das die Nutzung der Ergebnisse unterstützen und weitere Bedarfe der KMU identifizieren kann. Eine Verwertung durch weitere Veröffentlichungen und in weiteren Vorhaben ist selbstverständlich.

## 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“, oral presentation at Kleinheubacher Tagung 2022
- [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“, 30.FED Konferenz, 29./30. September 2022, Potsdam
- [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
- [24] Romy Salameh, Markus Bücken, Amir Wallrabenstein, „ ML-based Classification of S-Parameters to Support the Design of High-Speed Electronics“, Vortrag, Kleinheubacher Tagung 2022

## **2023**

- [25] 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/>
- [26] 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
- [27] 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
- [28] 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
- [29] 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.
- [30] 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.

- [31] 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
- [32] 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
- [33] 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)
- [34] 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)
- [35] 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)
- [36] 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
- [37] 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 2023
- [38] 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
- [39] 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)
- [40] 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)
- [41] I. Cahani and M. Stiemer, „Autoencoders in the Machine Learning Supported Design of PCBs“, 2023 Kleinheubach Conference. IEEE, 2023.
- [42] Z. Nehzi, 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).
- [43] M. Schierholz, Z. Nehzi, M. Stiemer and Ch. Schuster, „PCB based Power Delivery Network Analysis Using Transfer Learning and Artificial Neural Networks“, in Proc. 28th IEEE Workshop on Signal and Power Integrity 2024 (submitted).
- [44] M. Stiemer, R. Ueltzen, I. Cahani, Z. Nehzi, 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.
- [45] Rebecca Ueltzen, Marcus Stiemer, Ralf Brüning, „Parameteridentifikation von Schaltplänen und Explainable Artificial Intelligence“, poster presentation at 5. progressivKI workshop Karlsruhe, 2023.
- [46] Ali Ahari, Ilda Cahani, Denis Hemker, Christian Rabbi Garaza, „Machine Learning Pipeline in Use Case #4“, poster presentation at 5. progressivKI workshop Karlsruhe, 2023.

- [47] Rebecca Ueltzen, Marcus Stiemer, Ralf Brüning, „Explainable Artificial Intelligence am Beispiel für Parameteridentifikation von Schaltplänen“, poster presentation at 6. progressivKI workshop Hamburg, 2023.
- [48] 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.
- [49] 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.
- [50] Sanchez Lopera, Daniela, Ishwor Subedi and Wolfgang Ecker, „Using Graph Neural Networks for Timing Estimations of RTL Intermediate Representations“, MLCAD 09.2023
- [51] E. S. Alcorta et al., „Special Session: Machine Learning for Embedded System Design“, CODES+ISSS
- [52] 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
- [53] 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
- [54] 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.
- [55] 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.
- [56] D. Hemker, J. Maalouly, H. Mathis, R. Klos, E. Ramanan: "From Schematics to Netlists - Electrical Circuit Analysis Using Deep Learning Methods", Kleinheubacher Tagung 2023
- [57] 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)
- [58] 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
- [59] 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
- [60] 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.
- [61] 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.

- [62] Öffentlichkeitsarbeit über eigene Website; Jürgen Kutter, Michael Kemkes: <https://www.innozent-owl.de/foerderprojekte-erkunden/progressivki/>
- [63] 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/>
- [64] 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
- [65] Ilda Cahani, and Marcus Stiemer, “Mathematical optimization and machine learning to support PCB topology identification”, Advances in Radio Science 21, 25-35, 2023.

## 2024

- [66] Novacek, Aharie, Müller, Reiter, Viehl, Bringmann. „Ontology-supported AI Model and Dataset Management.“ ICIT24 [Im Review]
- [67] Marcel Olbrich, Sven Lange, Dennis Hemker, Jad Maalouly, Jürgen Kutter, “AI Assisted EMC Interference Recognition”, 2. progressivKI Tag, Hamm, 28.02.2024
- [68] 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
- [69] 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
- [70] 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.
- [71] 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).
- [72] 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.
- [73] 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.
- [74] 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>

- [75] 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>
- [76] D. Hemker, J. Maalouly, P. Brus, C. Garaza, V. Esen, A. Ahari, J. Novacek, S. Reiter, T. Müller, R. Ueltzen: „Best Practices for MLOps in IC Design: A Case Study” [https://www.researchgate.net/publication/386134735\\_Best\\_Practices\\_for\\_MLOps\\_in\\_IC\\_Design\\_A\\_Case\\_Study](https://www.researchgate.net/publication/386134735_Best_Practices_for_MLOps_in_IC_Design_A_Case_Study)
- [77] Ralf Brüning, “AI-Supported PCB Design – Revolution or Evolution? Where we are today, Challenges, Opportunities and Limitations - An EDA-Vendor Point of View”, 2. progressivKI Tag, Hamm, 28.02.2024
- [78] Ralf Brüning, “The Quest for Automation - AI in Electronic-Design – Disruption or Evolution?”, ADTC 2024/edaForum2024, 9.-10. April 2024 (Dresden), Keynote-Präsentation
- [79] Werner John; Emre Ecik; Nima Ghafarian Shoaee; Julian Withöft; Ralf Brüning; Jürgen Götze, “AI Workbench - Conceptual Workflow to Develop AI Models for SI/PI-Applications in PCB Development”, 2024 IEEE Joint International Symposium on Electromagnetic Compatibility, Signal & Power Integrity: EMC Japan / Asia-Pacific International Symposium on Electromagnetic Compatibility (EMC Japan/APEMC Okinawa), 20-24 May 2024, Okinawa/Japan
- [80] Emre Ecik, Werner John, Julian Withöft, Ralf Brüning, Jürgen Götze, “A Statistically Evaluated Decision Tree Approach for SI-Compliant PCB Design”, 2024 International Symposium on Electromagnetic Compatibility – EMC Europe, Bruges, Belgium, 09/2024
- [81] Nima Ghafarian Shoaee; Baoyin Hua; Werner John; Ralf Brüning; Jürgen Götze, “Enhanced Reinforcement Learning Methods for Optimization of Power Delivery Networks on PCB”, 2024 International Symposium on Electromagnetic Compatibility – EMC Europe, Bruges, Belgium, 09/2024
- [82] Julian Withöft; Werner John; Emre Ecik; Ralf Brüning; Jürgen Götze, “Machine Learning Methods for Elaborating the Feasible Region for Signal Integrity Analysis in Differential Pair PCB Structures”, 2024 International Symposium on Electromagnetic Compatibility – EMC Europe, Bruges, Belgium, 09/2024
- [83] E. Ecik, W. John, J. Withöft, R. Brüning, J. Götze; “Implementierung entscheidungsbaum-basierter KI-Module zur Vorhersage SI-konformer Signale“, Kleinheubacher Tagung 2024, Kleinheubach, 26. September 2024
- [84] Ilda Cahani and Marcus Stiemer, „Dimensional Reduction via Autoencoders for Automated PCB Topology Design“, oral presentation at 2024 Kleinheubacher Tagung, 2024.
- [85] Marcus Stiemer, Rebecca Ueltzen, “Assessing and Improving Signal Integrity in PCB Structures by Machine Learning Techniques”, oral presentation at 2024 Kleinheubacher Tagung, 2024.
- [86] Rebecca Ueltzen, Marcus Stiemer, Ralf Brüning, “Explainable Artificial Intelligence am Beispiel für Parameteridentifikation von Schaltplänen”, poster presentation at 7. progressivKI workshop Hamm, 2024.
- [87] Marcus Stiemer, Ilda Cahani, Rebecca Ueltzen, Zouhair Nezhi, “Machine Learning to Support Electronic Design Automation”, poster presentation at Abschlussworkshop progressivKI Hildesheim, 2024.
- [88] Marcus Stiemer, Ilda Cahani, Rebecca Ueltzen, Zouhair Nezhi, “Machine Learning to Support Electronic Design Automation”, poster presentation at Tag der Bundeswehr Hamburg, 2024.

- [89] Ilda Cahani, Marcus Stiemer, "Machine Learning Supported Design of PCBs through Mathematical Optimization and Autoencoders", poster presentation at 7. progressivKI workshop Hamm, 2024.
- [90] Rebecca Ueltzen, Marcus Stiemer, "Explainable artificial intelligence for the parameter identification of PCBs", poster presentation at 2024 Smart Systems Integration Conference and Exhibition (SSI), 2024.
- [91] Marcus Stiemer, Harald Mathis, H. Céline Lecampion, Wenceslas Rahajandraibed, Christian Hedayat, "Mitigation of AI-inherent risks in AI-supported industrial development and scientific research", 2024 Smart Systems Integration Conference and Exhibition (SSI). IEEE, 2024.
- [92] Marcus Stiemer, Sven Lange, Dominik Schröder, Christian Hedayat, Jad Maalouly, Dennis Hemker, and Harald Mathis, "Enhancing Information Extraction in EMC Measurements through Artificial Intelligence", 2024 Smart Systems Integration Conference and Exhibition (SSI). IEEE, 2024.
- [93] Morten Schierholz, Christian Schuster, Zouhair Nezhi, and Marcus Stiemer, "PCB Based Power Delivery Network Analysis Using Transfer Learning and Artificial Neural Networks", 2024 IEEE 28th Workshop on Signal and Power Integrity (SPI). IEEE, 2024.
- [94] Zouhair Nezhi, Marcus Stiemer, Morten Schierholz, and Christian Schuster, "Dimensional Reduction by Auto-Encoders in Machine Learning Based Power Integrity Analysis", 2024 IEEE 28th Workshop on Signal and Power Integrity (SPI). IEEE, 2024.
- [95] Zouhair Nezhi, Nima Ghafarian Shoaee, and Marcus Stiemer, "Iterative placement of decoupling capacitors using optimization algorithms and machine learning", *Advances in Radio Science* 21, 123-132, 2024.

## 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.
- [Cahani22] I. Cahani, M. Stiemer, „Graph Neural Networks to Support an Automated Design of PCBs“, oral presentation at Kleinheubacher Tagung 2022
- [Cahani23A] I. Cahani, M. Stiemer, „Autoencoders in the Machine Learning Supported Design of PCBs“, Proc. 2023 Kleinheubach Conference, IEEE Xplore, 2023
- [Cahani23B] I. Cahani, M. Stiemer, “Mathematical optimization and machine learning to support PCB topology identification”, *Advances in Radio Science* 21, 25-35, 2023.
- [Chinesta] Francisco Chinesta, *From Data-based engineered models to Model-based engineered data*, Compumag, Paris, 2019
- [Chu] Chu, X., He, Y., Chakrabarti, K., & Ganjam, K. (2015, May). Tegra: Table extraction by global record alignment. In *Proceedings of the 2015 ACM SIGMOD international conference on management of data* (pp. 1713-1728).

- [Clark] Clark, C. A., & Divvala, S. (2015, April). Looking beyond text: Extracting figures, tables and captions from computer science papers. In Workshops at the Twenty-Ninth AAAI Conference on Artificial Intelligence.
- [Collobert] Collobert R. und Weston J. (2008) A unified architecture for natural language processing: Deep neural networks with multitask learning. In Proceedings of the 25th international conference on Machine learning, pp. 160–167.
- [CornVie] Alessandro Cornaglia, Alexander Viehl, Oliver Bringmann, and Wolfgang Rosenstiel. 2019. SIMULTime: Context-sensitive timing simulation on intermediate code representation for rapid platform explorations. In Proceedings of the 24th Asia and South Pacific Design Automation Conference (ASPDAC '19).
- [Coüasnon] Coüasnon, B., & Lemaitre, A. (2014). Handbook of Document Image Processing and Recognition, chapter Recognition of Tables and Forms.
- [Csaba] Csaba Szepesvári, Algorithms for Reinforced Learning, Morgan & Claypool, 2010
- [Csurka] Domain Adaptation for Visual Applications: A Comprehensive Survey, Csurka, 2007, arXiv:1702.05374
- [DAC\_AI] Machine Learning/AI, DAC 2019; <https://www.dac.com/content/machine-learningai>
- [DACPan20] DAC Panel – Artificial Intelligence Comes to CAD: Where’s the Data? by Tom Simon on 07-30-2020 at 10:00 am, Categories: AI, EDA, Events, Synopsys <https://semiwiki.com/eda/288904-dac-panel-ai-artificial-intelligence-comes-to-cad-wheres-the-data/>
- [DCP] <https://dcp-standard.org/>
- [DeepPCB] Chip Placement with Deep Reinforcement Learning (<https://arxiv.org/pdf/2004.10746.pdf>), A Deep Reinforcement Learning Approach for Global Routing (<https://arxiv.org/abs/1906.08809>), DeepPCB™: Pure AI-powered, cloud-native PCB routing (<https://deeppcb.ai/>), Demystifying Machine Learning for Signal and Power Integrity Problems in Packaging (<https://ieeexplore.ieee.org/document/9149655>)
- [Dernoncourt] Dernoncourt F., Young Lee J. und Szolovits P. (2017) Neuroner: an easy-to-use program for named-entity recognition based on neural networks. arXiv preprint arXiv:1705.05487
- [Dhiran] Dhiran, T., & Sharma, R. (2013). Table detection and extraction from image document. International Journal of Computer & Organization Trends, 3(7), 275-278.
- [Dierig] Dierig, C. (2018, April 22). Fachkräftemangel kostet Deutschland 30 Milliarden Euro. WELT. 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](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.
- [Lecue20] F. Lecue, "On the role of knowledge graphs in explainable AI.", *Semantic Web* 11.1, 2020
- [LingZhang21] Ling Zhang et al.: Fast PDN Impedance Prediction Using Deep Learning, EMC + SIPI Virtual IBIS Summit, 2021
- [LiHanLi] Li J., Sun A., Han J. und Li C. (2020) A Survey on Deep Learning for Named Entity Recognition. In Proceedings of the Seventh Joint Conference on Lexical and Computational Semantics, pp. 167-172.
- [Liu] Liu, Y. (2009). Tableseer: automatic table extraction, search, and understanding.
- [LuSun] T. Lu, J. Sun, K. Wu and Z. Yang; High-Speed Channel Modeling With Machine Learning Methods for Signal Integrity Analysis; IEEE Transactions on Electromagnetic Compatibility, vol. 60, no. 6, pp. 1957 - 1964, Dec. 2018.
- [Mandal] Mandal, S., Chowdhury, S. P., Das, A. K., & Chanda, B. (2004). A Very Efficient Table Detection System from Document Images. In ICVGIP (pp. 411-416).
- [Masudul] Masudul H. Quraishi, Hessam S. Sarjoughian, and Soroosh Gholami. 2018. Co-simulation of hardware RTL and software system using FMI. In Proceedings of the 2018 Winter Simulation Conference (WSC '18). IEEE Press, 572–583.
- [Mikolov] Tomas Mikolov, Kai Chen, Greg Corrado, Jeffrey Dean: Efficient Estimation of Word Representations in Vector Space. <https://arxiv.org/abs/1301.3781>
- [Milošević] Milošević, N. (2018). A multi-layered approach to information extraction from tables in biomedical documents.
- [Minsky] M. Minsky, Neural Nets and the Brain Model Problem, Ph.D. dissertation in Mathematics, Princeton, 1954; siehe auch: M. Minsky, Seymour Papert: Perceptrons. An Introduction to Computational Geometry. MIT Press, Cambridge MA u. a. 1969
- [MueBel] D. Mueller, M. Beltle, S. Tenbohlen: Automated Filter Optimization for High-Voltage Cable Harness Based on Circuit Simulations for Conducted Emissions Prediction, EMC Europe 2018, Amsterdam 2018
- [Nezhi22] N. Nezhi, N. Ghafarian, M. Stiemer: „Zur Platzierung von Entkopplungskondensatoren mittels Optimierungsalgorithmen und ANN-Bewertung der PDN-Impedanz“, oral presentation at Kleinheubacher Tagung 2022
- [Nezhi24] Zouhair Nezhi, Nima Ghafarian Shoaee, and Marcus Stiemer, “Iterative placement of decoupling capacitors using optimization algorithms and machine learning”, *Advances in Radio Science* 21 (2024): 123-132.
- [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
- [Riazi19] M. Sadegh Riazi, Bitra Darvish Rouhani, Farinaz Koushanfar: Deep Learning on Private Data, IEEE Security and Privacy Magazine PP 99, 2019
- [Sarawagi] Sunita Sarawagi: Information Extraction. In: Foundations and Trends in Databases. Volume1, Issue 3, 2008 <https://doi.org/10.1561/1900000003>
- [Schierholz24] Morten Schierholz, Christian Schuster, Zouhair Nezhi, and Marcus Stiemer, "PCB Based Power Delivery Network Analysis Using Transfer Learning and Artificial Neural Networks", 2024 IEEE 28th Workshop on Signal and Power Integrity (SPI). IEEE, 2024
- [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
- [Wang17] Q. Wang, Z. Mao, B. Wang, L. Guo, „Knowledge graph embedding: A survey of approaches and applications“, IEEE transactions on knowledge and data engineering, 29(12), 2724-2743, 2017.
- [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](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.
- [YaguangLi19] Yaguang Li et al: A Customized Graph Neural Network Model for Guiding Analog IC Placement, IEEE/ACM International Conference On Computer Aided Design ICCAD, 2020
- [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/>



## Berichtsblatt

1. ISBN oder ISSN	2. Berichtsart (Schlussbericht oder Veröffentlichung) Schlussbericht
3. Titel Schlussbericht zum Förderprojekt „progressivKI - Unterstützung der Entwicklung von effizienten und sicheren Elektroniksystemen für zukünftige KFZ-Anwendungen mit automatisierten Fahrfunktionen mittels einer modular strukturierten KI-Plattform“ Teilvorhaben: Erforschung und Implementierung von KI-Bildverarbeitungsalgorithmen	
4. Autor(en) [Name(n), Vorname(n)] Mathis, Harald Ghosh, Indranil	5. Abschlussdatum des Vorhabens 30.09.2024
	6. Veröffentlichungsdatum
	7. Form der Publikation Schlussbericht
8. Durchführende Institution(en) (Name, Adresse) Hochschule Hamm-Lippstadt - 59063 Hamm	9. Ber. Nr. Durchführende Institution
	10. Förderkennzeichen 19A21006Q
	11. Seitenzahl 128
12. Fördernde Institution (Name, Adresse)  Bundesministerium für Wirtschaft und Klimaschutz (BMWK) 53107 Bonn	13. Literaturangaben 211
	14. Tabellen 3
	15. Abbildungen 33
16. Zusätzliche Angaben	
17. Vorgelegt bei (Titel, Ort, Datum)	
18. Kurzfassung Die wesentlichen Innovationen im Fahrzeug (~ 90%) beruhen auf Mikroelektronik, an deren Entwicklung und Produktion die gesamte Automobillieferkette beteiligt ist. Es ist daher unabdingbar, die sich ständig weiterentwickelnden neuen Möglichkeiten der Halbleiterindustrie und Elektronik möglichst schnell in die Entwicklung neuer Fahrzeuge einfließen zu lassen. Dieses Vorhaben adressierte in dem BMWK-Förderauftrag „Künstliche Intelligenz als Schlüsseltechnologie für das Fahrzeug der Zukunft“ den Teilschwerpunkt (C) KI-Verfahren in der Fahrzeugentwicklung <=> KI-Methoden in der Simulation. Um Entwurfsprozesse für zukünftige KFZ-Elektroniksysteme optimal zu unterstützen und zu automatisieren ist – aufgrund der deutlich zunehmenden Systemkomplexität auf dem Weg zum autonomen und möglicherweise elektrisch angetriebenen Fahrzeug – der Einsatz von KI-Modulen unbedingt erforderlich. Die dabei erforderlichen F+E-Schritte sind so umfangreich, dass sie zukünftig nur mit Hilfe einer KI-basierten Plattform in ausreichend kurzer Zeit und mit vertretbarem Kostenaufwand erfolgreich umgesetzt werden können. Ziel des Projektes war es, durch den kooperativen Betrieb von KI-Systemen Elektroniksysteme schneller und zuverlässiger zu entwickeln, um somit für zukünftige Schlüsseltechnologien für die Automobilindustrie eine weltweit wirkende Innovations- und Technologieführerschaft der beteiligten Unternehmen zu erreichen. Typische elektronische Komponenten sind zum Beispiel: ABS oder ESP bzw. ACC. Weiterhin sollen hier genannt werden: Umfelderkennung durch kompakte Sensorik sowie die Sensordatenfusion und -interpretation in Echtzeit mittels leistungsfähiger Steuereinheiten und Multiprozessorsysteme. Zur Entwicklung sicherer und zuverlässiger elektronischer Komponenten und Systeme sind u. a. neue Entwurfs- und Validierungsmethoden auf KI-Basis notwendig.	
19. Schlagwörter EDA, Mikroelektronik, Halbleiterindustrie, Fahrzeugentwicklung, Künstliche Intelligenz (KI), Systemkomplexität, Autonomes Fahren, Elektroniksysteme, Sensordatenfusion, Validierungsmethoden, Innovationsführerschaft	
20. Verlag	21. Preis

## Document Control Sheet

1. ISBN or ISSN	2. type of document (e.g. report, publication) Final Report
3. title Final Report on the Funding Project "progressivAI - Supporting the Development of Efficient and Safe Electronic Systems for Future Automotive Applications with Automated Driving Functions Using a Modular AI Platform" Sub-projects: Research and development of AI image processing algorithms	
4. author(s) (family name, first name(s)) Mathis, Harald Ghosh, Indranil	5. end of project 30.09.2024
	6. publication date
	7. form of publication Final Report
8. performing organization(s) (name, address) Hochschule Hamm-Lippstadt - 59063 Hamm	9. originator's report no.
	10. reference no. 19A21006Q
	11. no. of pages 128
12. sponsoring agency (name, address)  Bundesministerium für Wirtschaft und Klimaschutz (BMWK) 53107 Bonn	13. no. of references 211
	14. no. of tables 3
	15. no. of figures 33
16. supplementary notes	
17. presented at (title, place, date)	
18. abstract The essential innovations in vehicles (~90%) are based on microelectronics, in the development and production of which the entire automotive supply chain is involved. It is therefore essential to incorporate the constantly evolving new possibilities of the semiconductor industry and electronics into the development of new vehicles as quickly as possible. This initiative addressed the sub-focus (C) "AI Methods in Vehicle Development <=> AI Methods in Simulation" in the BMWK funding call "Artificial Intelligence as a Key Technology for the Vehicle of the Future". To optimally support and automate design processes for future automotive electronic systems, the use of AI modules is indispensable, due to the significantly increasing system complexity on the path to autonomous and possibly electrically powered vehicles. The necessary R&D steps are so extensive that they can only be successfully implemented in the future with the help of an AI-based platform, in a sufficiently short time and at a reasonable cost. The goal of the project was to develop electronic systems faster and more reliably through the cooperative operation of AI systems, thus enabling the participating companies to achieve worldwide innovation and technology leadership for future key technologies in the automotive industry. Typical electronic components include, for example, ABS or ESP and ACC. Further examples include environmental sensing using compact sensors as well as sensor data fusion and interpretation in real time via powerful control units and multiprocessor systems. To develop safe and reliable electronic components and systems, new AI-based design and validation methods are necessary.	
19. keywords EDA (Electronic Design Automation), Microelectronics, Semiconductor Industry, Vehicle Development, Artificial Intelligence (AI), System Complexity, Autonomous Driving, Electronic Systems, Sensor Data Fusion, Validation Methods, Innovation Leadership	
20. publisher	21. price