Finanziert von der Europäischen Union
NextGenerationEU

Gefördert durch:
Bundesministerium für Wirtschaft und Klimaschutz
aufgrund eines Beschlusses des Deutschen Bundestages

BMWK-Verbundprojekt: progressivKI
Förderkennzeichen: 19A21006H
Projektlaufzeit: 01.04.2021 bis 30.09.2024

Schlussbericht 09-HOOD

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

Teilvorhaben: KI-Unterstützung für Requirement-Engineering

Version: 1.0
Erstelldatum: 04.12.2024
Autoren: Markus Eberhardt, Andrea Bärnthaler

Zuwendungsempfänger: HOOD GmbH (Fkz: 19A21006H)

Ansprechpartner: HOOD GmbH
Markus Eberhardt
82041 Oberhaching
markus.eberhardt@hood-group.com

Das diesem Bericht zugrundeliegende Vorhaben wurde mit Mitteln des Bundesministeriums für Wirtschaft und Klimaschutz unter dem Förderkennzeichen 19A21006H gefördert. Die Verantwortung für den Inhalt dieser Veröffentlichung liegt bei den Autoren.

© Copyright 2021-2024 by progrssivKI & HOOD GmbH

Inhalt

1 Zusammenfassung 5

2 Ziele 6

2.1 Problemstellung und allgemeine Ziele des Vorhabens 6

2.2 Wissenschaftliche und/oder technische Ziele des Vorhabens 7

2.2.1 KI-gestützter Entwurfsprozess 7

2.2.2 Umsetzung des geplanten modular strukturierten KI-Konzeptes 9

2.2.3 Genutzte KI-Verfahren und Werkzeuge 10

2.2.4 Aufbau KI-Modulbaukasten 15

2.2.5 Entwurfsprozesse 15

2.2.5.1 Allgemeiner Entwurfsprozess 17

2.2.5.2 Funktionale Sicherheit 18

2.2.5.3 Kostenreduktion mittels virtueller Entwicklung 19

2.2.6 IP-Schutz und Interoperabilität 22

2.2.7 Darstellung der wesentlichen Projektinnovationen 24

2.3 Ausgangssituation und Voraussetzungen, unter denen das Vorhaben durchgeführt wurde 26

2.3.1 Der Stand von Wissenschaft und Technik 26

2.3.2 Bisherige Arbeiten des Antragstellers 39

2.4 Abgrenzung und Zusammenarbeit mit anderen Projekten 41

3 Technische Ergebnisse 44

3.1 Arbeitspaket 1: edaKI-Anforderungen/Spezifikation modular strukturierte KI-Plattform 45

3.1.1 Teilaufgabe 1.1: Funktionale Sicherheit + Entwurfsabläufe (Wertschöpfungsketten) + Schnittstellen 46

3.1.2 Teilaufgabe 1.2: Spezifikation KI-gestützter Entwurf 50

3.1.3 Teilaufgabe 1.3: KI-Module/KI-Algorithmen/Analyse Synergien 55

3.1.4 Teilaufgabe 1.4: KI-Module für KI-Plattformen der Anwendungsebenen #1 - #2 + Struktur der KI-Plattformen 58

3.2 Arbeitspaket 2: KI-Datenaufbereitung/-generierung 61

3.2.1 Teilaufgabe 2.1: Definition und Planung von Schnittstellenmodellen 63

3.2.2 Teilaufgabe 2.2: Test-/Lerndatenerzeugung 72

3.2.3 Teilaufgabe 2.3: Modellbildung + Klassifikation + Signalauswertung 77

3.2.4 Teilaufgabe 2.5: Datenbasierte Trainings-/Lernmodule 80

3.3 Arbeitspaket 3: Verzahnte Entwicklung von Automobilkomponenten 85

3.3.1 Teilaufgabe 3.4: Implementation Domänenwissen 86

3.3.2 Teilaufgabe 3.6: Validierung KI-Module/KI-Framework für Plattformen Anwendungsebenen #1 und #2 98

3.4 Arbeitspaket 4: Erstellung Teilplattformen (#1: PCB-Entwurf; #2: IC-Anwendung/Sensorik) 110

3.4.1 Teilaufgabe 4.1: KI-Plattform Anwendungsebene #1 PCB-Entwurf 113

3.5 Arbeitspaket 5: Projektmanagement & Dissemination 121

3.5.1 Teilaufgabe 5.1: Projektleitung/ProjektOffice + progressivKI Advisory Board 123

3.5.2 Teilaufgabe 5.2: F+E-Ergebnisverbreitung + F+E-Nutzungspotentiale 123

3.5.3 Teilaufgabe 5.3: Dokumentation Gesamtprojekt 125

4 Verwertung und voraussichtlicher Nutzen 125

5 Veröffentlichungen 129

6 Quellen 135

1 Zusammenfassung

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

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

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

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

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

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

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

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

2 Ziele

2.1 Problemstellung und allgemeine Ziele des Vorhabens

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

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

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

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

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

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

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

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

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

Durch eine Cloud-Lösung wird eine Übertragbarkeit auf die Entwurfsprozesse industrieller Anwender garantiert, die nicht am Vorhaben beteiligt waren. Hierdurch wird im Zusammenhang mit entsprechenden Nutzungsmodellen, die insbesondere KMU einen Zugang zu KI-basierter Technologieentwicklung sicherstellen, eine zusätzliche Dimension einer erfolgreichen Vermarktung von progressivKI eröffnet. Die Kombination einer belastbaren und sicheren Cloud mit den Resultaten von progressivKI birgt auf lange Sicht das Potential, elektrotechnische Entwurfsprozesse mit verschwindenden Grenzkosten in kürzester Zeit auf neue, plötzlich auftretende Requirements umzustellen. Dies eröffnet nicht nur ein enormes Wertschöpfungspotential durch die Fähigkeit, die für eine klimaneutrale und sichere Mobilität erforderlichen Komponenten wirtschaftlich und unter Berücksichtigung weitreichender Kundenwünsche realisieren zu können, sondern definiert eine technologische Basis zum Erreichen nationaler Klimaziele bei gleichzeitiger Stärkung der deutschen Wirtschaft. Dadurch, dass mit progressivKI intensive datenbasierte Dienstleistungen mit hohem Sicherheitsanspruch auf den Markt kommen, ist zu erwarten, dass auch der Ausbau der Serverinfrastruktur in Europa angekurbelt wird mit den entsprechenden positiven konjunkturellen Effekten.

2.2 Wissenschaftliche und/oder technische Ziele des Vorhabens

2.2.1 KI-gestützter Entwurfsprozess

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

noch schwer formalisierbares Expertenwissen erforderlich, oder Entwürfe erweisen sich sogar in der Realität als untauglich.

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

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

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

Künstliche Intelligenz (KI/AI)	Wird als Bezeichnung der wissenschaftlichen Disziplin verwendet, die sich mit dem Studium von Agenten beschäftigt, die ihre Umgebung wahrnehmen, auf diese reagieren und Maßnahmen ergreifen, um die Wahrscheinlichkeit, ihre Ziele zu erreichen, zu maximieren (Poole, David; Mackworth, Alan; Goebel, Randy (1998). Computational Intelligence: A Logical Approach. New York: Oxford University Press. ISBN 978-0-19-510270-3).
Machine Learning (ML)	Bezeichnet die wissenschaftliche Disziplin, die sich mit Algorithmen befasst, die sich aufgrund von Erfahrungsdaten automatisch verbessern können (computerbasierte Generierung von Wissens Erfahrung). Als solche ist sie Teil der künstlichen Intelligenz.
Deep Learning (DL)	Bezeichnet eine Methode des Machine Learnings, bei der mehrschichtige künstliche neuronale Netze eingesetzt werden.
Selbstlernende Prozesse (SP)	Hierunter werden fortgeschrittenere Algorithmen zusammengefasst, die weitgehend auf neuronalen Netzen basieren, und diese in die Lage versetzen, kognitive Prozesse, die der Mensch beim Elektronik-Entwurf erbringt, maschinell abzubilden. Hierzu zählen das datenbasierte Aufbauen eines Modells der Realität zur Erfolgsbewertung (Reinforcement Learning), der Transfer erlernter Fähigkeiten in andere Domänen (Transfer Learning) und der Umgang mit unvollständiger Information („wahrnehmungsbasierte" adhoc-Approximationen der Situation, vgl. [MORAVČÍK, Matej, et al. Deepstack: Expert-level artificial intelligence in heads-up no-limit poker. Science, 2017, 356. Jg., Nr. 6337, S. 508-513]).

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

2.2.2 Umsetzung des geplanten modular strukturierten KI-Konzeptes

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

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

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

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

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

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

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

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

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

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

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

2.2.3 Genutzte KI-Verfahren und Werkzeuge

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

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

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

Die Vorgehensweise in progressivKI wurde durch die aktuelle Entwicklung im TensorFlow-Ökosystem unterstützt, da das Huskarl[1]-Werkzeug als neues Werkzeug (Framework) einen neuen modularen Ansatz des Reinforcement erlaubt. Diesen Ansatz verfolgte progressivKI intrinsisch. Die unterschiedlichen Pfade durch die KI-System-Modullandschaft können iterativ gestaltet werden, so dass eine Optimierungsstrategie (stetige Verbesserung, Konvergenzverhalten) umgesetzt werden konnte.

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

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

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

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

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

Random Forest - Ein Random Forrest besteht aus mehreren unkorrelierten Entscheidungsbäumen, die unter einer bestimmten Art der Randomisierung in einem Lernprozess induziert wurden. Eine Klassifikationsentscheidung wird durch einen einfachen Mehrheitsentscheid über alle Bäume getroffen.

Vorteile:

Evaluierung basiert auf mehreren Bäumen - ist also parallelisierbar.

Effizient für große Datenmengen.

Sehr schnelles Training möglich.

Zusammenhang zwischen Klassen/Entscheidungen kann unmittelbar hergestellt werden.

DL-Segment
Tensorflow - Entwickelt von Google bietet Tensorflow Schnittstellen zu allen populären Programmiersprachen. Am häufigsten verwendet wird es allerdings mit Python. Tensorflow stellt eine Schnittstelle für Entwickler bereit, mit der effizient Architekturen neuronaler Netze erstellt und mit diesen experimentiert werden kann. Darüber hinaus können einfach Daten in Form von Graphen, Netzen, SQL-Tabellen und Bilder integriert bzw. importiert werden.
Torch - Ein großer Vorteil von Torch ist die Verwendung von dynamisch updatenden Graphen, deren Architektur während des Prozesses geändert werden kann. Dies birgt große Möglichkeiten für das Reinforcement Learning.
Keras - Keras ist die High-Level Umgebung zur effizienten Benutzung von Tensorflow. Die Erstellung und Importierung von Modellen und großen Datenmengen ist um vieles Einfacher als bei den Low-Level Frameworks. Dafür werden Einbußen in der Konfiguration hingenommen. Eine Kombination mit z.B. Tensorflow für diese Belange ist aber jederzeit möglich.

SP-Segment
Huskarl - Der ausgewiesene Fokus des auf TensorFlow basierenden Huskarl liegt auf dem Deep Reinforcement Learning. Neben der Basis von Tensorflow kann für schnelles Prototyping auch auf die High-Level API Keras zugegriffen werden. Zusätzlich sind integrierte Algorithmenbausteine wie Deep Q-Learning verfügbar. <https://www.heise.de/developer/meldung/Deep-Reinforcement-Learning-Huskarl-verspricht-schnelleres-Prototyping-4475103.html>

Die dargestellten Werkzeuge (siehe Abbildung 17) sind so gewählt, dass einerseits Domänenwissen (siehe auch oben: tacit knowledge[2]) abgebildet werden kann und anderseits das Ergebnis des ML als Eingangsgröße für das nächste Segment dienen kann. Das bedeutet, man fängt mit der klassischen Feature Extraction an und kann diese – eventuell nach Iteration – als Eingangsparameter für einen Deep-Learning-Prozess einsetzen. Denkbar ist auch, dass ein ML-Ansatz das Kundenproblem bereits löst. Dann endet die Problemlösung nach dem ML-Segment.

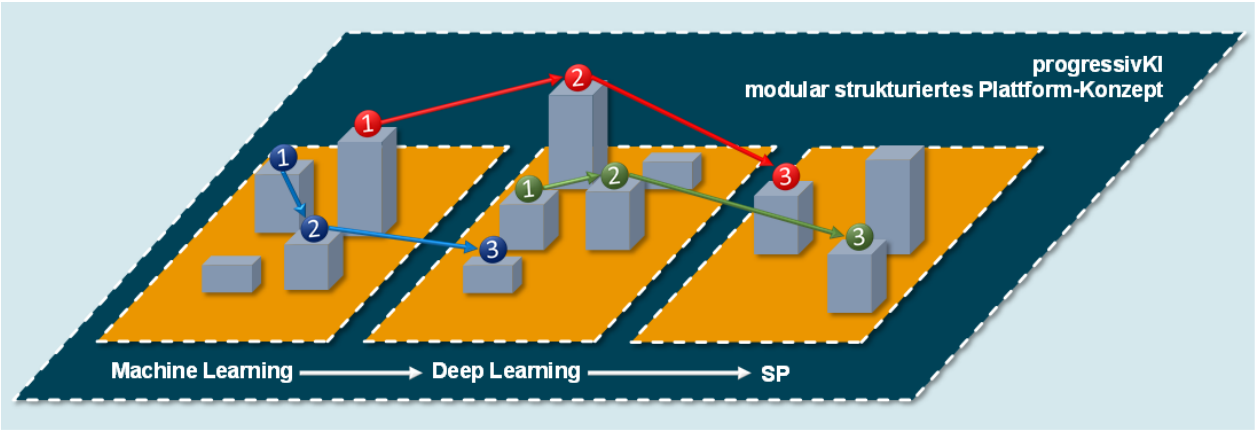

Abbildung 1: progressivKI modular, strukturierte KI-Plattform - Module aus den 3 Segmenten Machine Learning (ML) – Deep Learning (DL) – Selbstlernende Prozesse (SP)

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

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

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

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

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

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

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

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

Dabei werden die im ML-Segment erhaltenen Parameter und Features[3] für den DeepLearning-Prozess nach Möglichkeit eingesetzt.

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

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

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

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

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

- Einfach in andere Programmiersprachen wie C++, C, Java einzubetten.
- Objekt- und prozessorientierte Programmiersprache sorgt für sicheres Datenmanagement und schnelle Berechnung der Daten.

2.2.4 Aufbau KI-Modulbaukasten

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

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

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

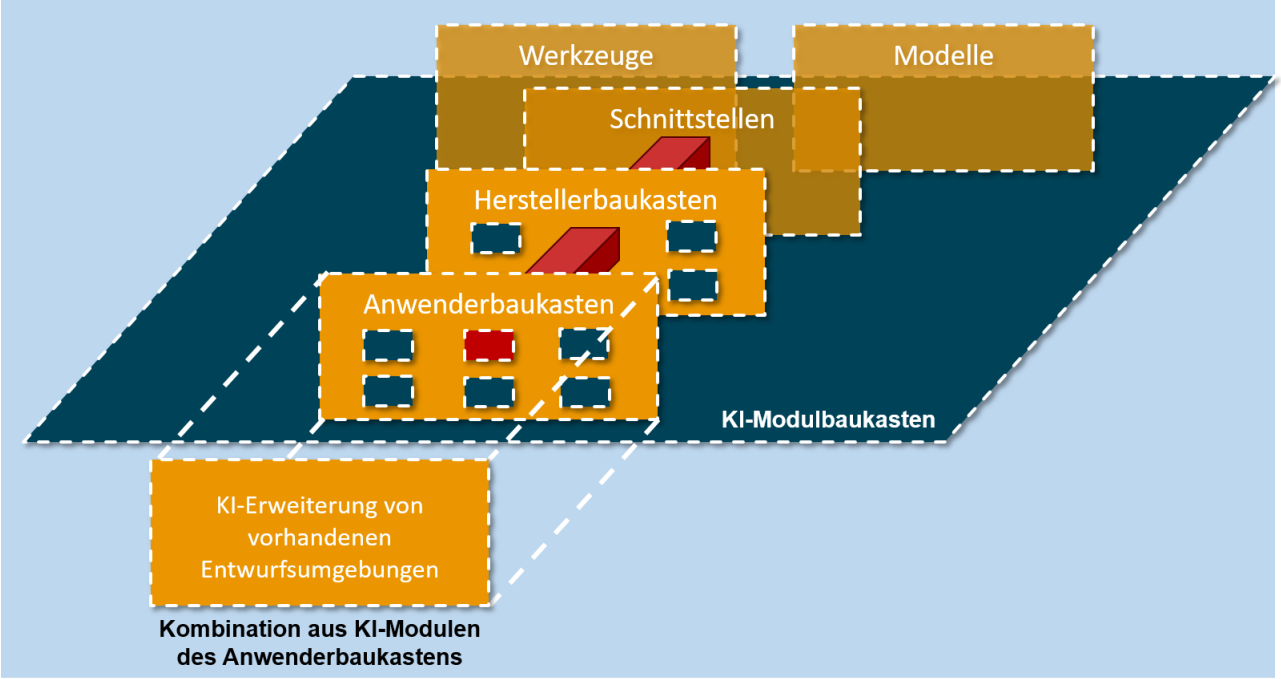

Abbildung 2: Prinzipieller Aufbau eines KI-Modulbaukasten

2.2.5 Entwurfsprozesse

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

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

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

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

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

Weiterhin muss beachtet werden, dass für den Entwurf elektronischer Systeme neben den spezifizierten Haupteigenschaften auch die sogenannten Nebeneigenschaften (Abbildung 3) in den Entwurfsprozess vermehrt eingehen müssen. Diese sogenannten Nebeneigenschaften gewinnen immer mehr Einfluss auf die funktionale Sicherheit eines Systems und entwickeln sich vermehrt zum Kostentreiber.

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

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

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

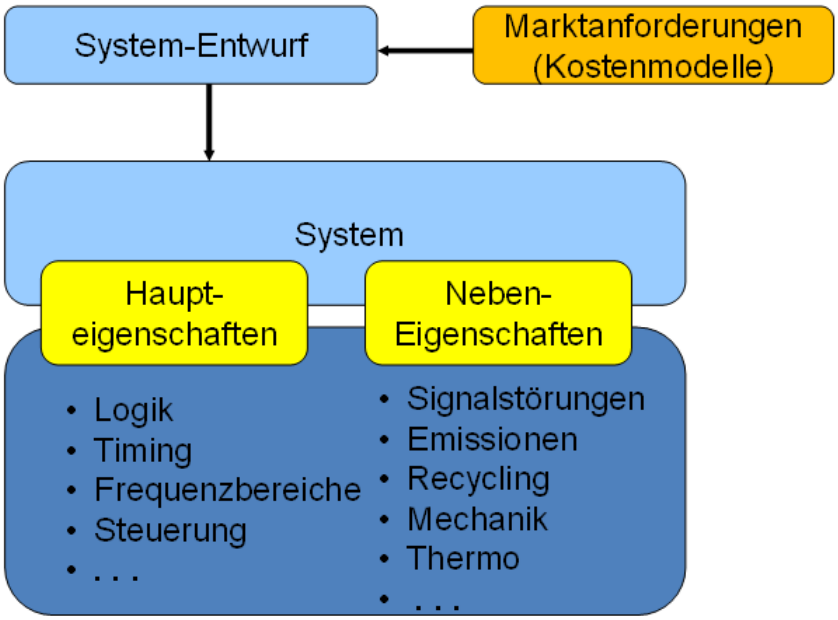

Abbildung 3: Gliederung eines mikroelektronischen Systems in Haupt- und Nebeneigenschaften

2.2.5.1 Allgemeiner Entwurfsprozess

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

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

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

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

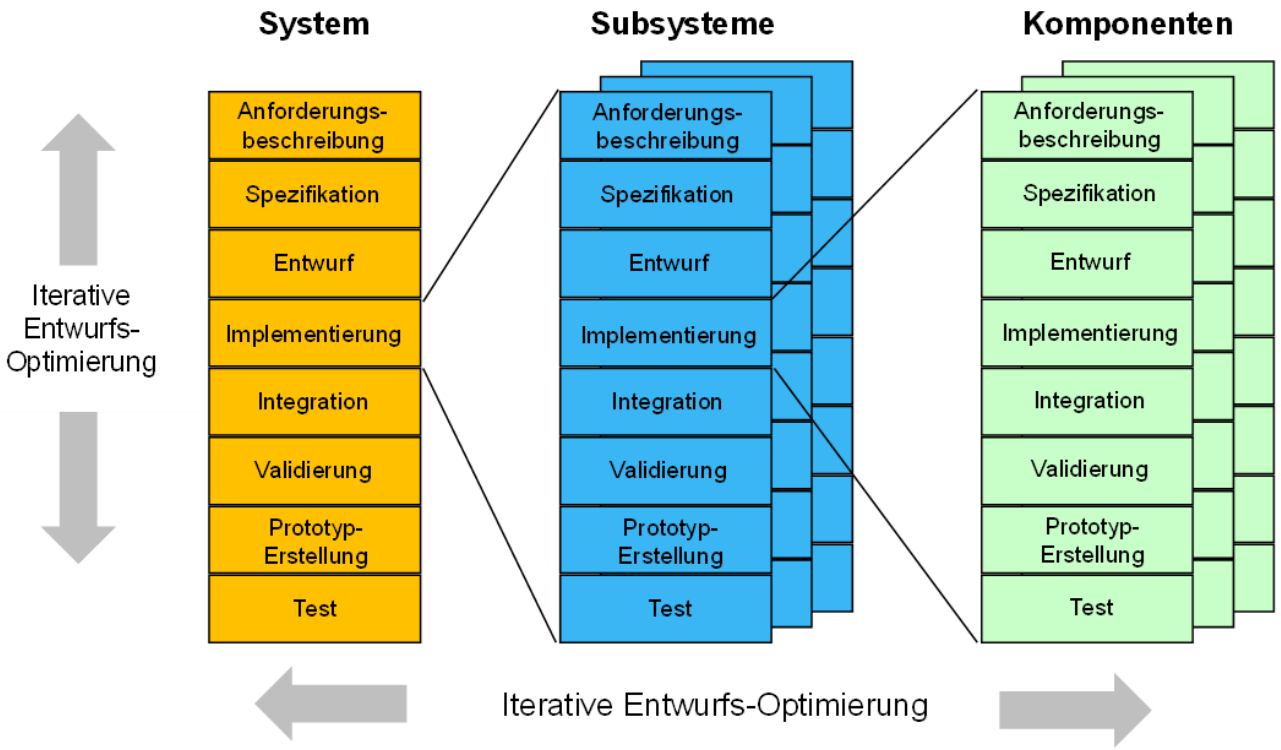

Abbildung 4: Verallgemeinerter Entwurfsprozess als Grundlage für die Analyse des Einsatzes von KI-Modulen im industriellen Umfeld

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

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

2.2.5.2 Funktionale Sicherheit

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

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

(das sind Fehler bei der Spezifikation, Implementierung etc. des Systems auftreten können) und zur sicheren Beherrschung von Ausfällen und Störungen (oft auch durch physikalische Kopplungen verursacht).

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

2.2.5.3 Kostenreduktion mittels virtueller Entwicklung

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

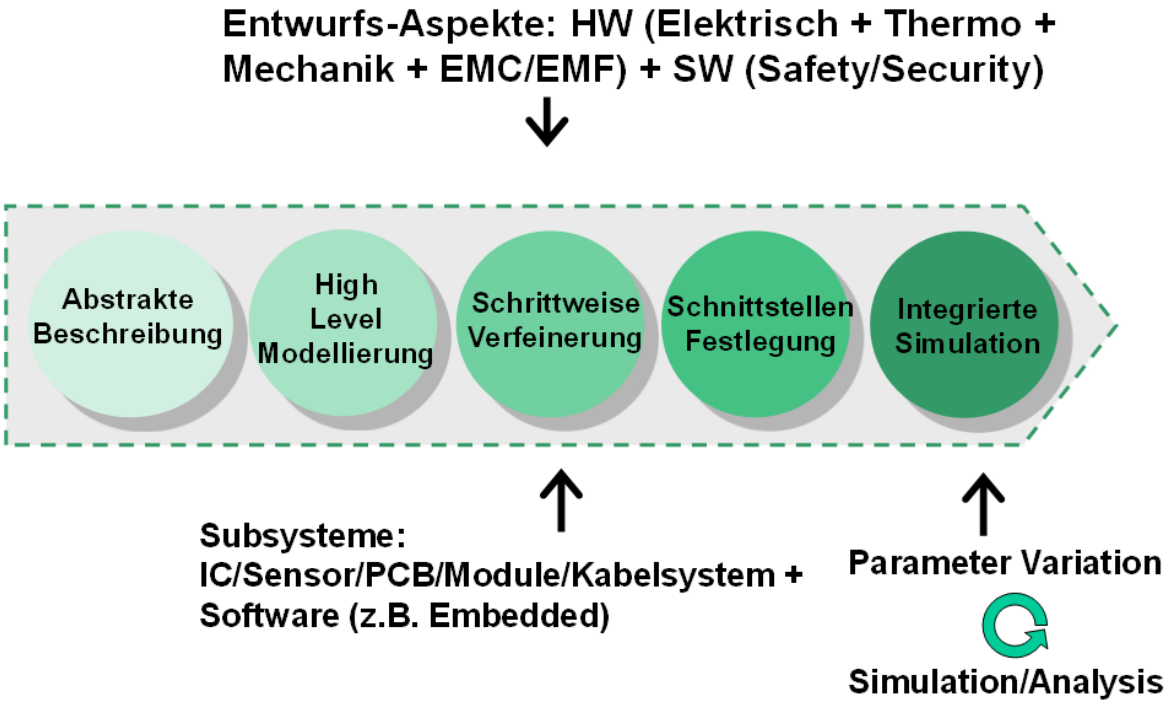

Abbildung 5: Entwurfsaspekte und -schritte auf HW- und SW-Ebene

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

aus Sicht der funktionalen Sicherheit die HW-Entwurfsaspekte |*physikalische Kopplungen*| sowie die SW- Entwurfsaspekte |*Safety/Security*| in die Modellierung einbezogen werden.

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

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

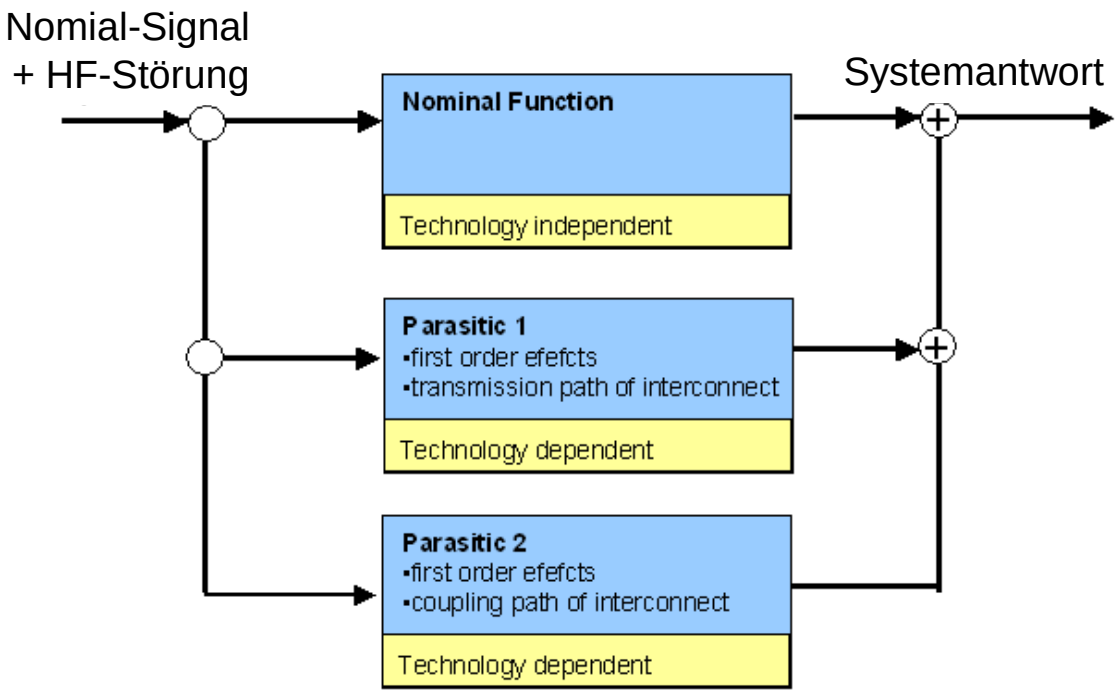

Abbildung 6: Ansatz zur Einführung von Modellhierarchien für eine Fehleranalyse durch Simulation

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

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

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

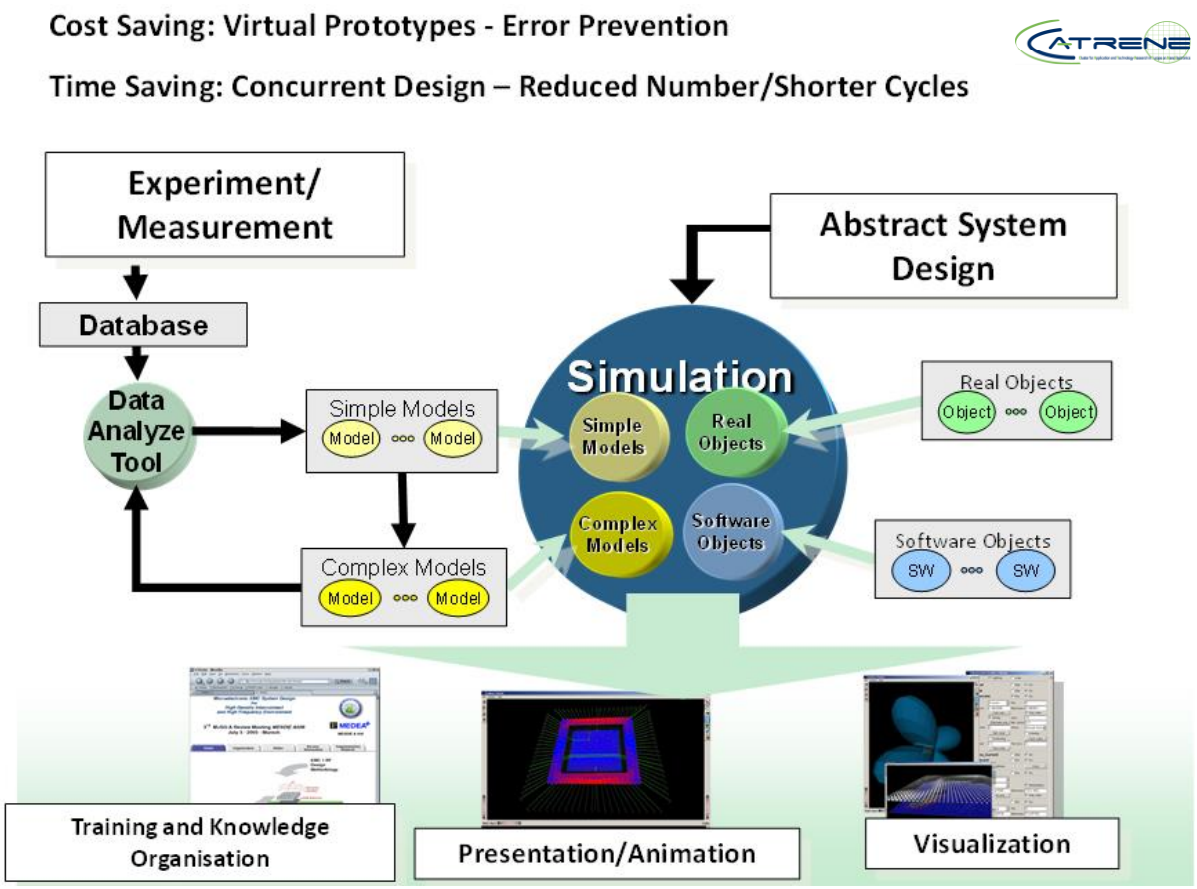

Abbildung 7: Virtuelle Entwicklung: Einsatz von Simulationsverfahren und –prinzipien

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

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

2.2.6 IP-Schutz und Interoperabilität

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

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

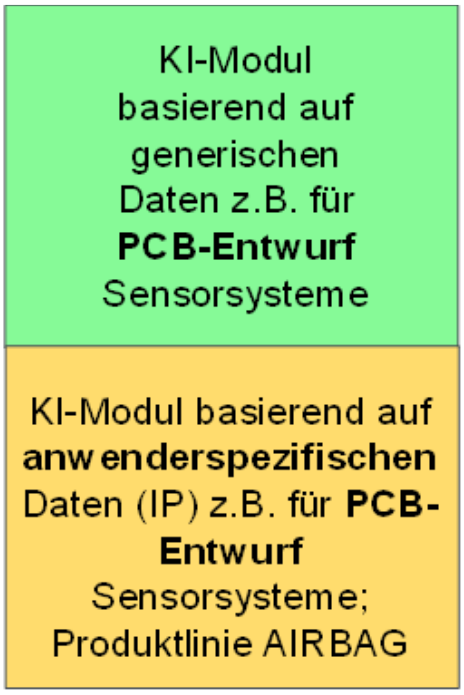

Abbildung 8: progressivKI-Ansatz zur Sicherstellung eines umfassenden IP-Schutz und Herstellung der Interoperabilität (Beipiel Anwenderebene #2 PCB-Entwurf)

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

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

2.2.7 Darstellung der wesentlichen Projektinnovationen

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

#	Vorwettbewerbliches Innovationselement	edaKI-Einsatzgebiet
IE.1	KI-Einsatz zur 20%igen Reduktion der zukünftig aufzuwendenden Ressourcen (Zeit, Personal, Kosten) für den Entwurf funktional-sicherer elektronischer KFZ-Systeme.	Entwurfsprozess; Objekt 1 bis Objekt 8; siehe auch Abbildung 10.
IE.2	Entwicklung einer neuartigen, modular aufgebauten sowie flexibel einsetzbaren KI-Plattform zur direkten Abdeckung der System-Entwurfsebenen |PCB-Entwurf| und |IC-Entwurf/Intelligente Sensorik|.	Entwurfsprozess; Objekt 1 bis Objekt 8; siehe auch Abbildung 10.
IE.3	Entwicklung von sicheren, verschlüsselten und intelligenten Konnektoren zu den einzelnen (verteilten) Modulen und Subsystemen der modularen KI-Plattform.	IP-Schutz/Interoperabilität/KI-Interaktions-modelle; siehe Abbildung 11; Abbildung 24.
IE.4	Portabilität und Übertragbarkeit der technischen Lösungen auf die individuellen Entwurfsprozesse durch Anordnung domänen- und applikationsspezifischer Konnektoren um einen leistungsfähigen KI-Kern.	KI-Module aus den 3 Segmenten Machine Learning (ML) – Deep Learning (DL) – Selbstlernende Prozesse (SP); siehe Abbildung 17.
IE.5	Erforschung neuartiger Konzepte für den kooperativen Betrieb von KI-Systemen in industriellen Entwurfsabläufen.	❑ Anwendungsebene #1: PCB-Entwurf; siehe Abbildung 11 + Abbildung 12. ❑ Anwendungsebene #2: IC-Entwurf/Sensorik; siehe Abbildung 15. ❑ Neuartige KI-basierte Unterstützung des Prinzips der Variantenkonstruktion.
IE.6	Innovations-Sprung und gesteigerte Wertschöpfung durch Einsatz und Adaption von OpenSource KI-Software. Vermeidung von zeitaufwendigen Parallelentwicklungen durch Nutzung des weltweit ausgereiften informationstheoretischen Knowhow mittels Open-Source KI-Software zur Entwicklung einer modular strukturierten KI-Plattform.	KI-Module aus den 3 Segmenten Machine Learning (ML) – Deep Learning (DL) – Selbstlernende Prozesse (SP); siehe Abbildung 17.
IE.7	KI-Zugang für KMU; es wird eine für jede Domain allgemein zugängliche KI-basierte Fähigkeiten-Basis aufgebaut und kontinuierlich weiterentwickelt (2-stufiger Ansatz zum IP-Schutz). Diese kann für die zukünftig notwendige Wettbewerbssteigerung durch KMU optimal genutzt werden.	KI-Modulbaukasten; adaptierbar auf spezifische KMU-Randbedingungen (keine durchgängige Werkzeugkette; OpenSource Simulationswerkzeuge; Beauftragung an externe Dienstleister;…; siehe Abbildung 18.
IE.8	Definition und Umsetzung eines reichhaltigen Anwenderökosystems mit komplexen Anforderungen, die in den entsprechenden Workstream des aktuellen GAIA-X Prozesses (GAIA-X Workstream 2 |Technische Umsetzung|) einfließen. Sicherstellung der Übertragbarkeit auf Entwurfsprozesse industrieller Anwender, die aktuell nicht am Vorhaben beteiligt sind, durch eine Cloud-Lösung (quasi als Goldstandard).	GAIA-X Ansatz für wertschöpfungsketten-übergreifende industrielle Entwicklungsabläufe; horizontaler + vertikaler Informationsfluss; siehe Abbildung 20.

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

Tabelle 2: progressivKI-Innovationselemente gemäß Schumpeter-Definition*

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

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

2.3 Ausgangssituation und Voraussetzungen, unter denen das Vorhaben durchgeführt wurde

2.3.1 Der Stand von Wissenschaft und Technik

Ökonomische Rahmenbedingungen des KI-Einsatzes

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

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

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

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

Konzepte und Begriffe des Maschinellen Lernens

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

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

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

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

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

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

KI für Domänen-spezifische Anwendungsfälle

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

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

KI-Frameworks

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

kommuniziert werden. Dies war der Ausgangspunkt der Forschung für progressivKI sowie der Wertschöpfung bei Bereitstellung der modularen strukturierten KI-Plattform im EDA-Bereich.

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

In den letzten Jahren wurde in großem Umfang weitere freie KI-Software zur Verfügung gestellt, die Anbindungen an zahlreiche Datenbank- und andere Systeme umfasst, komfortable Frameworks bietet oder auf TensorFlow aufbauende komplexere KI-Algorithmen zur Verfügung stellt. Hier ist vor allem die in Python verfügbare Bibliothek Keras zu nennen, die eine einheitliche und leicht nutzbare Schnittstelle zu mehreren Deep Learning Backends, insbesondere zu TensorFlow bietet, und das Importieren bereits vorhandener Modelle sowie großer Datenmengen vereinheitlicht und wesentlich vereinfacht. Dadurch ist es ohne Umwege möglich, wissenschaftlich belegte, vordefinierte und ggf. sogar vortrainierte neuronale Netze einzubinden und an die jeweiligen Anforderungen des Gesamtsystems anzupassen. Durch die zu Grunde liegende state-of-the-art API TensorFlow können die Modelle aber auch Low-Level adaptiert und manipuliert werden, um eine möglichst geringe Fehlerquote bei Klassifizierungen und Vorhersagen zu generieren [RamaSingh].

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

Verwendung von Simulation

Obwohl EDA-Tools eine hohe Menge unterschiedlicher Datenobjekte während des Entwurfsprozesses generieren und zusätzliche proprietären Daten (insbesondere Entwurfs-Regeln / Anforderungen / Constraints) zum Anlernen von KI-Algorithmen zur Verfügung stehen könnten, soll im Rahmen des Projektes die verfügbare Zahl an hochwertigen Daten durch zusätzliche dezidierte Simulationen (SI/PI/EMC) erweitert werden. Somit kann ein kombinierter Ansatz aus Simulationsdaten und gemessenen Daten zum effizienten Anlernen der eingesetzten KI-Algorithmen verwendet werden. Als Instrumente der Simulation kommen je nach abzubildendem Anwendungsfall Netzwerk-Simulationstools, Field-Solver, multiphysikalisch gekoppelte

Simulationstools (3D EM) und spezielle Simulationsverfahren für z.B. das Power-Ground-Verhalten zum Einsatz. Hierbei können mittels der Simulationstools, z.B. mit Hilfe eines Field-Solvers, in kurzer Zeit große Mengen unterschiedlicher zufällig generierter Schaltungsszenarien analysiert werden. Anschließend werden diese analysierten Szenarien hinsichtlich verschiedener Parameter (akzeptable EMV-Abstrahlung, zulässiger Cross-Talk zwischen Leitungen, etc.) bewertet.

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

Semantisches Interface

Wie bereits erörtert, wird ein entscheidender Punkt wird die Verfügbarkeit, Quantität und Qualität von Daten zum Anlernen des Systems sein. Um hier möglichst viele Daten von vielen Anwendern der Plattform zugänglich machen zu können, ist die Einführung einer einheitlichen internen semantischen Beschreibungssprache vorteilhaft, einschließlich automatisierter Übersetzungsprozesse in diese Sprache. Dieses Modul soll optional zur Verfügung gestellt werden und sich durch autarkes Lernen ebenfalls kontinuierlich verbessern. Die Topologie einer elektronischen Schaltung kann bereits gut durch ein Netz wiedergegeben werden. Ferner steht mit VHDL eine umfangreiche Beschreibungssprache für elektrische Schaltkreise zur Verfügung, die genutzt werden kann. Ein analoges Konzept wurde in [Esteban] für chemische Produktionsanlagen realisiert.

KI-Module für EDA-Anwendungen

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

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

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

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

Die steigende Entwurfskomplexität erfordert eine stärkere Zusammenarbeit auf allen Entwicklungsebenen. Durch den zunehmenden Einsatz von Machine- und Deep-Learning in komplexen Systemen, auch in Entwurfssystemen, werden mehr Mitarbeiter benötigt. Entwickler von Systemen bzw. Subsystemen und Komponenten benötigen Flexibilität bei der Bereitstellung von Inferenzmodellen. Weiterhin müssen die Entwickler von Inferenzmodellen z.B. über das notwendige Fachwissen in den Bereichen Optimierung, Variantenkonstruktion und Wiederverwendung von Komponenten verfügen. Sie müssen auch in der Lage sein, die für die Entwicklung von Inferenzmodellen notwendigen Informationen zusammenzuführen. Es werden Werkzeuge benötigt, die die wachsende Menge an Trainingsdaten bewerten und verwalten können. Insbesondere dem Lifecycle-Management der Inferenzmodelle kommt in diesen Zusammenhang eine hohe Bedeutung zu [Graeber].

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

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

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

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

Segment „KI zur Verifikation von Entwürfen“

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

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

Segment „Interpretation Design-relevanter Informationsquellen“

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

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

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

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

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

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

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

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

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

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

Segment „Berücksichtigung der EMV im Entwurfsprozess”

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

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

Segment „Lieferkettenübergreifende Qualitätssicherung“

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

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

Um den Anforderungen des IP-Schutz, der Komplexität von Systemen sowie dem Aspekt der unterschiedlichen Lieferanten gerecht zu werden, werden häufig Prädiktionsmodelle eingesetzt, welche von der eigentlichen Realisierung abstrahieren und nur die für den aktuellen Analysefall relevanten Aspekte versuchen zu bestimmen. Hierbei können die Modelle auf Erfahrungen mit verwandten Systemrealisierungen basieren, Experten- bzw. Domänenwissen oder aber auch Referenzmessungen. Ziel ist immer, den relevanten Aspekt des Systems mit Hilfe eines Modells abzubilden. Im Kontext von KI-basierten Methoden stellt die Gruppe des Imitation Learning (IL), was eine Untergruppe des Reinforcement Learning (RL) ist, interessante Konzepte zur Verfügung. Im Vergleich zu RL greift IL aber anstelle einer spezifizierten Kostenfunktion auf existierendes Expertenverhalten zurück. Im Falle von Behavioral Cloning erlernt das Modell das Expertenverhalten mittels des aktuellen Zustands sowie der ergriffenen Aktion [Pomerleau, BainSammut]. Das generelle Vorgehen bietet somit interessante Ansätze, um das Expertenwissen

von Entwicklern bzw. das Verhalten von Systemen mittels Modellen nutzbar zu machen. Eine Weiterentwicklung stellt das Direct Policy Learning (DPL) dar, bei welchem anstelle auf existierendes Expertenwissen auf ein interaktives Referenzsystem zurückgegriffen wird, dies ist insbesondere bei der Nachbildung von Systemverhalten vielversprechend. Ein etwas abweichender Ansatz versucht anstelle des Verhaltens die Kostenfunktion zu schätzen. Beim Inverse Reinforcement Learning (IRL) wird die Reward-Funktion der Grundlage der Demonstrationen des Experten erlernt und dann die optimale Entscheidung mit Hilfe von RL zu finden. Den Ansätzen inhärent ist, dass sie neben dem aktuellen Zustand auch die ergriffene Aktion spezifiziert sein muss.

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

MetaModellierung

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

- Auffinden einer geeigneten Metrik für die Bewertung der Qualität der Daten als Repräsentanten des Zustand- oder Designraumes.
- Modellierung des Ausgangszustand des jeweiligen Lernverfahrens.
- Analyse der Veränderung des Zustandes im mathematischen Modell aufgrund des Lernprozesses.
- Einordnen des Problems entsprechend des auftretenden dynamischen Verhaltens in eine Problemklasse.

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

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

Die mathematische Analyse betrachtet eine große Familie von Algorithmen als Entität und beschreibt die Struktur dieses Objektes in Hinblick auf die Verwendbarkeit zur Lösung gewisser Probleme. Diesen Ansatz Mathematik zu betreiben, hat S. Smale als richtungsweisend für das 21.

Jahrhundert identifiziert. Die mathematische Analyse sollte in diesem Projekt zur rigorosen Qualitätssicherung der in der Plattform implementierten Verfahren verwendet werden. Dabei spielen zusammenfassend die folgenden Punkte eine wichtige Rolle:

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

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

Im Bereich der Datenerfassung und Verwaltung sind im Zuge der vergangenen Jahre zwar einige neue Technologien entstanden, wie zum Beispiel sogenannte „Data Lake“ Systeme, die es ermöglichen, Daten aus unterschiedlichen Quellen miteinander in einen Kontext zu bringen, allerdings klären solche Systeme nicht, welche Daten sinnvoll für die Erfassung sind. Die besondere Herausforderung bei der Anwendung von KI in der effizienten Entwicklung von eingebetteten Systemen wird sein, zunächst die Art der Daten, die für eine KI-Anwendung relevant sind, zu identifizieren und dies auch dynamisch erweitern zu können. Insbesondere muss darauf geachtet werden, dass nicht allein die Daten, die zu einem erfolgreichen Schritt im Entwicklungsprozess geführt haben, gesammelt werden (wie es zum Beispiel mit der Versionierung der finalen Tool-Reports bei der Beendung eines Entwicklungsschrittes gemacht wird), sondern auch die Daten der Zwischenschritte, die notwendig waren, zu dem Ergebnis zu kommen. Somit würde sichergestellt, dass eine zukünftige KI nicht auf vorgeprägten, sondern umfassenden Daten trainiert werden kann. Weiterhin, bedeutet dies auch, dass man klären muss, welche Strukturierung dieser Daten notwendig ist, um einen effizienten Zugriff auf diese Daten zu gewährleisten und, um sicherzustellen, dass diese Daten nicht auf konkrete Entwickler zurückführbar sind- um betriebliche Auflagen zu wahren.

Maschinenlernen zur Reduktion von Modellfehlern

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

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

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

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

Insbesondere wenn das Modell bereits eine günstige Struktur aufweise, kann der Modellierungsfehler als so klein angenommen werden, dass ein lineares Modell für eine sehr genaue Modellfehleridentifikation vollständig ausreichend ist. Dieses Paradigma ist derzeit aktuell und viel diskutiert in der Computational Electromagnetics-Community (z.B. [Chinesta]). Eine solche Erweiterung von [modularKI] erhöht die Sicherheit der Plattform, sinnvolle Ergebnisse zu liefern, die Möglichkeit, zusätzliche Sicherheit durch Crosschecks unterschiedliche Verfahren zu erhalten und mindert somit auch das Projektrisiko von progressivKI.

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

Identifikation geeigneter Hardware

Nach dem im vorherigen Abschnitt allgemeine Konzepte, welche für die angestrebte Anwendungsdomäne interessant sein könnten, vorgestellt wurden, soll in diesem Abschnitt dedizierte Ansätze zur Einbeziehung von Hardwareeigenschaften zur Prädiktion des Softwareverhaltens vorgestellt werden. In [AbelRein] wird ein messbasierter Ansatz zur Modellierung des Cache-Ersetzungsverhaltens vorgestellt. Die Autoren beleuchten, an welchen Stellen der Einsatz von maschinellem Lernen die hohen Anforderungen an die Erstellung des Modells reduzieren können. Ein ähnlicher auf Messungen basierter Ansatz zur Prädiktion von Laufzeiteigenschaften ist in [CornVie] vorgestellt. Ähnlich zu [AbelRein] bieten sich KI-gestützte Modelle zur Reduktion der Komplexität sowie zur Steigerung der Adaptionsfähigkeit der Modelle an. Hier kann progressivKI mit der Generierung von Modellen basierend auf Experten- und Erfahrungswissen unterstützen und die rein messungsbasierten Ansätze erweitern. Der in [Graves] vorgestellte Ansatz ist rein KI-basiert. Mit Hilfe eines neuronalen Netzwerks, dass externen

Speicher lesen und schreiben kann (Differentiable Neural Computer, DNC), lernt das Modell mittels unterschiedlicher Referenz-Demonstrationen. Die Autoren demonstrieren den Ansatz am Beispiel von Graphen-basierten Experimenten, was vielversprechend für die Übertragung auf Basisblock-Abfolgen und somit die Laufzeitprädiktion von Software ist. Abschließend soll ein KI-basierter Ansatz, welcher die Laufzeitprädiktion mit Hilfe von Referenzmessungen auf unterschiedlichen Systemen angeht, vorgestellt werden. Hierbei wird ein Modell für den Wechsel von einer Hardware-Architektur auf eine Zweite trainiert. Mit Hilfe dieses Modells können Aussagen über die Zielplattform, bzw. das neue System, basierend auf Erfahrungen mit einem zweiten System getroffen werden. Viele der betrachteten Arbeiten bieten interessante Ansätze zum Entwurf von Prädiktionsmodellen im Kontext von progressivKI. Basierend auf den im Projekt identifizierten Datenquellen, bzw. deren Umfang, können unterschiedliche Ansätze adaptiert bzw. kombiniert werden. Eine vielversprechende Grundlage zur Erweiterung stellen die Arbeiten in [CornVie] dar.

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

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

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

2.3.2 Bisherige Arbeiten des Antragstellers

09-HOOD

Unternehmensvorstellung

Die HOOD GmbH ist ein führendes Unternehmen im Bereich des Requirements-Engineerings im deutsch-sprachigen Raum. HOOD steht dabei für herausragende Expertise, was Ermittlung, Dokumentation und Abstimmung von Anforderungen angeht. Die REConf ist eine deutschlandweit bekannte und zudem größte Konferenz zum Thema Requirements Engineering und wird, mit Ausnahme von 2020, jährlich durch HOOD veranstaltet.

Die Kunden von HOOD schätzen den großen Fundus an RE-Methoden und Praktiken, den HOOD ihnen bedarfsgerecht z.B. in Form von Trainings oder auch entwicklungsbegleitend vermittelt.

Da es im Requirements Engineering zu einem guten Teil um Verständnis und inhaltliche Abstimmung geht, ist HOOD bei vielen Kunden stark in Fragestellungen der Zusammenarbeit zwischen Anforderungsgebern und Anforderungsnehmern involviert und bietet seinen Kunden kompetente Lösungen an.

Projektbezogene Kompetenzen und Schwerpunkte

HOOD bringt in das Fördervorhaben die langjährige Erfahrung und Kompetenz im Requirements Engineering und Systems Engineering, sowohl mit agilen als auch traditionellen Vorgehensweisen, ein.

DESIRe® (dynamic expert system for improving requirements) ist z.B. ein Produkt von HOOD welches Anforderungsautoren oder -prüfer bei der Sicherstellung der Qualität von natürlichsprachlich formulierten Anforderungen unterstützt. Es handelt sich hierbei um ein Werkzeug, das abhängig von verwendeten Wörtern (z. B. mehrdeutigen Wörtern, Verben etc.) in der ausgewählten Anforderung vordefinierte Fragen in einem Fenster anzeigt. Dies sind Fragen, die auf mögliche Schwächen der Anforderung hinweisen. Die Idee hierbei ist, dass der Anforderungsautor durch die gedankliche Beantwortung der gestellten Fragen die Anforderung inhaltlich überarbeitet.

Relevante Vorgängerprojekte

Fördervorhaben autoSWIFT

(Förderkennzeichen 16ES0356-61 im Förderprogramm IKT 2020, Laufzeit 01.09.2015 - 30.11.2018)

Ziel des BMBF-Projektvorhabens autoSWIFT war es, mit einer neuen gemeinsamen Methodik und entsprechender Infrastruktur die Zusammenarbeit innerhalb der Wertschöpfungskette signifikant zu verbessern, um innovative und hochqualitative Fahrzeugkomponenten auf Basis neuester Technologien der Mikroelektronik wesentlich früher und passgenauer als bisher marktreif bereitstellen zu können. Im Teilvorhaben „Requirements Engineering“ analysierte HOOD die Formen der Zusammenarbeit heutiger Partner entlang der Wertschöpfungskette der Automobilindustrie. Dabei wurden die Defizite der aktuellen Zusammenarbeit deutlich, die vor allem durch bilaterale Kommunikation und dem starken Bedürfnis des Schutzes eigenen geistigen Eigentums geprägt sind. Im Rahmen des Forschungsvorhabens konnten neue Wege und Werkzeuge skizziert werden, die es ermögliche, Innovationen schneller im Automobil realisieren zu können.

Fördervorhaben SAFE4I

(BMBF Förderkennzeichen 01IS17032, Laufzeit: 1.10.2017 bis 30.9.2021)

Das Ziel des vom BMBF geförderten Forschungsvorhabens SAFE4I ist die Beschleunigung der Entwicklung funktional sicherer Software. Dabei werden alle Teile der Software betrachtet, die nötig sind, um kundenspezifische Automatisierungslösungen für Industrie 4.0 Anwendungen zu realisieren. Darunter fallen Automatisierungssoftware, Steuerungssoftware, eingebettete Software und Firmware. Dieses Ziel soll durch die strikte Trennung des Entwurfs der geforderten Software-Funktionalität von den Maßnahmen zur Software-Absicherung erreicht werden.

Die Rolle von HOOD liegt in der wirksamen Verknüpfung des Requirements Engineerings mit Model Based Systems Engineering unter Berücksichtigung agiler Prinzipien, wie z.B. bei der Erhebung und Validierung von Anforderungen an das Requirements-Engineerings von Software-

Safety-Maßnahmen, der Entwicklung neuer Methoden basierend auf diesen Anforderungen sowie der Konzeption von Schulungen für diese Methoden

Fördervorhaben SATiSFy

(BMBF Förderkennzeichen 16KIS0826, Laufzeit 1.5.2018 – 30.04.2021)

Das Ziel des vom BMBF geförderten Forschungsvorhabens SATiSFy ist es, Techniken zur formalen Erfassung und frühzeitigen Verifikation für Systeme zum autonomen Fahren zu entwickeln, um die notwendigen Security- und Safety Anforderungen im Ansatz sowohl auf Hardware- als auch auf Softwareebene gesamtheitlich zu spezifizieren, zu visualisieren und sie insbesondere vor einem abschließenden Integrationstest bereits formal validieren zu können.

Das Ziel des Teilvorhabens von HOOD ist:

- Methoden zur gesamtheitlichen Spezifikation analysieren.
- Geeignete Methoden und Praktiken zur Ermittlung von Safety- und Security Anforderungen identifizieren.
- Informationsmodelle zur Strukturierung von Safety- und Security-Anforderungen entwickeln.
- Modellierungstechniken zur Visualisierung von Safety- und Security-Anforderungen untersuchen.
- Agile Vorgehensweisen zur frühzeitigen Validierung von Safety- und Security-Anforderungen erproben.

2.4 Abgrenzung und Zusammenarbeit mit anderen Projekten

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

Rekonfigurierbare Hardwareplattform zur KI-basierten Sensordatenverarbeitung für das autonome Fahren

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

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

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

KI-Prozessorarchitekturen für Radarmodule im autonomen Fahrzeug

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

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

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

Elektronik für verteilte Künstliche Intelligenz zur sensorbasierten Prozess- und Zustandskontrolle

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

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

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

Sichere und intelligente Elektroniksysteme für vertrauenswürdige Elektronikprodukte in Industrie 4.0

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

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

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

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

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

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

KI-Marktplatz (BMWi - KI-Innovationswettbewerb)

Ökosystem für Künstliche Intelligenz in der Produktentstehung

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

https://ki-marktplatz.com/

KIPS (Technologieförderung Sachsen, KI-Plattform Sachsen)

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

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

3 Technische Ergebnisse

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

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

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

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

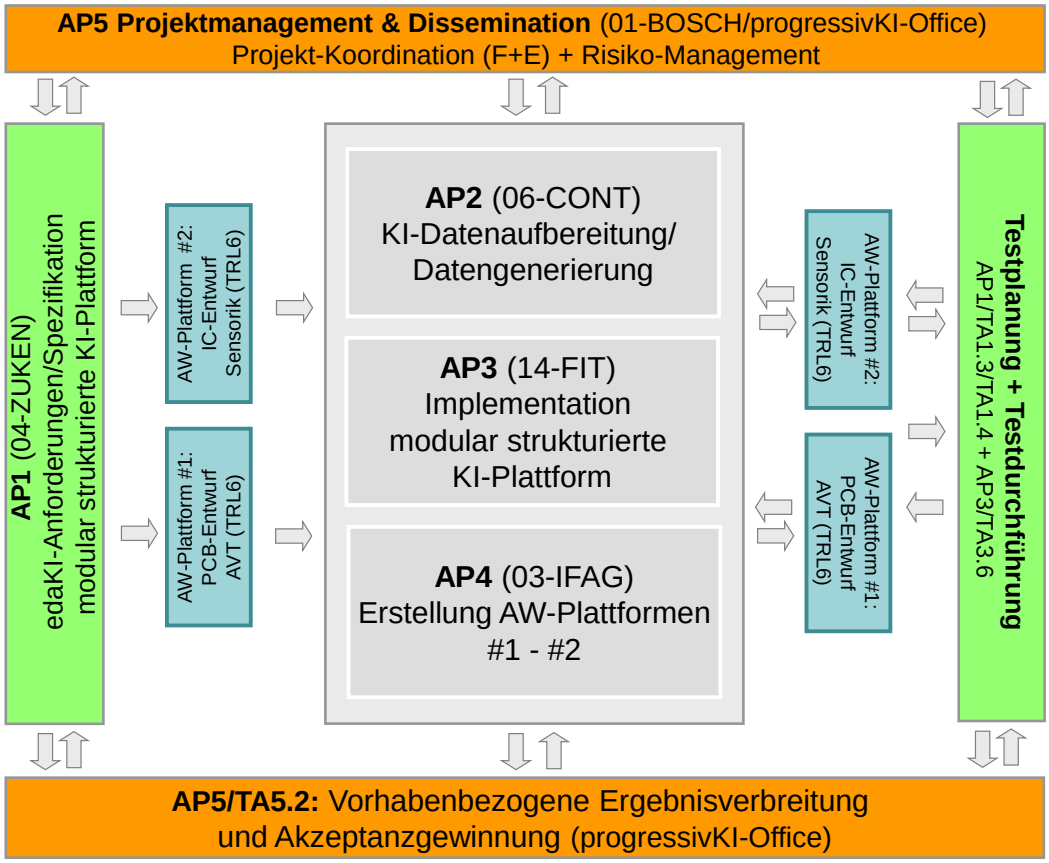

Abbildung 9: Abhängigkeiten und Interaktion der progressivKI-Arbeitspakete

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

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

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

Dieses Arbeitspaket definierte und lieferte:

- Voruntersuchungen zur Erstellung des KI-Konzeptes |KI-gestützter Systementwurf für den Bereich Elektronikentwicklung|.
- Definition der Ausprägungen für die Anwendungsebenen #1: PCB-Entwurf; #2: IC-Anwendung/Sensorik.
- Entwicklung von Vorlagen für eine prototypische Implementierung von KI-Modulen und die Analyse der Ergebnisse.
- Sichtung relevanter Fallbeispiele zu KMU-Entwicklungsprozessen.
- Erstellung eines Konzeptes für einen modularen Baukastens zur Entwicklung von anwendungsspezifischen Lösungen.
- Erstellung einer Spezifikationsmatrix zur Konzeptionierung von modularen KI-Plattformelementen.
- Gewährleistung eines optimalen Datenaustausches zwischen KI-Modulen und vorhandenen Entwurfsumgebungen.
- Anforderungen an Datenaustausch über Unternehmensgrenzen hinweg (IP-Schutz).
- Verfahren zur Sicherung von Erfahrungswissen generiert durch KI-Einsatz.

- Beschreibung und Bewertung von Markteffekten durch den KI-Einsatz auf KMU.
- Dokumentation der Ergebnisse zur Überführung in ein Lastenheft.
- Festlegung des funktionalen Rahmens des geplanten Chat-Bots. Der funktionale Rahmen könnte sich aus einer Integration von RASA NLU (Toolikt) und neuronalen Netzwerk (NN)-Methoden zusammensetzen. Der Umsetzung von Prinzipien der Entitäts-Extraktion, der Absichtserkennung und der Schlüsselwortzuordnung kommt dabei eine hohe Bedeutung zu. Zu klären ist, ob auch eine regelbasierte KI-Komponente in den funktionalen Rahmen integriert werden sollte.

Geplante Ergebnisse von AP1 waren:

- Im Rahmen dieses Arbeitspakets waren mehrere Schlüsselergebnisse vorgesehen. Zunächst erfolgte die Definition und Spezifikation der erforderlichen KI-Algorithmen, wobei der Schwerpunkt auf der funktionalen Sicherheit für die zu automatisierenden Entwurfsabläufe lag. Gleichzeitig wurden die Schnittstellen und Datenformate spezifiziert, um einen sicheren und effizienten Datenaustausch zu gewährleisten.

- Des Weiteren wurden KI-verwertbare Regelwerke erstellt, basierend auf Entwurfs- und Designregeln. Hierbei erfolgte die Spezifikation der Datenaufbereitung und die Festlegung von Anforderungen an die KI-Module aus der Perspektive der Entwurfsprobleme, die sich aus den Use Cases der beiden Anwendungsebenen ergaben.

- Eine umfassende Analyse verschiedener Open-Source KI-Frameworks wurde durchgeführt, wobei der Fokus auf den Eingangsdatenformaten lag. Dabei wurden Synergien zwischen den genutzten Frameworks herausgearbeitet, und die KI-Algorithmen wurden spezifiziert.

- Die Ergebnisse aus den Arbeitsschritten AT1.1 bis AT1.3 sowie AT 2.1 dienten als Grundlage für die Spezifikation der Anwendungsebenen und ihrer Strukturen. Zusätzlich wurden nutzbare Datenquellen der KI-Plattformen analysiert und klassifiziert, um eine umfassende Grundlage für die weiteren Entwicklungsphasen geschaffen zu haben.

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

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

Die folgenden Themen mussten im Detail bearbeitet werden:

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

Teilbeitrag 1.1.9: KI-Einfluss auf die Struktur von Entwicklungsprozessen in den projektspezifischen Wertschöpfungsketten (09-HOOD)

Ziele

In diesem Teilbeitrag sollen die strukturellen und kooperativen Veränderungen, die durch den Einsatz von KI in den Entwicklungsprozessen erforderlich sind, untersucht werden. Im Fokus stehen:

- **Veränderung der Zusammenarbeit:** Untersuchung der Auswirkungen des Einsatzes von KI-Systemen auf die Zusammenarbeit der Akteure in der Wertschöpfungskette.
- **Anpassung der Entwicklungsprozesse:** Analyse und Anpassung der Strukturen von Entwicklungsprozessen aufgrund der Einführung KI-gestützter Entwurfsprozesse.
- **Mindset-Entwicklung:** Förderung eines geeigneten Mindsets für die Entwicklung sicherer Systeme im Kontext der Verwendung von KI.

Problemstellung

Die Einführung von KI-gestützten Entwurfsprozessen in bestehende Wertschöpfungsketten führt zu einer grundlegenden Veränderung der etablierten Prozesse und Strukturen, was potenziell zu Konflikten oder Missverständnissen zwischen den beteiligten Akteuren führen kann. Die Notwendigkeit diese neuen Prozesse sicher und effizient zu gestalten erfordert, dass alle Beteiligten nicht nur technische Anpassungen vornehmen, sondern auch ihre Denkweise und Arbeitsweise entsprechend anpassen.

Lösungsweg und Ergebnisse

Der Lösungsweg für den Teilbeitrag fokussierte sich auf die systematische Untersuchung und Anpassung der Entwicklungsprozesse im Kontext der Einführung von KI-gestützten Systemen in die Wertschöpfungsketten. Der Lösungsweg sieht die folgenden Schritte vor:

- Konsolidierung von Entwicklungsprozessen:
  a) Analyse der bestehenden Entwicklungsprozesse der beteiligten Akteure
  b) Harmonisierung und Zusammenführung divergierender Ansätze und Methoden
  c) Etablierung einer einheitlichen und effizienteren Vorgehensweise
- Betrachtung von Sicherheitsaspekten von KI-Systemen
  a) Identifikation und Bewertung sicherheitsrelevanter Aspekte bei der Implementierung von KI-Systemen

b) Analyse potenzieller Risiken
c) Definition von Sicherheitszielen
d) Entwicklung von Maßnahmen zur Gewährleistung der Sicherheit der Systeme

- Zusammenführung der Erkenntnisse

Virtuelle Sitzungen zur Konsolidierung von Entwicklungsprozessen:

In mehreren virtuellen Sitzungen der Arbeitsgruppe#2 wurden die bestehenden Entwicklungsprozesse der Konsortialpartner analysiert. Dabei lag der Fokus auf der Identifizierung der unterschiedlichen Artefakte, Aktivitäten und Rollen, die in den Entwurfsprozessen für Leiterplatten (PCB) und integrierte Schaltungen (IC) eine Rolle spielen. Diese Prozesse wurden diskutiert, um sie besser auf die Anforderungen des KI-Einsatzes abzustimmen. Die Abbildung zeigt die in der Arbeitsgruppe#2 erarbeitete detaillierte Übersicht der Entwicklungsprozesse, die die verschiedenen Aktivitäten, Artefakte und Rollen entlang der Wertschöpfungsketten illustriert. Diese Visualisierung diente dazu, die komplexen Beziehungen zwischen den verschiedenen Elementen zu verdeutlichen und Ansatzpunkte für eine harmonisierte Zusammenarbeit zu identifizieren.

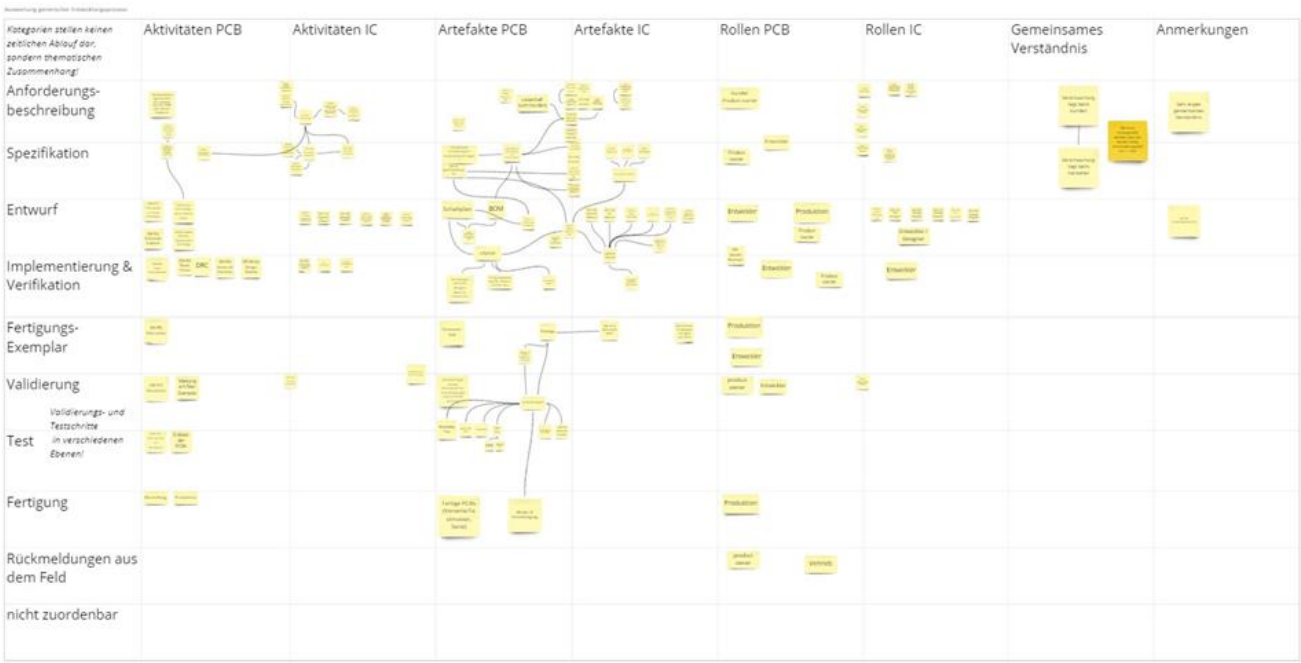

Abbildung 10: Diskussion eines generischen Entwicklungsprozesses in AG#2

Workshops zur Sicherheit von KI-Systemen:

Ein zentraler Schritt im Lösungsprozess war die Durchführung eines Workshops, der sich mit der Sicherheit von KI-Systemen befasste. Hier wurden drei Kernfragen diskutiert:

- Was verstehen wir unter Sicherheit im Kontext von KI?
- Welche Sicherheitsaspekte sind speziell im Projekt "progressivKI" von Bedeutung?
- Welche laufenden und geplanten Aktivitäten adressieren diese Sicherheitsaspekte?

Die Abbildung zeigt die Fragestellungen und Themenbereiche, die im Workshop behandelt wurden.

Abbildung 11: Fragestellungen der Workshop Teilnehmer zu Sicherheit im Kontext von KI

Zusammenführung der Erkenntnisse:

Die gewonnenen Erkenntnisse aus den virtuellen Sitzungen und dem Workshop wurden zusammengeführt, um eine umfassende Anpassung der Entwicklungsprozesse vorzunehmen. Hierbei wurde besonderes Augenmerk darauf gelegt, wie die durch KI-bedingten Änderungen in den Prozessen strukturiert und nachhaltig in die Wertschöpfungskette integriert werden können.

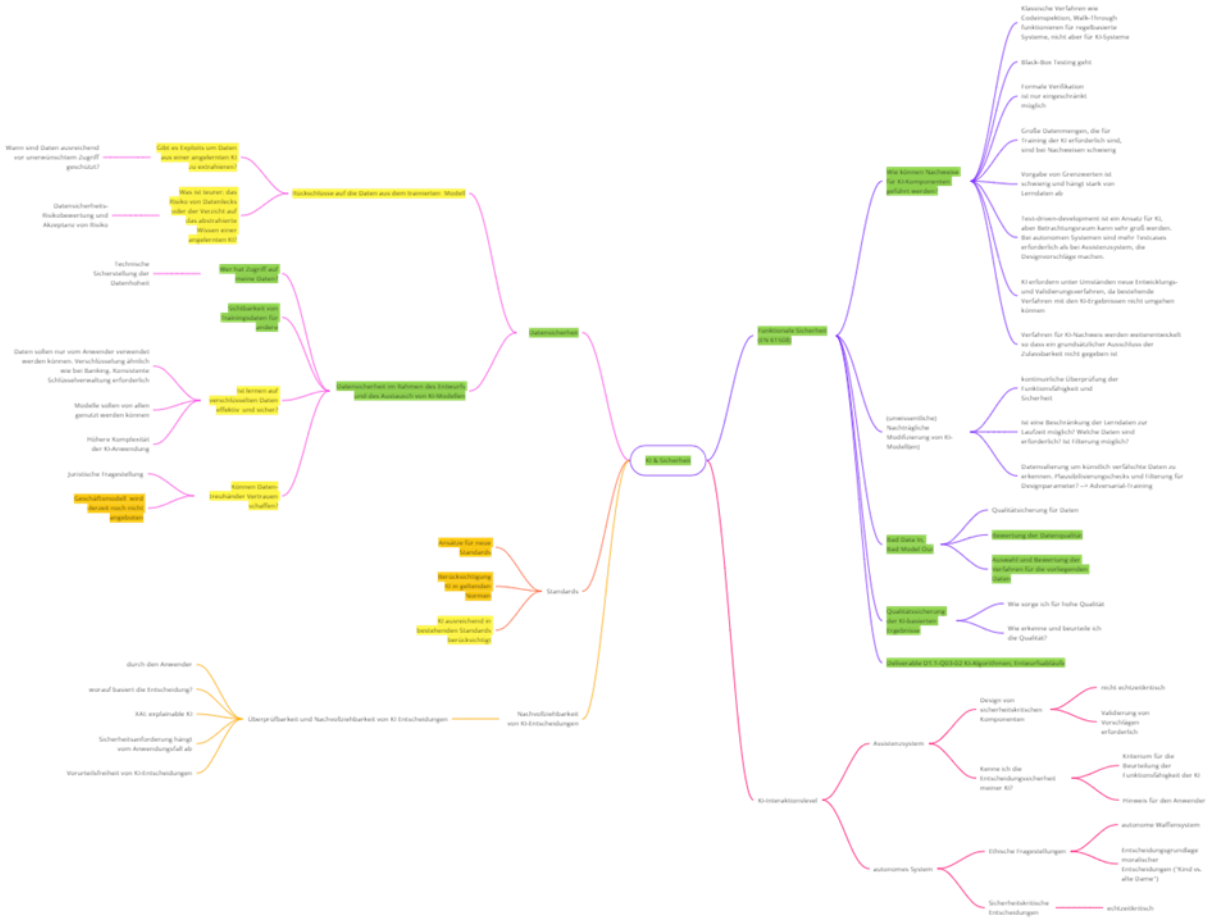

Abbildung 12: Strukturierung der Sicherheitsaspekte im Kontext von KI

Die Abbildung illustriert einen zusammenhängenden Überblick über die verschiedenen Sicherheits- und Entwicklungsaspekte, die im Laufe des Projekts diskutiert wurden. Diese Mindmap zeigt die Vernetzung der Themen und dient als Grundlage für die konsolidierte Anpassung der Prozesse. Besonders hervorzuheben ist die Strukturierung der Sicherheitsaspekte, die nach ihrer Priorität und Relevanz für das Projekt klassifiziert wurden (transparent für KI-relevant, grün für direkt relevant, gelb für indirekt relevant, orange für Verwertbarkeit nach Projektende).

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 1.2.9: KI-Anforderungen der partner-spezifischen Wertschöpfungsketten und Ermittlung von Einsatzpotentialen (09-HOOD)

Ziele

Dieser Teilbeitrag zielt darauf ab, die Integration und den Nutzen von KI in den spezifischen Prozessen der Projektpartner zu maximieren:

- **Erhebung der Anforderungen an KI-Systeme**:
  Identifizieren der spezifischen Anforderungen der Projektpartner an gemeinsam genutzte KI-Systeme, insbesondere für den KI-gestützten Entwurfsprozess sowie für die Unterstützung bei der Lastenhefterstellung und -analyse und der Modellierung.
- **Ermittlung von Einsatzpotentialen für KI**:
  Untersuchen der Einsatzpotentiale von KI-Systemen in den partner-spezifischen Wertschöpfungsketten, um geeigneter Anwendungsfälle zu identifizieren.

Problemstellung

Derzeit ist oft unklar, wie KI-Systeme optimal in die spezifischen Wertschöpfungsketten der Projektpartner integriert werden können, insbesondere im Kontext des KI-gestützten Entwurfsprozesses und der Unterstützung bei der Lastenhefterstellung und -analyse. Es besteht Unsicherheit darüber, welche Anforderungen an diese KI-Systeme gestellt werden müssen, um sowohl den Schutz geistigen Eigentums als auch eine effektive Zusammenarbeit zwischen den Partnern zu gewährleisten. Zudem stellt sich die Herausforderung, geeignete Szenarien für den Austausch von KI-Modellen und Daten zu definieren, die den unterschiedlichen Bedürfnissen und Schutzanforderungen der Partner gerecht werden.

Lösungsweg und Ergebnisse

Der Lösungsweg zur Ermittlung der KI-Anforderungen und des Einsatzpotenzials in den partner-spezifischen Wertschöpfungsketten umfasste mehrere Phasen, die darauf abzielten, die optimalen Einsatzmöglichkeiten von KI in den Entwicklungsprozessen der Projektpartner zu identifizieren und zu implementieren:

1. Erhebung der Anforderungen durch Use Case Stories und Anwender Use Cases:

- **Identifikation der Use Case Stories:**
  Zu Beginn wurden die spezifischen Anforderungen der Partner in Form von Use Case Stories erfasst. Diese Stories beschrieben die wesentlichen Herausforderungen und Bedürfnisse der Partner in ihren Entwicklungsprozessen. Jede Story bestand aus einer Beschreibung der Rolle im Entwicklungsprozess, dem spezifischen Prozessschritt, den Aktivitäten, die durch KI unterstützt werden sollen, und der Motivation, warum diese Unterstützung notwendig ist.
- **Ableitung von Anwender Use Cases:**
  Die Use Case Stories wurden anschließend in Anwender Use Cases überführt, die detailliert beschrieben, wie diese Anforderungen in den jeweiligen Entwicklungsprozessen umgesetzt werden könnten. Dabei wurden relevante Akteure, unterstützende Systeme, Vorbedingungen und der grundlegende Ablauf des Prozesses identifiziert und analysiert. Diese Use Cases halfen, die konkreten Schritte zu definieren, in denen KI-Systeme eingesetzt werden könnten.

2. Analyse des KI-Potenzials in den Use Case Schritten:

- **Systematische Bewertung:**
  Jeder identifizierte Schritt in den Anwender Use Cases wurde auf sein Potenzial hin untersucht, durch KI unterstützt zu werden. Diese Analyse umfasste die Formulierung spezifischer Problemstellungen, die sich auf Wissensprobleme, die Komplexität der Aufgaben und die potenzielle Fehleranfälligkeit bezogen. Beispielsweise wurde untersucht, wie gut eine KI-Anforderungen identifizieren, diese zuordnen und Widersprüche erkennen kann**.**
- **Charakterisierung der Aktivitäten:**
  Die Aktivitäten wurden hinsichtlich der Häufigkeit des Auftretens, der Notwendigkeit von Expertenwissen und der Möglichkeit zur Lösung durch klassische Algorithmen charakterisiert. Dies half zu bestimmen, welche Aktivitäten für KI besonders geeignet waren und welche eher durch traditionelle Methoden unterstützt werden sollten**.**

3. Entwicklung und Definition von KI-Stories:

- **Formulierung der KI-Stories:**
  Basierend auf den Ergebnissen der Analyse wurden spezifische KI-Stories entwickelt. Diese Geschichten konkretisierten, wie die KI in den verschiedenen Schritten der Use Cases eingesetzt werden sollte. Zum Beispiel könnte eine KI relevante Anforderungen identifizieren, diese den richtigen Datenblättern zuordnen und potenzielle Widersprüche erkennen, was den Entwicklungsprozess effizienter und weniger fehleranfällig macht.

- **Lösungsansätze für die KI-Stories:**
  Für jede KI-Story wurden mögliche Lösungsansätze entwickelt. Dies beinhaltete die Auswahl geeigneter Algorithmen, die Identifikation benötigter Daten und die Bestimmung der Schnittstellen zu bestehenden Systemen. Es wurde auch festgelegt, wie die KI in den Prozess integriert werden könnte, ob sie beispielsweise selbstständig Vorschläge macht, Entscheidungen trifft oder Aufgaben vollständig autonom ausführt.

4. Analyse von Varianten der Zusammenarbeit:

- **Diskussion der Hauptvarianten:**
  Identifikation und Analyse der Hauptvarianten für die Zusammenarbeit zwischen den Partnern:
  a. **Interne Nutzung:**
     Nutzung von Modellen und Daten ausschließlich intern, ohne Austausch zwischen den Partnern**.**
  b. **Geteilte Daten:**
     Teilen von Daten zwischen den Partnern, während die Modelle proprietär bleiben.
  c. **Geteilte Modelle:**
     Austausch sowohl von Daten als auch von Modellen zwischen den Partnern.
  d. **Bereitstellung von Modelldiensten:**
     Modelle werden als Dienstleistung bereitgestellt, ohne dass direkter Zugriff auf die Modelle oder Daten erfolgt.

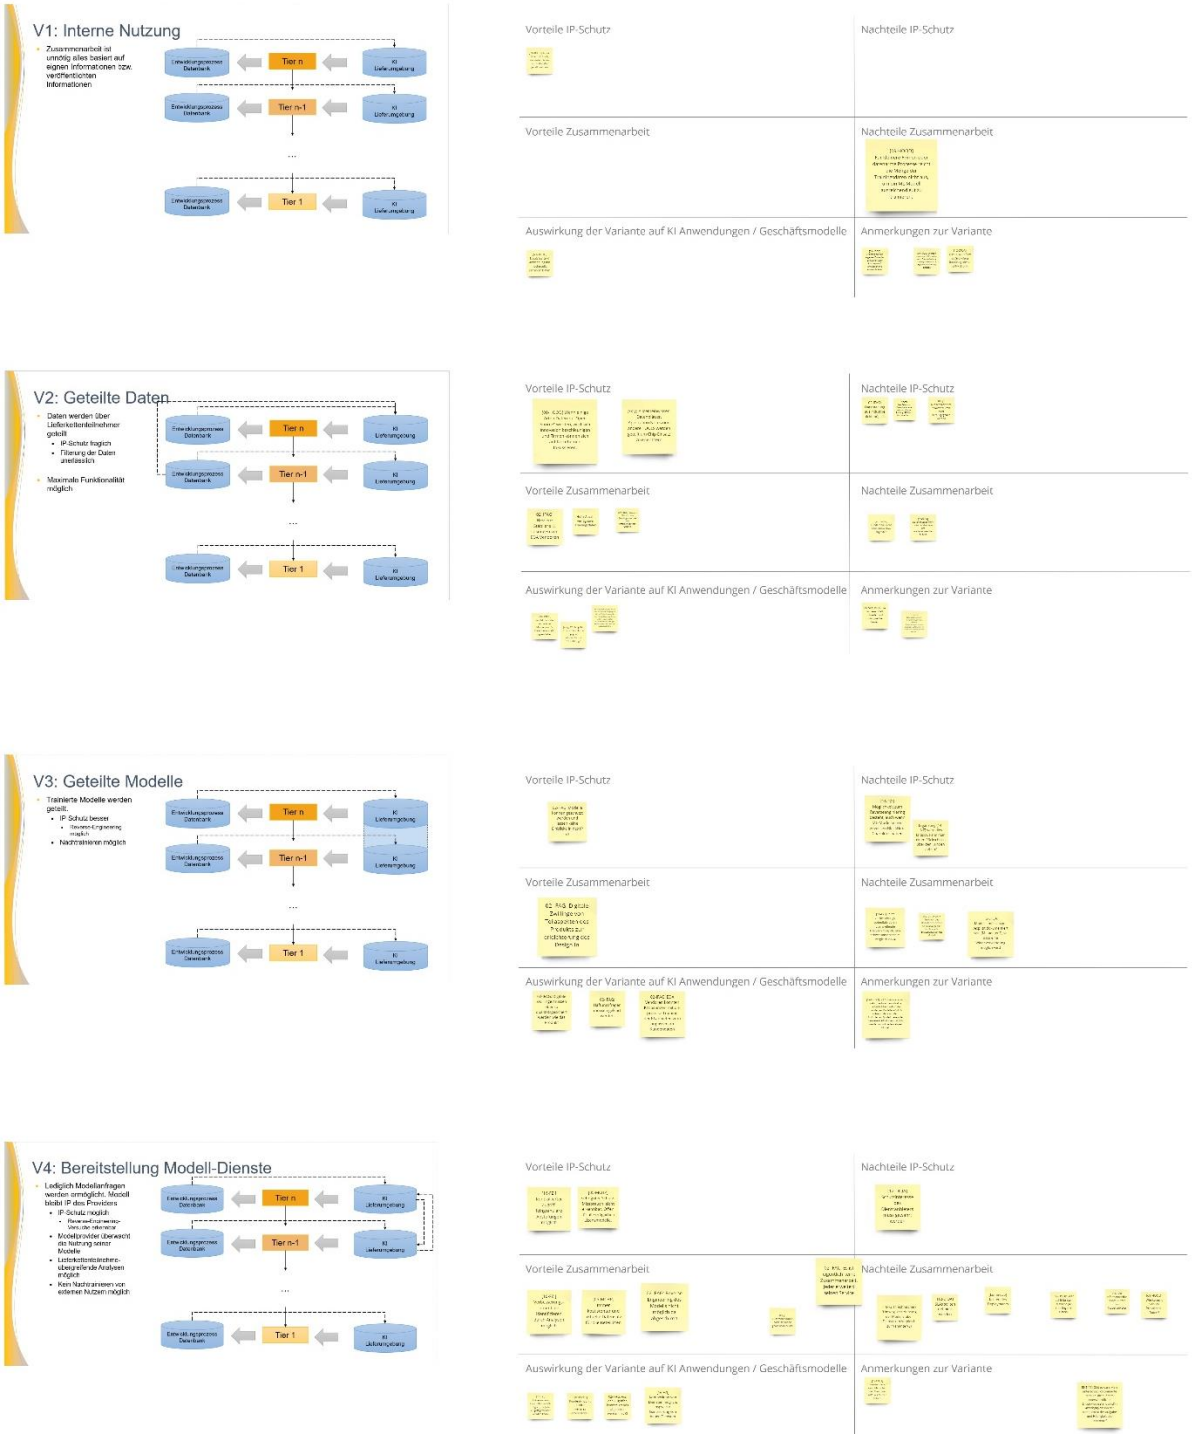

Abbildung 13: Diskussion der Varianten der Zusammenarbeit in AG#2

Bewertung der Varianten:
Jede Variante wurde hinsichtlich ihrer Vor- und Nachteile für den IP-Schutz und die Zusammenarbeit bewertet.

5. Umsetzungsstrategie und Präsentation der Ergebnisse:

- **Priorisierung und Implementierung:**

Auf Basis der Analyse wurde eine Umsetzungsstrategie entwickelt, die die priorisierten Use Cases und KI-Lösungsansätze in den Entwicklungsprozess integriert. Diese Strategie umfasste die Planung und Implementierung der KI-Lösungen in den Wertschöpfungsketten der Partner.

Die umfassende Analyse und der strukturierte Lösungsweg führten zu mehreren Ergebnissen:

1. Entwicklung des KI4RE-Lösungskonzepts:

Das KI4RE-Lösungskonzept war ein zentrales Ergebnis des Projekts.

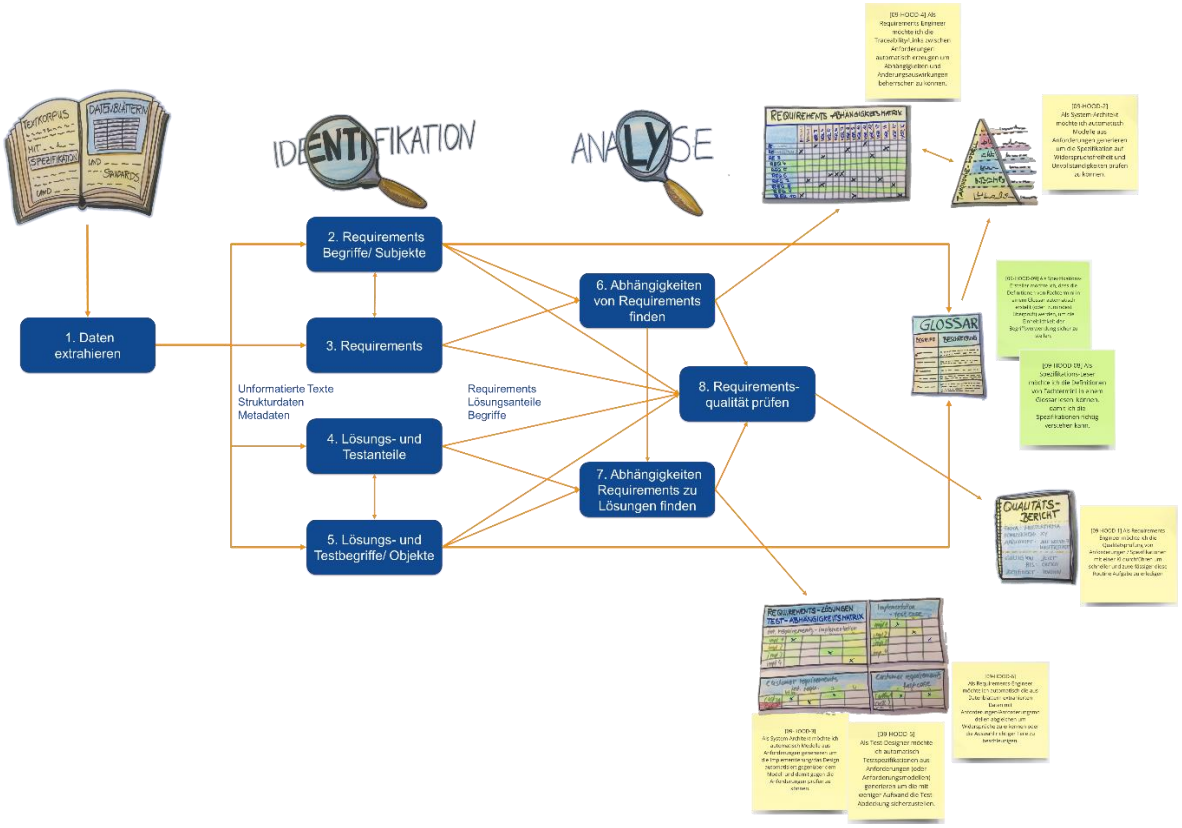

Abbildung 14: KI4RE – Unterstützung des RE durch künstliche Intelligenz

Es beschreibt die Transformation von Quelldaten in Artefakte des Requirements Engineering, die den in den KI-User Stories formulierten Anforderungen gerecht werden. Das Konzept umfasst alle erforderlichen Arbeitsschritte von der Erhebung der Quelldaten bis zur Erstellung der RE-Artefakte. Dieses Lösungskonzept wurde auf der Konferenz „Tag des Systems Engineering 2022“ vorgestellt.

2. Bewertung der Varianten der Zusammenarbeit:

Die Bewertung der vier Varianten im Rahmen der Arbeitsgruppe#2 zeigte, dass die Wahl der optimalen Strategie stark vom spezifischen Anwendungsfall und den geschäftlichen Bedürfnissen der Partner abhängt. Während die interne Nutzung vor allem für Unternehmen geeignet ist, die ihr geistiges Eigentum streng schützen müssen, bietet die Bereitstellung von Modelldiensten das größte Potenzial für eine enge Zusammenarbeit, erfordert aber auch ein hohes Maß an Vertrauen und technischen Schutzmaßnahmen.

3. Einsatzpotentiale für KI in der Wertschöpfungskette:

Die systematische Untersuchung der Use Cases ergab klare Einsatzpotentiale für KI, insbesondere in Bereichen, in denen große Datenmengen analysiert und Entscheidungen getroffen werden müssen. Diese Erkenntnisse führten zu konkreten Implementierungen von KI-Systemen, die dazu beitragen, Effizienz und Genauigkeit in den Entwicklungsprozessen zu steigern.

4. Langfristige Auswirkungen und strategische Implementierung:

Die entwickelten Konzepte und die Erkenntnisse aus der Zusammenarbeit zwischen den Partnern beeinflussten die langfristige Implementierung von KI-Systemen in den Wertschöpfungsketten. Die strategischen Empfehlungen basierten auf den detaillierten Analysen und halfen den Partnerunternehmen, fundierte Entscheidungen für die Zukunft zu treffen.

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

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

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

Teilbeitrag 1.3.9: Kriterien für die Akzeptanz von KI-basierten Entwurfsvorschlägen (09-HOOD)

Ziele

Die Ziele dieses Teilbeitrags lassen sich wie folgt zusammenfassen:

1. **Untersuchung des Einflusses von KI-Entscheidungen auf Entwicklerebene:** Ziel war es, zu verstehen, wie KI-Entscheidungen die Arbeit von Entwicklern beeinflussen.
2. **Erarbeitung von Akzeptanzkriterien:** Es sollten Kriterien definiert werden, die die Akzeptanz von KI-Entscheidungen sowie von KI-gestützter Extraktion von Design-Constraints und Spezifikationen fördern.
3. **Bewertung von Lösungsansätzen zur Prozessoptimierung:** Ziel war es, verschiedene KI-gestützte Ansätze wie Machine Learning und Constraint Solving auf ihre Eignung zur Beschleunigung und Verbesserung von Entwicklungsprozessen zu bewerten.

Problemstellung

KI-Systeme treffen zunehmend Entscheidungen, die traditionell von Menschen getroffen wurden. Dies wirft Herausforderungen hinsichtlich der Akzeptanz und Nachvollziehbarkeit dieser Entscheidungen auf, insbesondere wenn es darum geht, wie Entwickler die durch KI getroffenen Entscheidungen wahrnehmen und wie gut diese in bestehende Entwicklungsprozesse integriert werden können. Darüber hinaus besteht Unsicherheit darüber, ob und wie KI-gestützte Methoden zur Extraktion von Design-Constraints und Spezifikationen aus natürlichsprachlichen Dokumenten in der Praxis zuverlässig und effizient eingesetzt werden können.

Lösungsweg und Ergebnisse

Der Lösungsweg für diesen Teilbeitrag umfasste mehrere Schritte, die darauf abzielten, die Akzeptanz von KI-basierten Entwurfsvorschlägen zu erhöhen und ihre Integration in bestehende Entwicklungsprozesse zu optimieren. Dieser Lösungsweg kann in zwei Hauptbereiche unterteilt werden:

- die Untersuchung und Festlegung von Akzeptanzkriterien sowie
- die technische Umsetzung und Bewertung von KI-gestützten Methoden zur Anforderungs- und Designoptimierung.

Untersuchung und Festlegung von Akzeptanzkriterien

Ein wesentlicher Bestandteil des Lösungswegs war die Identifizierung und Analyse von Faktoren, die die Akzeptanz von KI-Systemen bei Entwicklern und anderen Stakeholdern beeinflussen. Dazu wurde ein Workshop durchgeführt, in dem die Interaktion zwischen Anwendern und KI-Systemen detailliert diskutiert wurde. Die Teilnehmer analysierten die Akzeptanz von KI-Entscheidungen in verschiedenen Anwendungsfällen und entwickelten spezifische Kriterien, die erfüllt sein müssen, damit KI-Entscheidungen als vertrauenswürdig und nützlich wahrgenommen werden.

Die Untersuchung fokussierte sich auf die folgenden Kriterien für die Akzeptanz von KI:

- **Datenschutz und Datensicherheit:**
  Die KI-Systeme müssen sicherstellen, dass alle verarbeiteten Daten geschützt und die geltenden Datenschutzanforderungen vollständig erfüllt werden, um das Vertrauen der Anwender zu gewährleisten.

- **Verlässliche und nachvollziehbare Ergebnisse:**
  Die von der KI generierten Vorschläge müssen präzise, auf einer soliden Datenbasis beruhend, und ihre Entscheidungsprozesse müssen für die Anwender transparent und nachvollziehbar sein.

- **Benutzerfreundlichkeit und Integration:**
  Die KI-Systeme müssen eine intuitive Benutzeroberfläche bieten und sich nahtlos in bestehende Arbeitsabläufe integrieren lassen, um eine hohe Akzeptanz bei den Anwendern zu erreichen.

- **Berücksichtigung des Erfahrungsstands der Anwender:**
  Die KI-Systeme müssen sowohl für erfahrene als auch für weniger erfahrene Benutzer geeignet sein, um eine breite Nutzung sicherzustellen.

- **Wirtschaftlicher Nutzen:**
  Der Einsatz der KI-Systeme muss einen klar erkennbaren und messbaren Nutzen im Hinblick auf Effizienzsteigerung und Qualitätsverbesserung bieten und dabei wirtschaftlich sinnvoll sein.

Technische Umsetzung und Bewertung von KI-gestützten Methoden

Neben der theoretischen Untersuchung der Akzeptanzkriterien wurde ein technischer Lösungsweg entwickelt und getestet, um die praktische Anwendung von KI in der Extraktion von Design-Constraints und Spezifikationen zu evaluieren. Ein zentraler Ansatz dabei war die Verwendung von Named-Entity-Recognition (NER) in natürlichsprachlichen Dokumenten. Dieser Ansatz ermöglicht es, physikalische Einheiten und andere relevante Entitäten automatisch zu identifizieren und diese in ein Subjekt-Objekt-Modell einzubinden.

Die NER-Technologie wurde weiter verfeinert, um zu bestimmen, inwieweit bindende Verben in der SPO-Struktur (Subjekt-Prädikat-Objekt) in Knowledge-Graphen nützlich sein könnten. Dabei wurde auch untersucht, wie diese Informationen in einen RDF-Datastore transformiert werden können, um eine strukturierte und leicht zugängliche Wissensbasis zu schaffen.

Ergebnisse

Die Untersuchung führte zu mehreren wesentlichen Erkenntnissen:

1. **Vertrauen und Transparenz als Schlüsselfaktoren:** Die Ergebnisse bestätigten, dass Vertrauen und Transparenz in die Entscheidungen der KI-Systeme entscheidend für deren Akzeptanz sind. Entwickler zeigten eine höhere Akzeptanz, wenn sie die Entscheidungen der KI nachvollziehen und überprüfen konnten.

2. **Erhöhte Effizienz und Qualität:** Der Einsatz von NER und ML zur Extraktion und Optimierung von Design-Constraints führte zu einer signifikanten Verbesserung der Effizienz und Qualität im Entwicklungsprozess. Die KI-Systeme konnten komplexe Zusammenhänge schneller und präziser erfassen als herkömmliche Methoden, was zu einer Zeitersparnis und besseren Ergebnissen führte.

3. **Anpassungsfähigkeit und Benutzerfreundlichkeit:** Die KI-Systeme waren so gestaltet, dass sie leicht in bestehende Prozesse integriert werden konnten, ohne die Anwender mit zusätzlichen Komplexitäten zu belasten. Dies trug maßgeblich zur positiven Wahrnehmung und Akzeptanz bei.

4. **Soziale Akzeptanz durch Entlastung und Mehrwert:** Die KI-Systeme ermöglichten es den Entwicklern, sich von Routineaufgaben zu entlasten und sich auf anspruchsvollere Aufgaben zu konzentrieren. Dies führte zu einer erhöhten Zufriedenheit und einer positiven Einstellung gegenüber der KI-Unterstützung.

Die erzielten Ergebnisse zeigten, dass der Einsatz von NER zur Extraktion von Informationen aus Texten eine vielversprechende Methode darstellt. Durch die automatische Identifizierung und Kategorisierung von Entitäten konnten relevante Design-Constraints schneller und präziser erfasst werden als durch manuelle Verfahren.

Ein weiteres Ergebnis war die Bestätigung, dass die Akzeptanz von KI-Systemen stark von der Einbindung der von KI-Entscheidung betroffenen Personen hat. Es wurde deutlich, dass Entwickler eine höhere Akzeptanz für KI-gestützte Prozesse zeigen, wenn sie das Gefühl haben, dass sie die Kontrolle über die Entscheidungen behalten und die Möglichkeit haben, die Ergebnisse zu überprüfen und anzupassen.

Die Ergebnisse der Untersuchungen wurden in dem Bericht "Kriterien für die Akzeptanz von KI-basierten Entwurfsvorschlägen" (D1.3-Q03-07) zusammengefasst.

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 produktionsspezifischer 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 1.4.9: Ermittlung von Automatisierungspotentialen durch KI-Einsatz in der Elektronikentwicklung (09-HOOD)

Ziele

Der Teilbeitrag konzentriert sich auf die Identifizierung spezifischer Automatisierungspotentiale durch KI in der Elektronikentwicklung. In enger Zusammenarbeit mit Industriepartnern und KMUs sollen Prozesse von der Anforderungserhebung bis zur Fertigung betrachtet werden, sowie die Machbarkeit und der Nutzen von KI-Lösungen bewertet werden.

Problemstellung

Die Elektronikentwicklung ist durch eine komplexe Abfolge von Phasen gekennzeichnet, beginnend mit der Anforderungsbeschreibung bis hin zur Fertigung. Innerhalb dieses Prozesses entstehen

zahlreiche Schnittstellen und Übergänge, die manuell koordiniert und bearbeitet werden müssen. Dies führt zu hohen Aufwänden und einer erhöhten Fehleranfälligkeit, insbesondere in den Phasen der Spezifikation, des Entwurfs sowie der Implementierung und Verifikation.

Die zentrale Herausforderung besteht darin, wie KI-Technologien eingesetzt werden können, um diese Phasen zu automatisieren und die Übergänge zwischen ihnen zu optimieren. Dabei muss die KI in der Lage sein, nicht nur die Anforderungen präzise zu interpretieren, sondern auch automatisiert Design-Vorschläge abzuleiten, die den spezifischen Anforderungen gerecht werden. Zusätzlich gilt es, die KI so zu entwickeln, dass sie in der Lage ist, die generierten Ergebnisse in nachfolgenden Phasen zu validieren und zu optimieren, ohne dass manuelle Eingriffe erforderlich sind.

Dies erfordert eine enge Verzahnung von KI-basierten Lösungen mit den bestehenden Entwicklungsprozessen und stellt hohe Anforderungen an die Flexibilität und Anpassungsfähigkeit der eingesetzten KI-Module.

Lösungsweg und Ergebnisse

Der Lösungsweg bestand aus mehreren aufeinander abgestimmten Schritten, die das Ziel verfolgten, Automatisierungspotenziale durch den Einsatz von Künstlicher Intelligenz (KI) in der Elektronikentwicklung zu identifizieren und zu realisieren.

1. **Erhebung von KI-User Stories**: Der erste Schritt bestand darin, spezifische KI-User Stories zu sammeln. Diese wurden im Rahmen der Arbeitsgruppe#2 in Zusammenarbeit mit den Konsortialpartnern entwickelt und spiegelten die praktischen Anwendungsfälle wider, in denen KI-Potenziale identifiziert wurden. Diese User Stories dienten als Basis, um zu verstehen, wo und wie KI in den Entwicklungsprozessen eingesetzt werden könnte, und welche Anforderungen an die KI-Lösungen gestellt werden.
2. **Analyse und Bewertung von KI-Einsatzmöglichkeiten**: Anhand der erhobenen User Stories und der bestehenden Prozesse in der Elektronikentwicklung wurden mögliche Einsatzfelder für KI identifiziert und analysiert. Dies geschah durch eine enge Zusammenarbeit mit den Industriepartnern, um praxisnahe und relevante Anwendungsbereiche zu definieren. Ein zentraler Aspekt dieser Phase war die Diskussion der Machbarkeit und der potenziellen Herausforderungen, wie in der folgenden Abbildung dargestellt.

Abbildung 15: Diskussion von KI-Einsatzpotentialen in AG#2

3. **Bewertung des Nutzens eines KI-Einsatzes durch KMUs:** Im KMU-Forum (UC#9) am 12.05.2022 in Paderborn lag der Schwerpunkt auf der Bewertung des Nutzens, den kleine und mittlere Unternehmen (KMUs) durch den Einsatz von KI erwarten. Die entwickelten Methoden und Ansätze wurden den anwesenden Unternehmen vorgestellt und anschließend gemeinsam bewertet. Die Ergebnisse dieser Bewertungen wurden in die weitere Entwicklung und Optimierung der KI-Lösungen integriert. Die Einschätzung der KMUs zum Nutzen von KI, wie in Abbildung unten dargestellt, zeigte, dass insbesondere wirtschaftliche Effizienz und Innovationskraft als die größten Vorteile angesehen wurden.

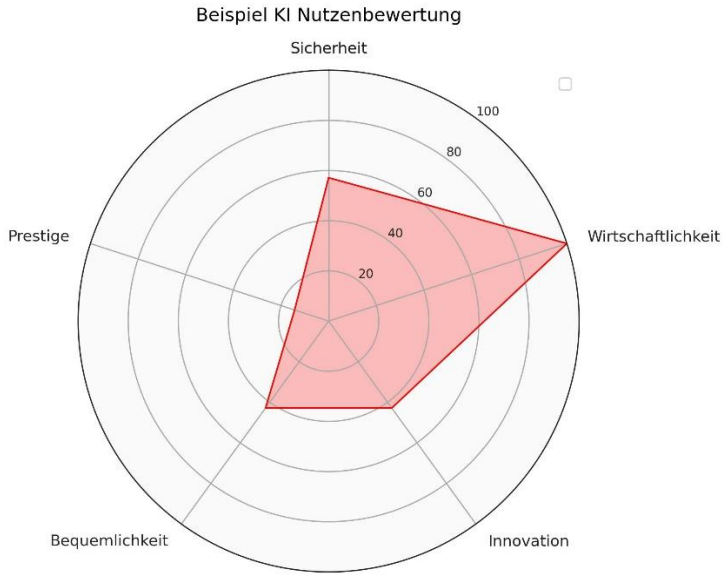

Abbildung 16: KMU Einschätzung des KI-Nutzens nach Kategorien

4. **Integration in die Produktionsprozesse**: Im weiteren Verlauf des Projekts wurde der Einsatz von KI insbesondere im Kontext der Leiterplattenproduktion untersucht. Hierbei stellte sich heraus, dass die größten Automatisierungspotenziale in den vorgelagerten Prozessen liegen, wie z.B. in der Fertigungsaufbereitung von Kundendaten. Der Bedarf an einem KI-Tool, das Schwachstellen im Layout erkennt und automatisch behebt, wurde als wesentlich identifiziert. Jedoch zeigte sich, dass der Einsatz von KI in den eigentlichen Produktionsprozessen, insbesondere bei komplexen Platinen mit bis zu 70 Fertigungsschritten, als schwierig einzuschätzen ist.

Die Ergebnisse des Teilbeitrags können wie folgt zusammengefasst werden:

1. **Erfolg in der Identifikation von Automatisierungspotenzialen**: Es wurden erfolgreich verschiedene Bereiche identifiziert, in denen KI-Potenziale zur Automatisierung und Effizienzsteigerung in der Elektronikentwicklung bestehen. Insbesondere die Unterstützung im Requirements-Management und Engineering sowie die Verbesserung von Fertigungsdaten durch KI erwiesen sich als vielversprechend.

2. **Teilweise Realisierbarkeit der Zielsetzungen**: Während einige der angestrebten Ziele, wie die Ableitung von Design-Vorschlägen durch KI-Module, in bestimmten Anwendungsfällen nicht realisierbar waren, konnten in anderen Bereichen, wie der Aufbereitung von Kundendaten, erhebliche Fortschritte erzielt werden.

3. **Bewertung des KI-Nutzens durch KMUs:** Im Rahmen des KMU-Forums wurde der Nutzen eines KI-Einsatzes von den beteiligten KMUs ausführlich bewertet. Die Ergebnisse zeigten, dass insbesondere die wirtschaftliche Effizienz und die Sicherheit als Nutzen von KI-Lösungen angesehen wurden. Diese Einschätzungen bestätigten die Relevanz und den potenziellen Mehrwert der entwickelten KI-Lösungen für die Elektronikentwicklung.
4. **Herausforderungen bei der Integration in die Produktionsprozesse**: Es wurde deutlich, dass die Integration von KI in hochkomplexe Produktionsprozesse, wie sie bei der Fertigung von Leiterplatten vorkommen, mit erheblichen Herausforderungen verbunden ist. Diese erfordern eine noch weitergehende Anpassung der KI-Module und eine engere Verzahnung mit den spezifischen Anforderungen der Produktionsschritte.

3.2 Arbeitspaket 2: KI-Datenaufbereitung/-generierung

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

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

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

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

Daten und Domänenwissen sind der Schlüssel für eine funktionierende KI. In diesem Arbeitspaket wurden die Schnittstellen zu den applikationsspezifischen Datenquellen und Werkzeugen identifiziert und die Module zu deren Erschließung entwickelt und Trainingsdatenbanken für die spezifizierten UseCases aufgebaut. Wo erforderlich, wurden zusätzliche Daten durch Simulation generiert und, darauf aufbauend, werden Trainingsprozesse definiert, implementiert und anhand

der gewonnenen Daten sowie zusätzlicher Regeln KI-Modelle erzeugt und in datenbasierte Trainings- und Lernmodule integriert.

Beim Datenimport mussten daher unterschiedliche Bedarfe und unterschiedliche Komplexitätsstufen der Probleme beim potenziellen Kunden zu berücksichtigen, um die Module zum Datenimport so zu gestalten, dass für den Kunden Lösungen mit einer großen Hebelwirkung geschaffen und nutzbar gemacht werden können und das Domainwissen adäquat erschlossen werden kann. Hier kam der – ebenfalls KI-basierten - Bildverarbeitung auf unterschiedlichen Ebenen eine wichtige Rolle für die Qualitätskontrolle und als Wissensspeicher zu. Von großer Bedeutung war hier die Zeta-Suite.

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

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

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

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

Die folgenden F+E Themen wurden in AP2 adressiert:

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

Geplante Ergebnisse von AP2 waren:

- Im Rahmen dieses Arbeitspakets standen mehrere zentrale Ergebnisse im Fokus. Zunächst erfolgte die Definition und Implementierung von Schnittstellenmodellen, die spezifisch auf die Entwurfs- und Simulationsumgebungen, Datenbanken sowie Dateiformate wie Bilder oder Textdokumente abzielten. Dabei wurde ein besonderes Augenmerk auf Verfahren zum Datenschutz gelegt. Die Schaffung einheitlicher Schnittstellen und Austausch-Dateiformate für sämtliche anfallende Daten sowie die Festlegung von Standards zur Beschaffenheit dieser Daten waren zentrale Aspekte.

- Das Arbeitspaket beinhaltete ebenfalls die Aufbereitung von Test- und Lerndaten aus bestehenden Datenbanken sowie durch Simulationen und Messungen an Demonstratoren. Modelle aus bereits vorhandenem Erfahrungswissen und Regelwerken wurden entwickelt, wobei die Annotation, Kontextualisierung und Klassifikation der Daten anhand von Metadaten, Messergebnissen und der Bewertung durch Entwicklerexperten im Fokus standen. Eine umfassende Evaluation und Bewertung der KI-Ausgaben war ebenfalls Teil der geplanten Ergebnisse.

- Ein wesentlicher Bestandteil bildete der Meta-Algorithmus, der Metriken zur Beschreibung von Problemschwierigkeiten und des Abstands von Problemen im Sinne eines Umlernprozesses sowie zur Bewertung von Lernprozessen und Datenqualität integrierte. Dieser Meta-Algorithmus beinhaltete auch Entscheidungsmethodiken zur Auswahl von Algorithmen, die bei der Vorgabe einer Probleminstanz zielführend eingesetzt werden konnten. Zusätzlich wurden Schnittstellen geschaffen, um den Meta-Algorithmus auf dem gesamten Spektrum der über die modularen KI-Plattform bereitgestellten KI-Verfahren operieren zu lassen.

- Ein weiterer Schwerpunkt lag auf applikationsspezifischen Trainings- und Lernmodulen, die auf den Use Cases für die 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 2.1.9: Optimiertes Requirement-Engineering (RE) für KI-basierte Entwicklung (09-HOOD)

Ziele

1. **Anpassung und Weiterentwicklung von RE-Methoden für KI-Systeme**: Bestehende Requirements-Engineering-Methoden sollen analysiert und weiterentwickelt werden, so dass sie den spezifischen Herausforderungen der Entwicklung von KI-basierten Systemen gerecht werden. Dabei liegt der Fokus auf der Integration von Methoden, die den Besonderheiten von KI-Komponenten, wie stochastischen Elementen und maschinellem Lernen, Rechnung tragen.
2. **Entwicklung von speziellen Methoden zur Anforderungserhebung**: Es soll erarbeitet werden, welche Vorgehensweisen und Techniken am besten geeignet sind, um die Anforderungen an KI-Systeme präzise zu identifizieren und zu spezifizieren. Dies umfasst sowohl die Erhebung der technischen Anforderungen als auch das Verständnis der Kontextbedingungen und Nutzerbedürfnisse.
3. **Festlegung der Rahmenbedingungen für den Einsatz von KI-Systemen**: Es sollen Randbedingungen bestimmt werden, die für den erfolgreichen Einsatz von KI-Systemen notwendig sind. Dazu gehört die Analyse, unter welchen Bedingungen KI-Systeme optimal funktionieren und welche spezifischen Anforderungen an die Qualität der Daten und das Systemverhalten gestellt werden müssen.
4. **Untersuchung der Qualifikationsanforderungen für Requirements-Engineers**: Es soll untersucht werden, ob und in welchem Umfang die Ausbildung und Qualifikation von Requirements-Engineers angepasst werden muss, um den Anforderungen der Entwicklung von KI-Systemen gerecht zu werden. Dies umfasst die Vermittlung von Kenntnissen über KI-Technologien sowie spezifische RE-Methoden für KI.
5. **Definition neuer Qualitätskriterien für KI-Systeme**: Es soll bestimmt werden, welche neuen Qualitätskriterien für die Entwicklung und den Betrieb von KI-Systemen erforderlich sind. Diese Kriterien sollen sicherstellen, dass KI-Systeme zuverlässig, transparent und ethisch vertretbar arbeiten, insbesondere im Hinblick auf die Qualität der verwendeten Trainingsdaten und die Nachvollziehbarkeit von KI-Entscheidungen.
6. **Erstellung praxisorientierter Leitlinien und Anwendung der Erkenntnisse**: Die theoretischen Erkenntnisse sollen in praxisorientierte Leitlinien und Best Practices überführt werden, die im Rahmen von Workshops und Projekttreffen auf konkrete Anwendungsfälle, wie die Entwicklung einer modularen KI-Plattform, angewendet und getestet werden. Dies dient der Validierung und Optimierung der entwickelten RE-Methoden im realen Projektkontext.

Problemstellung

Die herkömmlichen Requirements-Engineering-Methoden (RE) sind auf deterministische, klassische Systeme ausgelegt und reichen nicht aus, um die spezifischen Herausforderungen der Entwicklung von KI-Systemen zu bewältigen. KI-Systeme weisen stochastische und lernbasierte Eigenschaften auf, was das Verhalten dieser Systeme oft unvorhersehbar und dynamisch macht. Diese Eigenschaften erfordern eine neue Herangehensweise im RE, da traditionelle Ansätze die Spezifizierung von Anforderungen an solche Systeme nur unzureichend unterstützen.

Zusätzlich stehen KI-Systeme vor der Herausforderung, dass ihre Leistungsfähigkeit stark von der Qualität und Quantität der genutzten Trainingsdaten abhängt. Dies führt zu Unsicherheiten in Bezug auf das Systemverhalten und erschwert die klare Definition von Anforderungen, die für die

korrekte Funktion notwendig sind. Gleichzeitig müssen Anforderungen so formuliert werden, dass sie in einem sich ständig verändernden Systemkontext weiterhin relevant und gültig bleiben.

Darüber hinaus existieren Fragen zur Qualifikation der Requirements-Engineers selbst, da die Entwicklung von KI-Systemen spezielles Wissen erfordert, das in den traditionellen Ausbildungsprogrammen für RE nicht vollständig abgedeckt ist. Die Interaktion mit KI-Algorithmen, die Nachvollziehbarkeit von Entscheidungen und der Umgang mit neuen regulatorischen Anforderungen, wie dem EU-AI-Act, stellen zusätzliche Komplexitäten dar.

Lösungsweg und Ergebnisse

Die zentrale Herausforderung bestand darin, die bestehenden Requirements-Engineering (RE)-Methoden an die besonderen Bedürfnisse von KI-basierten Systemen anzupassen. Im Verlauf des Projekts wurde ein systematischer Ansatz verfolgt, um geeignete Lösungen zu entwickeln, die sowohl den technischen Anforderungen als auch den speziellen Eigenschaften von KI-Systemen gerecht werden.

1. Analyse der bestehenden RE-Methoden:
   - Zu Beginn des Projekts wurde eine detaillierte Analyse der etablierten RE-Methoden durchgeführt, um festzustellen, welche Bereiche bei der Entwicklung von KI-Systemen problematisch sind. Insbesondere wurde untersucht, wie der Einsatz von stochastischen Elementen und maschinellem Lernen (ML) die traditionelle Anforderungserhebung und -spezifikation beeinflusst.
   - Diese Analyse ergab, dass bestehende Methoden, die für klassische Software-Systeme geeignet sind, nicht ausreichen, um die Unsicherheiten und Lernprozesse von KI-Systemen zu adressieren. Diese Systeme weisen ein dynamisches Verhalten auf, das stark von den verwendeten Daten und dem Systemkontext abhängt, was spezifische Anpassungen erfordert.
2. Entwicklung neuer Ansätze und Methoden:
   - Auf Basis dieser Analyse wurden spezifische RE-Methoden für KI-Systeme entwickelt. Hierzu gehörte die Einführung von KI-User-Stories, die es ermöglichen, menschliche Bedürfnisse im Kontext von KI-Anwendungen frühzeitig zu identifizieren. Die KI-User-Stories helfen, den Anwendungskontext und die Motivation des Nutzers von der technischen Lösung zu trennen und die geforderten KI-Funktionen klar zu spezifizieren.
   - Darüber hinaus wurden Qualitätskriterien für KI-Systeme entwickelt, um sicherzustellen, dass die Systeme zuverlässig und transparent arbeiten. Diese Kriterien berücksichtigen die Qualität der Trainingsdaten, die Nachvollziehbarkeit von Entscheidungen sowie die Robustheit gegenüber sich verändernden Kontexten.

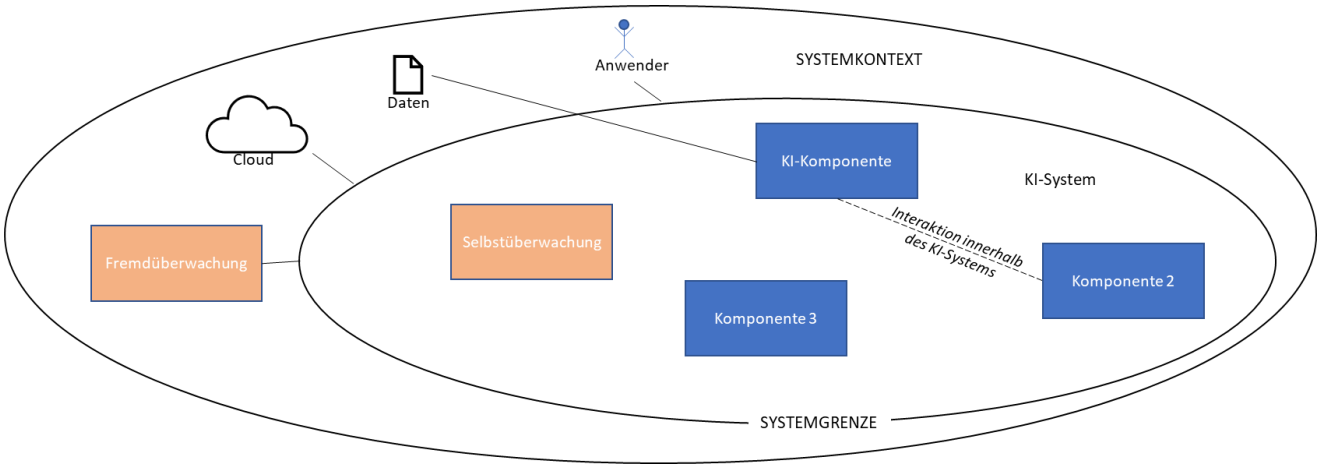

Abbildung 17:Der Systemkontext von KI-Systemen und die Wechselwirkungen innerhalb des Systems

Diese Grafik verdeutlicht, dass die genaue Definition und Abgrenzung des Systemkontextes essenziell ist, um das Verhalten des KI-Systems in verschiedenen Umgebungen zu spezifizieren. Dies stellt für das RE eine wesentliche Herausforderung dar, da das Systemverhalten in einem stochastischen Kontext anders ausgeprägt ist als in deterministischen Systemen.

3. Einführung von KPIs zur Überwachung und Validierung:

- Um sicherzustellen, dass das KI-System im laufenden Betrieb zuverlässig arbeitet, wurden im RE-Prozess Key Performance Indicators (KPIs) definiert. Diese KPIs helfen, das Verhalten des Systems sowohl durch Selbstüberwachung als auch durch Fremdüberwachung zu kontrollieren.
- Dabei wurde besonderes Augenmerk auf die dynamische Natur von KI-Systemen gelegt. Da sich sowohl der Kontext als auch das Systemverhalten ändern können, müssen die KPIs kontinuierlich überwacht und angepasst werden, um Fehlentwicklungen rechtzeitig zu erkennen.

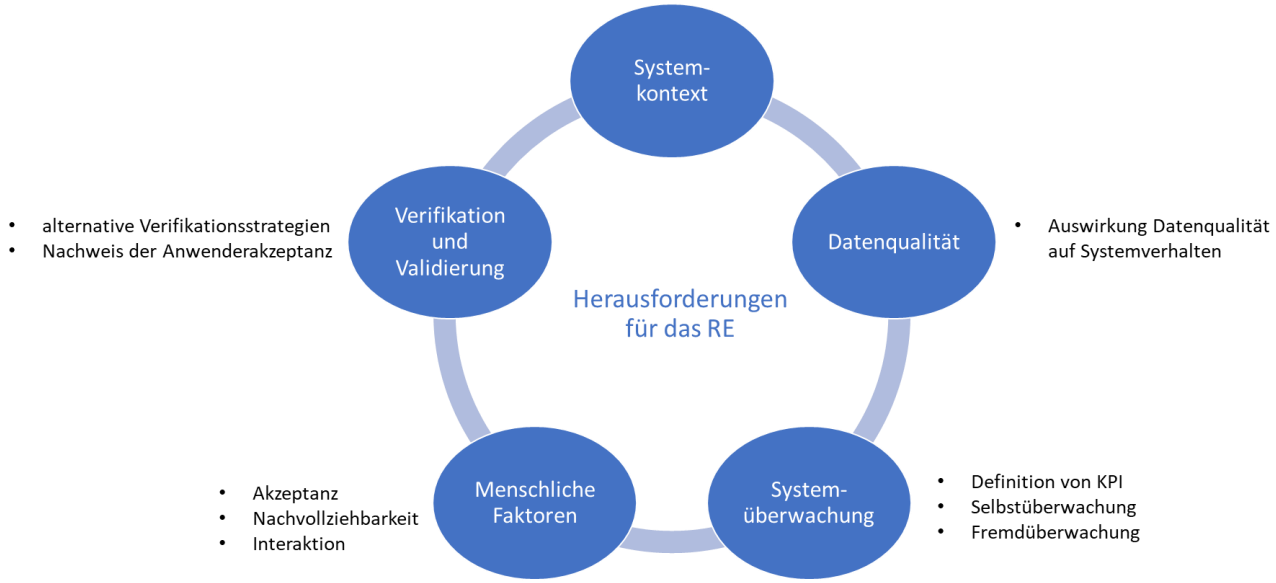

Abbildung 18: Herausforderungen für das RE in Bezug auf KI-Systeme

Diese Grafik zeigt die zentralen Herausforderungen, die sich für das Requirements-Engineering ergeben: Systemkontext, Datenqualität, Systemüberwachung, menschliche Faktoren sowie

Verifikation und Validierung. Die Herausforderung besteht darin, all diese Aspekte frühzeitig im Entwicklungsprozess zu berücksichtigen.

4. Workshops zur praktischen Anwendung:
   - Um die theoretischen Erkenntnisse zu testen und zu validieren, wurden RE-Workshops durchgeführt. Ein Beispiel ist der Workshop in Karlsruhe, bei dem die entwickelten RE-Methoden auf die Entwicklung der modularen KI-Plattform angewendet wurden. In diesem Workshop wurde diskutiert, wie die Anforderungen der modularen Plattform erhoben und spezifiziert werden können, insbesondere im Hinblick auf verschiedene Use Cases.
   - Ein weiterer Fokus lag auf der regulatorischen Einbettung, vor allem im Zusammenhang mit dem EU-AI-Act. Diese gesetzlichen Anforderungen stellen neue Herausforderungen für das RE dar, insbesondere in Bezug auf die ethischen Standards, Transparenz und Nachvollziehbarkeit von KI-Entscheidungen.

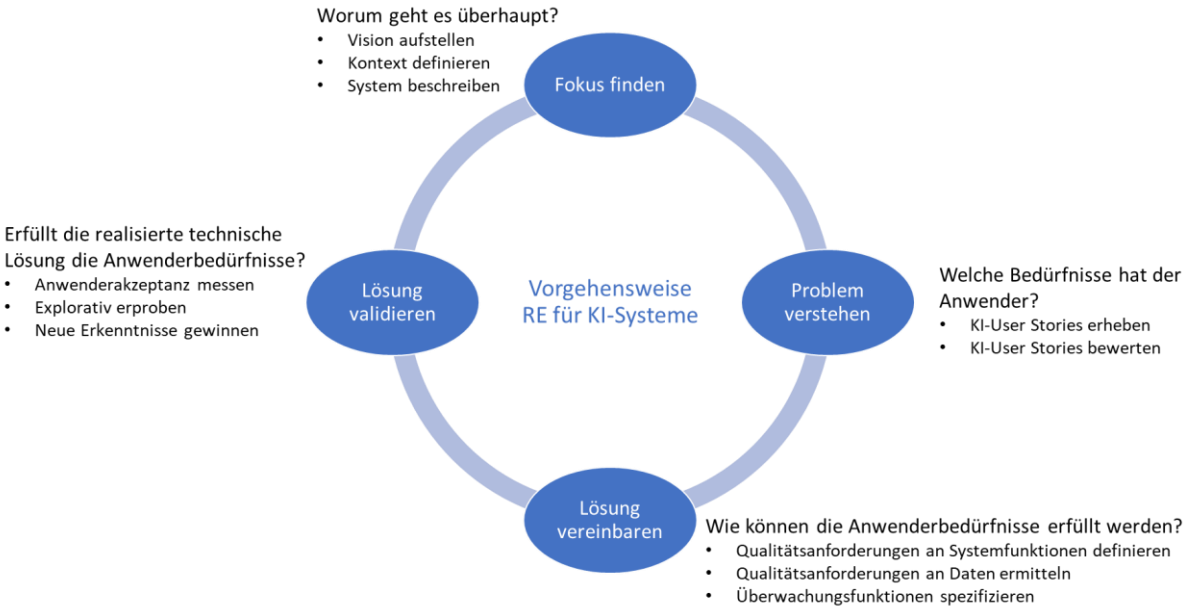

Abbildung 19: Vorgehensweise RE für KI-Systeme – Ein prinzipieller Lösungsansatz

Diese Grafik stellt die systematische Vorgehensweise des RE für KI-Systeme dar. Die Phasen „Fokus finden“, „Problem verstehen“, „Lösung vereinbaren“ und „Lösung validieren“ sind zentral, um sicherzustellen, dass die Anforderungen der KI-Systeme den realen Bedürfnissen und Kontexten entsprechen. Das RE muss iterativ arbeiten und fortlaufend sicherstellen, dass das System den festgelegten Anforderungen gerecht wird.

Die Anwendung dieser methodischen Ansätze auf die modulare KI-Plattform als zentraler Entwicklungsgegenstand des Projektes progressivKI führte zu folgenden Ergebnissen:

PRODUKT VISION „MODULARE KI-PLATTFORM“

Vision Statement	Vereinfachen des Einsatzes maschinellen Lernens, auch für kleine Unternehmen		
Zielgruppe	**Bedürfnisse**	**Produkt**	**Wirtschaftlichkeit**
• Entwickler von KI-Komponenten • Anwender von KI-Komponenten • Industrieanwender • Forschungsanwender	• strukturierte, kontrollierte Experimente • Nachvollziehbarkeit und Wiederverwertbarkeit der Experimente • Zusammenarbeit bei den Experimenten	• Open Source • Anpassbarkeit und Verwendung vorhandener Lösungskonzepte • Offene und standisierte Schnittstellen • offen für zukünftige Entwicklungen • Berücksichtigung unterschiedlichster Security Bedürfnisse • Während der Projektlaufzeit leistungsfähige Rechnerarchitektur für KI Training	• Supportangebote

6

Abbildung 20: Produkt Vision der modularen KI-Plattform

1. Zielgruppen und deren Bedürfnisse:

Die Plattform richtet sich an verschiedene Nutzergruppen:

- Entwickler von KI-Komponenten: Diese Zielgruppe benötigt eine strukturierte und kontrollierte Umgebung für Experimente. Es wird besonderer Wert auf Nachvollziehbarkeit und Wiederverwendbarkeit gelegt. Die Plattform soll es Entwicklern ermöglichen, Experimente zu dokumentieren und nahtlos mit anderen Entwicklern zusammenzuarbeiten.
- Anwender von KI-Komponenten: Diese Gruppe benötigt eine flexible Plattform, die es erlaubt, bestehende Lösungen anzupassen und für ihre spezifischen Use Cases zu nutzen. Die Plattform unterstützt offene, standardisierte Schnittstellen, um zukünftige Entwicklungen zu berücksichtigen und leicht in bestehende Systeme integriert zu werden.
- Industrieanwender und Forschungsanwender: Auch für diese Zielgruppen ist es wichtig, die Möglichkeit zu haben, eigene Experimente durchzuführen und bestehende Lösungen zu adaptieren.

2. Bereitgestellte Funktionen der modularen KI-Plattform

Die Plattform bietet eine Vielzahl von Funktionen, die sowohl technologische als auch organisatorische Aspekte abdecken:

- Open-Source und Anpassbarkeit: Die Plattform ist offen gestaltet, was es Entwicklern erlaubt, sie anzupassen und vorhandene Lösungskonzepte zu nutzen. Dies ermöglicht eine kosteneffiziente und schnelle Entwicklung.
- Offene und standardisierte Schnittstellen: Diese Schnittstellen sorgen dafür, dass die Plattform zukunftssicher ist und leicht erweitert werden kann. Entwickler und Anwender

können neue Module und Funktionen hinzufügen, ohne die gesamte Plattform zu modifizieren.

- Leistungsfähige Rechnerarchitektur für KI-Training: Während der Projektdauer wird eine robuste und leistungsfähige Hardware-Architektur bereitgestellt, die das Training von KI-Modellen effizient unterstützt.

3. Wirtschaftlichkeit der modularen KI-Plattform

Die Plattform bietet verschiedene Modelle zur Wirtschaftlichkeit, die insbesondere auf kleine Unternehmen abzielen:

- Supportangebote: Neben der technischen Bereitstellung wird besonderer Wert auf Support-Angebote gelegt, um Unternehmen bei der Einführung und Nutzung der KI-Plattform zu unterstützen. Dies verringert Einstiegshürden und fördert die Akzeptanz.

4. Abgrenzung und Spezifikation der Plattformfunktionen anhand von Use Cases

In mehreren Use Cases (UC) wurden spezifische Anforderungen und Abgrenzungen der modularen KI-Plattform herausgearbeitet:

- Use Case #4 (Plattform als Bestandteil der Gesamtkette): In diesem Use Case wird die Plattform als Teil einer gesamten Toolkette betrachtet, in die sie sich durch ihre Toolanbindung und Modulanbindung (Plugins) integriert. Funktionen wie Datenvisualisierung und Qualitätsbewertung von Modellen gehören zu den Kernbestandteilen der Plattform. Datenbereitstellung ist jedoch nicht Teil der Plattform, wie in der Abgrenzung betont wird.
- Use Case #6 (Datenmanagement und konfigurierbare Workflows): Die Plattform unterstützt spezifische Funktionen wie Data Extraktion, Data Storage, Data Annotation und konfigurierbare Workflows. Hierbei ist die Plattform in der Lage, Daten aus unterschiedlichen Quellen zu extrahieren und diese zur weiteren Verwendung im KI-Training oder der Modellvalidierung zu speichern. Abgrenzend wird hier festgelegt, dass die Plattform keine Endnutzer-GUI bereitstellt, sondern sich ausschließlich auf die Backend-Verarbeitung konzentriert.
- Use Case #1 und Use Case #2: Hochladen und Visualisieren von Modellen
    - Hochladen trainierter Modelle: Dies ermöglicht Entwicklern, ihre bereits trainierten Modelle auf die Plattform zu laden, um sie in der modularen Umgebung weiterzuverwenden oder zu teilen.
    - Daten hochladen: Neben Modellen können Anwender ihre Trainings- und Validierungsdaten in die Plattform integrieren.
    - XAI anbinden (Erklärbare KI): Die Plattform bietet Schnittstellen zur Anbindung von XAI-Tools, die die Nachvollziehbarkeit von KI-Entscheidungen verbessern.
    - Visualisierung: Visualisierungsfunktionen helfen den Anwendern, die Struktur und Ergebnisse ihrer Modelle sowie ihrer Daten zu analysieren.
    - Bestimmung von Parametern für PCB-Topologien: Speziell für Anwendungen im Bereich Elektronikdesign ermöglicht die Plattform die Anpassung von Parametern für Platinen (PCB) und Teilnetze.

    - Anforderung zusätzlicher Daten bei Bedarf (User Request): Die Plattform ist flexibel genug, um zusätzliche Daten von Nutzern bei Bedarf anzufordern und in den Trainingsprozess zu integrieren.
- Use Case #3 und Use Case #5: Erweiterte Modellverarbeitung und Integration mit Simulationstools
    - Autoencoder und Visualisierungsverfahren: Die Plattform unterstützt die Implementierung und Anwendung von Autoencoder-Algorithmen, die besonders bei Datenkompression und Anomalie Erkennung nützlich sind. Visualisierungsverfahren helfen bei der Analyse dieser Daten.
    - Anwendungsprozesse und Verfahren: Standardisierte Verfahren und Prozesse können auf Modelle angewendet werden, um sie effizienter zu trainieren und zu validieren.
    - Schnittstellen zu Mess- und Simulationstools (TBD): Die Plattform wird auch in der Lage sein, Schnittstellen zu externen Mess- und Simulationswerkzeugen bereitzustellen. Dies ist insbesondere relevant, wenn Modelle in physischen Umgebungen (z.B. in der Industrie) getestet oder validiert werden müssen.
    - Verwendung experimenteller Daten: Die Plattform unterstützt den Import und die Analyse von experimentellen Daten, die zur Verbesserung und Feinabstimmung von Modellen verwendet werden können.
    - Kontinuierliche Verbesserung der Modelle: Diese Funktion ermöglicht es, dass Modelle regelmäßig aktualisiert und auf der Grundlage neuer Daten und Feedbacks verbessert werden.
- Use Case #6 (HOOD): Modulare Modellverwaltung und Sichere Datenverwaltung
    - Laden von Foundation-Modellen: Die Plattform bietet die Möglichkeit, Foundation-Modelle als Basis für weitere Verfeinerungen auf die Plattform zu laden.
    - Finetuning der Modelle: Nutzer können Modelle weiter optimieren, indem sie sie mit neuen Daten nachtrainieren oder feintunen.
    - Inferenzserver über API: Die Plattform bietet eine API, die es ermöglicht, Modelle sicher und effizient für Inferenzaufgaben zu verwenden. Diese API ist über geschützten Zugriff verfügbar, um die Daten und Modelle zu sichern.
    - GUI für den Zugriff auf Modelle: Eine grafische Benutzeroberfläche (GUI) wird bereitgestellt, um den Zugriff auf die Modelle zu erleichtern und einfache Bedienung zu gewährleisten.
    - Dokumentation und Durchführung der Punkte: Anwender können die Ergebnisse ihrer Modelle dokumentieren und genaue Anweisungen zur Durchführung spezifischer Aufgaben erhalten.
    - Sicherer Datenupload: Daten können in einer sicheren Umgebung hochgeladen und verarbeitet werden, um Datenschutz und Sicherheitsanforderungen zu erfüllen.
    - Demonstrator über KI4RE ToolKit: Es wird ein spezielles ToolKit angeboten, das den Demonstrator für die Plattform in Verbindung mit dem KI4RE-Framework verwendet.

- Möglichkeit zur Nutzung nach Projektende: Die Plattform bietet weiterhin Unterstützung und Nutzungsmöglichkeiten nach Abschluss eines Projekts, um die Nachhaltigkeit der Modelle und Daten zu gewährleisten.

Die Projektergebnisse wurden in wissenschaftlichen Publikationen veröffentlicht, darunter der Artikel „RE für KI-Systeme: KI & maschinelles Lernen - Neue Herausforderungen für das RE“. Dieser Artikel fasste die wichtigsten Erkenntnisse und Lösungsansätze zusammen und wurde in der Fachzeitschrift „IT-Spektrum“ publiziert.

Zur Unterstützung der Qualifikation von RE wurden Workshops und Tutorials konzipiert und sowohl projektintern als auch auf Konferenzen wie dem TdSE (Tag des Systems Engineering) und der REConf durchgeführt.

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
- Kombinierter Ansatz aus Simulationsdaten und gemessenen Daten zur Erzeugung von hinreichend großen Datensätzen für ML
- Datenakquise durch Simulationen und realen Messdaten - Entwicklung von Konzepten zur Herstellung von EM- und thermischen Trainingsdaten für die KI-Module
- Batch-Simulation und -Parametervariationsmethodik zur externen automatischen Ansteuerung von Simulationswerkzeugen (HPC) + Definition von Metriken zur Bewertung von Simulationsdaten
- Einbindung von physikalischen Gesetzen und Design-Rules
- Verfahren zur Erstellung von Testdatensätzen zur Qualitätsbeurteilung KI-basierter Entwurfsentscheidungen/-vorschlägen

- Konzept zur Erstellung der Trainingsdaten, dass Qualität und Quantität der benutzten Trainingsdaten berücksichtigt
- Bewertungsverfahren für die zu erwartende wachsende Menge an Lern-(Trainings)-daten
- Werkzeuge zur Bewertung und Verwaltung (Lifecycle-Management) der wachsenden Menge an Trainingsdaten
- Management zur projektübergreifenden Bereitstellung von Lerndaten.

Teilbeitrag 2.2.9: Strategien für angepasstes KI-Training – Anwendungsebenen #1 - #2 (09-HOOD)

Ziele

Ziel war die Erforschung und Optimierung von KI-Methoden für das Requirements-Engineering, mit einem Fokus auf Datenbeschaffung, Qualitätssteigerung und Anpassung von NLP-Techniken. Zudem sollten innovative Ansätze zur Identifikation relevanter Entitäten und zur strukturierten Wissensextraktion entwickelt werden.

Problemstellung

Es gilt effektive Methoden für das Training von KI-Modellen im Bereich des Requirements-Engineering zu entwickeln und anzupassen. Eine zentrale Schwierigkeit ist die Beschaffung ausreichend großer und qualitativ hochwertiger Lerndaten, die für die spezifischen Anforderungen in dieser Domäne erforderlich sind. Spezifikationsdokumente, die als primäre Datenquelle dienen könnten, sind oft geschützt und daher nicht frei verfügbar, was die Erstellung eines umfassenden annotierten Datensatzes erschwert. Zudem ist die manuelle Annotation dieser Daten aufwändig und erfordert spezifisches Domänenwissen, das bei kostengünstigen Dienstleistern häufig nicht vorhanden ist, was die Qualität der Trainingsdaten beeinträchtigt. Diese Herausforderungen werden zusätzlich durch die Tatsache verstärkt, dass vortrainierte Sprachmodelle in spezialisierten Aufgabenstellungen, wie sie im Requirements-Engineering vorkommen, oft nicht die notwendige Präzision erreichen. Es war daher notwendig, alternative Ansätze zur Datenakquise und -generierung sowie Strategien zur Verbesserung der bestehenden NLP-Techniken zu entwickeln, um eine zuverlässige und effektive KI-Unterstützung in dieser Domäne zu ermöglichen.

Lösungsweg und Ergebnisse

Es wurden umfassende Untersuchungen zu zentralen Fragestellungen im Bereich des KI-Trainings im Kontext des Requirements-Engineering (RE) durchgeführt. Diese Fragestellungen betrafen unter anderem den optimalen Zeitpunkt für das Training von KI-Modellen, die Erhebung und Qualitätssicherung der erforderlichen Lerndaten sowie die Bewertung des Lernerfolgs und die Herausforderungen bei der Datenbeschaffung und -annotation.

Zunächst wurde intensiv diskutiert, ob das Training der KI-Modelle vor der Auslieferung oder auch im laufenden Betrieb des Systems erfolgen sollte. Dabei wurde insbesondere die Frage beleuchtet, wie die erforderlichen Lerndaten erfasst und welche Qualitätsstandards an diese Daten angelegt werden sollten. Die Herausforderung lag hierbei vor allem in der Beschaffung ausreichender Mengen an Trainingsdaten, die im Bereich des Requirements-Engineering von entscheidender Bedeutung sind. Es wurde erkannt, dass die Generierung und Annotation dieser Daten im erforderlichen Umfang im Rahmen des Projekts voraussichtlich nicht vollständig realisierbar ist. Daher wurden alternative Strategien in Betracht gezogen, die entweder mit geringeren Datenvolumina arbeiten oder auf unüberwachte (unsupervised) Lernstrategien zurückgreifen.

Ein zentraler Ansatz war die Annotation von Spezifikationen, um die Entität „Software Component“ zu identifizieren. In Zusammenarbeit mit dem Konsortialpartner DIQA wurde ein Korpus von Spezifikationen unter Verwendung des Tools Label Studio bearbeitet. Diese Daten wurden anschließend genutzt, um im Open-Source-NLP-Framework spaCy eine Named Entity Recognition (NER) Pipe zu trainieren, die erfolgreich in der Lage war, die Entität „Software Component“ in den Texten zu erkennen. Parallel dazu wurden alternative Ansätze für die NER in Zusammenarbeit mit DIQA diskutiert.

Im weiteren Verlauf des Projekts stellte sich heraus, dass Spezifikationsdokumente oft geschütztes geistiges Eigentum der Ersteller sind und daher nicht frei verfügbar gemacht werden können. Dies erschwerte die Erstellung eines umfassenden und annotierten Trainingsdatensatzes erheblich. Aufgrund dieser Einschränkungen wurden verschiedene alternative Ansätze zur Datenakquise und Trainingsdatengenerierung untersucht:

- **Verwendung von Dokumenten mit bekannten Dokumentenstrukturen**: Hierbei wurden verfügbare Dokumente des AUTOSAR-Standards im PDF-Format analysiert, die von der AUTOSAR-Webseite heruntergeladen werden konnten. Die Spezifikationen in diesen Dokumenten folgen einer einheitlichen Struktur, was die Identifikation von Anforderungen erleichtert. Anforderungssubjekte könnten in diesem Ansatz als grammatikalische Subjekte der Anforderungssätze mittels NLP-Techniken wie Sentence Boundary Detection, Tokenizing, Part-of-Speech, Dependency Parsing, Nouns Chunking und Named Entity Recognition (NER) identifiziert werden.
- **Generieren von Trainingsdaten anhand von Experten-Regeln**: Requirements-Engineering-Experten entwickelten Regeln zur Identifikation von Anforderungen und Anforderungssubjekten in Texten. Diese Regeln wurden algorithmisch implementiert, um Trainingsdaten zu generieren, die bereits die für die Aufgabenstellung erforderlichen Annotationen enthalten.
- **Export annotierter Trainingsdaten aus Requirements-Management-Werkzeugen**: In Requirements-Management-Werkzeugen werden Informationen strukturiert abgelegt und spezifisch attribuiert. Diese Attribuierung kann teilweise als Grundlage für die erforderlichen Annotationen genutzt werden. Fehlen bestimmte Annotationen, können diese mithilfe von NLP-Techniken automatisiert ergänzt werden, wobei die Genauigkeit der Ergebnisse sorgfältig geprüft werden muss.
- **Unstrukturierte Textdateien aus dem Internet**: Textdateien aus dem Internet sind in der Regel unstrukturiert und erfordern eine manuelle Annotation. Dieser Ansatz wurde nur begrenzt genutzt, da er ressourcenintensiv ist und aufgrund der Notwendigkeit eines umfangreichen Domänenwissens nicht ideal für die Aufgabenstellung geeignet war.

Ein weiteres bedeutendes Problem war die manuelle Annotation, die spezifisches RE-Domänenwissen erfordert. Diese Anforderung konnte bei günstigeren Dienstleistern oft nicht erfüllt werden, was zu einer verminderten Qualität der annotierten Trainingsdaten führte. Außerdem stellte sich heraus, dass vortrainierte Sprachmodelle in domänenspezifischen Aufgabenstellungen und aufgrund der Mehrdeutigkeit natürlicher Sprache häufig nicht die erforderliche Genauigkeit erzielten. Dies galt insbesondere für NLP-Techniken, die in Richtung Natural Language Understanding (NLU) gehen, wie z.B. Named Entity Recognition (NER) und Nouns Chunking. Um diese Probleme zu lösen, wurde das Nachtrainieren der Sprachmodelle auf die spezifische Domäne und Aufgabenstellung als notwendig erachtet. Zusätzlich wurde die Möglichkeit in Betracht gezogen, KI-Sprachmodelle durch regelbasierte Schritte zu erweitern, um die Qualität der Ergebnisse signifikant zu steigern.

Zur Umsetzung dieser Erkenntnisse wurden Daten aus verschiedenen Internetquellen extrahiert und manuell hinsichtlich physikalischer Einheiten annotiert. Dieser umfangreiche Korpus, bestehend aus 10.000 Sätzen, diente als Grundlage für das Nachtraining eines BERT-Sprachmodells. Ziel war es, das Modell in die Lage zu versetzen, physikalische Einheiten in natürlichsprachigen Texten zuverlässig zu erkennen. Dieses Nachtraining wurde mit dem Transformer-Modell BERT sowohl direkt in PyTorch als auch in spaCy durchgeführt, um unterschiedliche Ansätze vergleichen zu können. Als zusätzlicher Vergleich wurde ein regelbasierter Ansatz eingesetzt, bei dem physikalische Einheiten bei der tokenweisen Expansion mit der Python-Bibliothek PINT überprüft wurden.

Ein weiterer wesentlicher Bestandteil des Projekts war die Entwicklung einer kombinierten Vorgehensweise zur Named Entity Recognition (NER) und Entity Relation Extraction (ERE). Diese Kombination sollte eine detaillierte Analyse und Identifikation von RE- bzw. SE-Entitäten sowie deren Abhängigkeiten in Spezifikationsdokumenten ermöglichen. Hierzu wurde die erforderliche Werkzeugkette evaluiert und schließlich das Annotation-Tool Label Studio auf einem Server installiert. Dieses Werkzeug wurde in der Folge verwendet, um die notwendigen Trainingsdaten zu annotieren. Darüber hinaus wurde untersucht, ob die Einbindung eines Large Language Models (LLM) in die Werkzeugkette eine Unterstützung bieten könnte.

Für die praktische Umsetzung wurde wurden zwei alternative Wege der Umsetzung der von FIT entwickelten modularen KI-Plattform untersucht. Da wir bei HOOD das Betriebssystem Microsoft Windows verwenden, bestand die erste Umsetzung darin, eine virtuelle Maschine (VM) unter Verwendung von Oracle VirtualBox basiert. Auf dieser VM wurde das Betriebssystem Ubuntu 22.04 installiert, gefolgt von der Installation von Docker und dem Service Platform Python Client (SPPC). In dieser Umgebung wurde das Training eines BERT-Transformers für die Unit NER erfolgreich durchgeführt. Die entwickelte Trainings-Pipeline lief bereits mit verschiedenen Parametern erfolgreich durch.

Als weitere alternative Umsetzungsmöglichkeit haben wir unter Microsoft Windows WSL2 verwendet. In WSL2 wurde auch Ubuntu 22.04 verwendet, zusätzlich Docker Desktop direkt unter Windows. Der Service Platform Python Client (SPPC) wurde direkt in WSL2 installiert. Auch in dieser Umgebung wurde das Training des BERT-Transformers für die Unit NER erfolgreich durchgeführt.

Die trainierten Modelle wurden lokal bereitgestellt und auch mit lokalen Anwendungen darauf zugegriffen.

Für die nächste Phase war geplant, das Modell über die FIT-Plattform bereitzustellen und für produktive Anwendungen zu verwenden.

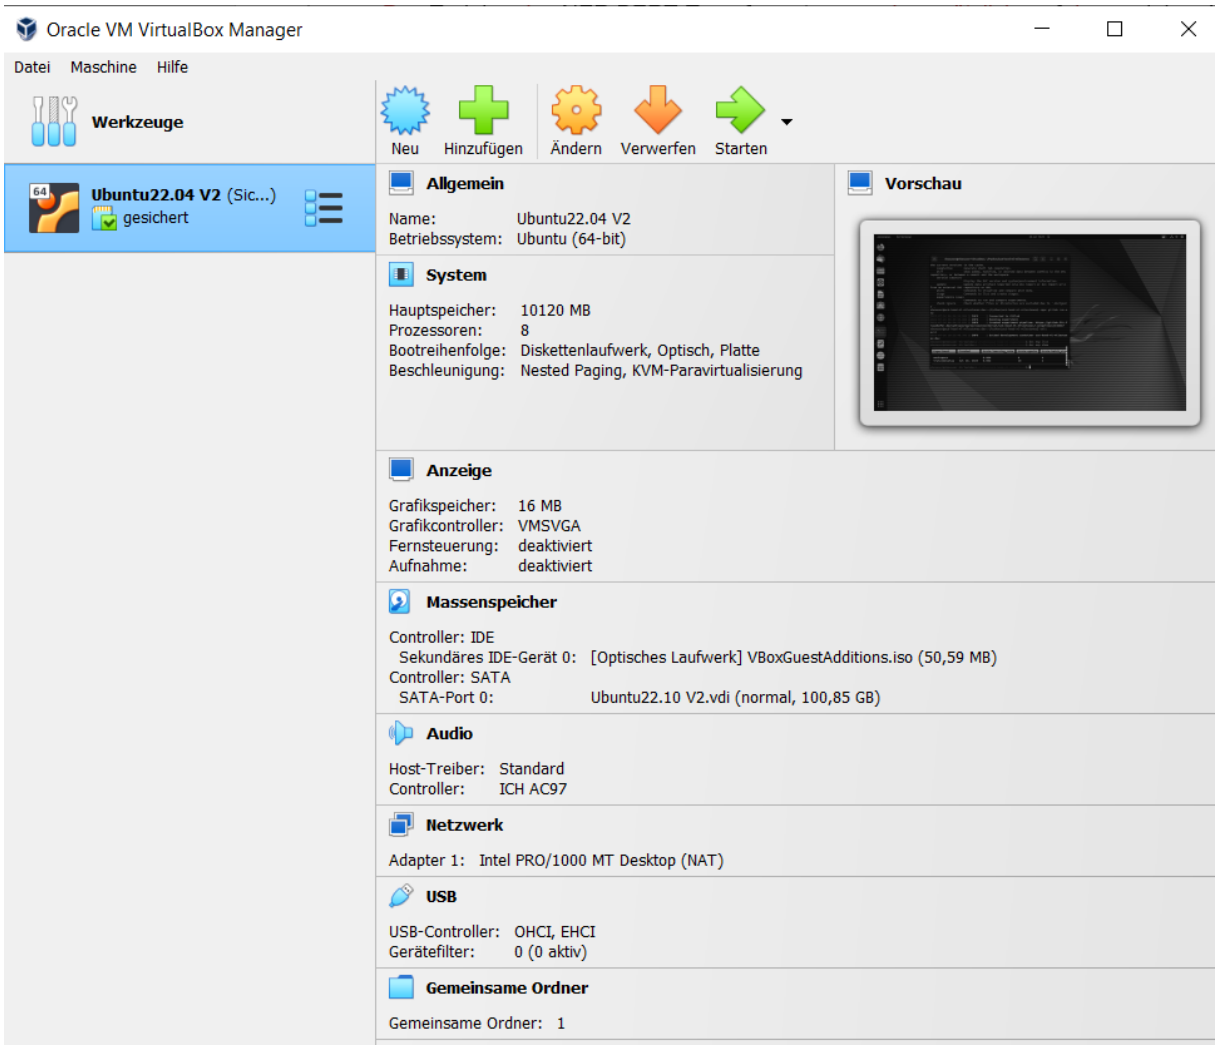

Abbildung 21: Virtuelle Maschine mit Ubuntu 22.04 in Oracle VirtualBox

Abschließend wurde die Fragestellung untersucht, wie aus einem Dokument Begriffe und deren Bedeutung extrahiert werden können.

Zu diesem Zweck wurden umfangreiche Daten annotiert, um spezielle Sprachmodelle für Named Entity Recognition (NER) und Entity Relation Extraction (ERE) zu trainieren. Die mithilfe dieser Modelle extrahierten Entitäten und Relationen wurden in Triplets zusammengefasst und in einen Knowledge Graph integriert. Als Graphendatenbank wurde neo4j verwendet. Dieser Knowledge Graph wurde mit Hilfe generativer KI ausgewertet, um relevante Begriffe für ein Glossar zu identifizieren und deren Bedeutung im Kontext des Ausgangsdokuments zu extrahieren. Der Workflow dieses Vorgehens ist in der nachfolgenden Graphik dargestellt.

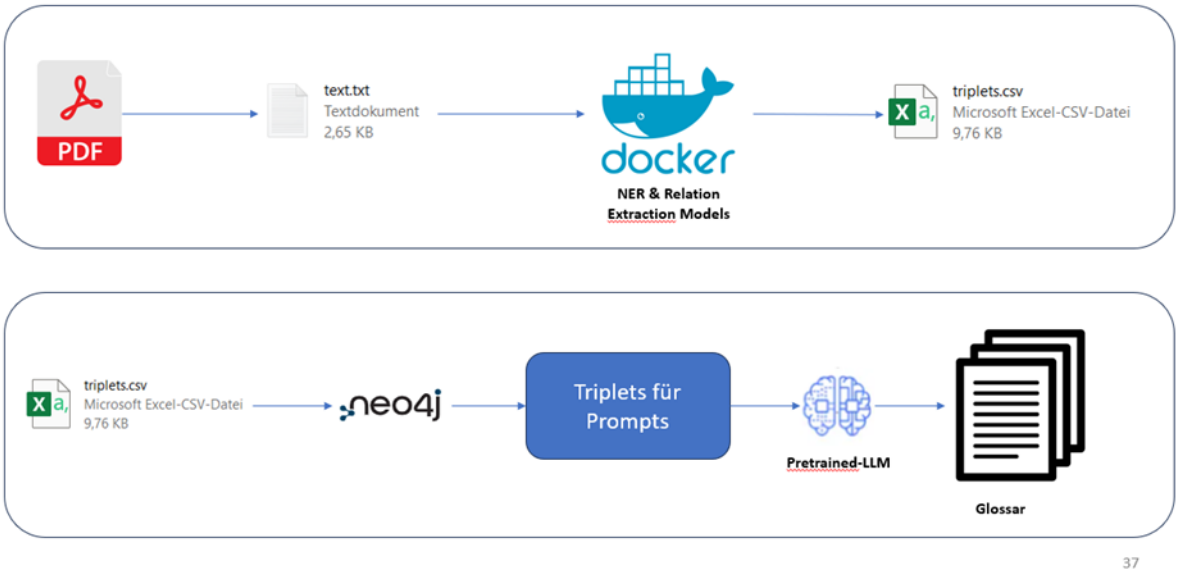

Abbildung 22: Vorgehensweise für die In-Context Ableitung von Glossarbegriffen und Definitionen

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 2.3.9: Entwicklung/Bewertung von Regeln für Constraint Solving (09-HOOD)

Ziele

- **Detektion von Constraints** in Lastenheften und Spezifikationen, um Anforderungen systematisch zu erfassen.
- **Nutzung von Constraints** zur Bewertung von KI-Ausgaben und zur Optimierung der Entscheidungsprozesse.
- **Erstellung von Regeln für Constraint Solving** zur effizienten Lösung von Problemen in Fertigungsprozessen.
- **Bewertung der entwickelten Regeln**, um ihre Anwendbarkeit und Effizienz in der Praxis zu gewährleisten.

Problemstellung

Lastenheften und Spezifikationen enthalten häufig unstrukturierte oder schwer erfassbare Anforderungen und Constraints. Diese sind jedoch entscheidend für die effiziente Nutzung von KI in Fertigungsprozessen. Es fehlt an etablierten Methoden, um diese Constraints automatisiert zu detektieren, in den Prozessablauf zu integrieren und für die Optimierung der KI-gestützten Entscheidungen zu verwenden. Zudem stellen die Komplexität der Fertigungsprozesse und die Notwendigkeit der Anpassung bestehender Systeme an die KI-Integration weitere Herausforderungen dar.

Lösungsweg und Ergebnisse

Der Lösungsweg zur Entwicklung und Bewertung von Regeln für das Constraint Solving folgt einem methodischen Ansatz, der auf der Detektion und systematischen Nutzung von Constraints in Lastenheften und Spezifikationen basiert. Dieser Ansatz zielt darauf ab, die Effizienz und Qualität der KI-gestützten Fertigungsprozesse, insbesondere in der Leiterplattenproduktion, zu verbessern.

1. Detektion von Constraints

Der erste Schritt des Lösungswegs bestand in der Entwicklung eines Verfahrens zur automatisierten Erkennung von Constraints in Lastenheften und Spezifikationen. Hierbei arbeitete das Projekt eng mit dem Partner DIQA zusammen, um Konzepte und Mechanismen zu identifizieren, die für den Aufbau einer Wissensdatenbank notwendig sind. Diese Wissensdatenbank dient der strukturierten Erfassung von Anforderungen und Constraints, die für den weiteren Prozess von großer Bedeutung sind.

Im Rahmen von UseCase#6 wurde intensiv untersucht, welche Konzepte sich am besten zur automatisierten Extraktion von Anforderungen eignen. Ein wesentlicher Aspekt war hierbei die Berücksichtigung von branchenspezifischen Normen und Regelsätzen, um sicherzustellen, dass die extrahierten Informationen den Anforderungen der jeweiligen Fertigungsprozesse entsprechen.

2. Nutzung von Constraints für KI-gestützte Prozesse

Nachdem die Constraints erkannt und in einer Wissensdatenbank abgelegt wurden, konnten sie zur Bewertung von KI-Ausgaben verwendet werden. Hier ging es insbesondere um die Optimierung der Fertigungsprozesse in der Leiterplattenherstellung. Verschiedene Fertigungsabschnitte, wie die Arbeitsvorbereitung, das Bohren, die Leiterbildbelichtung und die galvanische Aufkupferung, wurden auf ihre Eignung für eine KI-Integration hin untersucht.

- **Arbeitsvorbereitung**: KI wurde hier genutzt, um Daten zu kategorisieren, ihre Vollständigkeit zu prüfen und Layoutdaten mit Spezifikationen zusammenzuführen. Dies

führte zu einer effizienteren Datenverarbeitung und zur Erkennung von potenziellen Problemen, bevor diese den Produktionsprozess beeinflussen konnten.

- **Bohrprozess**: KI wurde eingesetzt, um die Qualität der Bohrungen durch die Analyse von Prüfplatinen zu bewerten. Die Einbindung von IPC-Regelsätzen half dabei, die besten Parameter für den Bohrprozess zu identifizieren, was zu einer höheren Präzision und Reduktion von Ausschuss führte.
- **Leiterbildbelichtung und galvanische Aufkupferung**: Weitere Fertigungsprozesse wurden ebenfalls für die KI-Integration in Betracht gezogen. Hier konnte die KI insbesondere zur Optimierung von Messergebnissen und zur Bestimmung der besten Prozessparameter eingesetzt werden. Diese automatisierten Auswertungen führten zu einer besseren Kontrolle der Prozessstabilität und zu einer Steigerung der Produktionsqualität.

3. Erstellung und Bewertung von Regeln für das Constraint Solving

Ein zentrales Ergebnis des Projekts war die Erstellung spezifischer Regeln für das Constraint Solving. Diese Regeln wurden auf Basis der erkannten Constraints und den Anforderungen der Fertigungsprozesse entwickelt. Ziel war es, automatisierte Lösungen für die Optimierung der Produktionsabläufe bereitzustellen. Die entwickelten Regeln wurden in den entsprechenden Fertigungsprozessen implementiert und auf ihre Effizienz und Praxistauglichkeit hin bewertet.

Die größten Herausforderungen bestanden darin, die Komplexität der Fertigungsprozesse mit den Möglichkeiten der KI-Technologie zu verbinden und sicherzustellen, dass die entwickelten Lösungen sowohl wirtschaftlich als auch technisch umsetzbar sind. Ein wichtiger Aspekt war hierbei die Anpassung bestehender Fertigungsprozesse, um die Vorteile der KI-Integration voll auszuschöpfen.

4. Ergebnisse

- Effizienzsteigerung und Kostensenkung: Durch die Integration von KI und die Nutzung von Constraints zur Prozessoptimierung konnten signifikante Effizienzgewinne und Kostensenkungen erzielt werden, insbesondere durch eine präzisere Datenverarbeitung und frühzeitige Problemerkennung.
- Verbesserung der Produktionsqualität: In den Bereichen Bohrprozess, Leiterbildbelichtung und galvanische Aufkupferung führte die KI-gestützte Analyse zu einer besseren Kontrolle der Prozessparameter und damit zu einer deutlichen Qualitätsverbesserung.
- Entwicklung anwendbarer Regeln: Die entwickelten Regeln für das Constraint Solving erwiesen sich als praxistauglich und konnten erfolgreich in den Fertigungsprozessen eingesetzt werden. Sie unterstützen die Automatisierung und tragen zur weiteren Optimierung der Produktionsabläufe bei.

3.2.4 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 Trainingssatz erstellt werden.

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

Bearbeitung der folgenden TA2.5-Themen:

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

- Anpassung von Entwurfsdaten sowie Vorverarbeitung zur Nutzung für CNN und Transfer-Learning.

Teilbeitrag 2.5.9: Trainingsmodelle für KI-Anwendungen im KFZ-Bereich (09-HOOD)

Ziele

Kenntnisvermittlung: Entwicklern sollen die notwendigen Kenntnisse vermittelt werden, um die Auswirkungen und Anwendungsmöglichkeiten von KI im Requirements-Engineering zu verstehen und einschätzen zu können.

Unterstützung des Mittelstands: Ziel ist es, Entwicklern das Wissen zu vermitteln, das ihnen ermöglicht, den Mittelstand optimal bei der Wertschöpfung in KI-gestützten Entwurfsprozessen zu unterstützen.

Effiziente Wissensvermittlung: Es sollen Methoden und Ansätze entwickelt werden, um das erforderliche Wissen effizient in den bestehenden Arbeitsalltag der Entwickler zu integrieren.

Problemstellung

Mittelständische Entwickler haben derzeit Schwierigkeiten, die Tragweite und Anwendungsmöglichkeiten von Künstlicher Intelligenz im Bereich des Requirements-Engineerings in KI-gestützten Entwurfsprozessen zu verstehen. Es mangelt an klaren Leitlinien und effizienter Wissensvermittlung, die es den Entwicklern ermöglichen würden, ihre bestehende Expertise in diesem neuen Kontext optimal einzusetzen und den Mittelstand entsprechend zu unterstützen.

Lösungsweg und Ergebnisse

Der Prozess zur Vermittlung der notwendigen Kenntnisse umfasste folgende Schritte:

1. **Analyse der Wissenslücken**: Zu Beginn wurde eine umfassende Analyse durchgeführt, um die spezifischen Wissenslücken und Herausforderungen zu identifizieren, denen sich Entwickler gegenübersehen, wenn sie KI im RE anwenden möchten.
2. **Entwicklung von Schulungs- und Trainingsmaterialien**: Basierend auf den identifizierten Wissenslücken wurden spezielle Schulungsmaterialien entwickelt. Diese zielten darauf ab, Themen wie Natural Language Processing (NLP) und große Sprachmodelle in verständlicher Form zu vermitteln.
3. **Workshops und Konferenzen**: Die entwickelten Materialien wurden in praxisnahen Workshops und auf Konferenzen vorgestellt, um Entwicklern die praktische Anwendung von KI im RE zu verdeutlichen. Ein Beispiel ist der NLP4RE-Workshop, der sich auf die Automatisierbarkeit von RE-Aufgaben und die Anwendung von NLP fokussierte.
4. **Kontinuierliche Anpassung**: Basierend auf dem Feedback aus den Workshops wurden die Inhalte fortlaufend optimiert und weiterentwickelt, um den Wissensbedarf der Entwickler kontinuierlich zu decken.

Dabei sind folgende Ergebnisse entstanden:

- **Prozessverbesserung und Trainingsmaterialien**: Durch die Schulungen wurden Entwicklern praxisnahe Einblicke in die Nutzung von KI im Requirements-Engineering gegeben, insbesondere im Bereich der Prozessverbesserung. Sie konnten lernen, wie KI-basierte Methoden ihre Arbeitsprozesse effizienter gestalten können.

Abbildung 23: Verbesserung von Engineering Prozessen und MBSE

- **Fehlererkennung und Konsistenzprüfung**: Im Rahmen des Projekts wurde eine KI-gestützte Fehlererkennung entwickelt, die insbesondere für die Konsistenzprüfung von Anforderungen genutzt werden kann. Dies wurde in Workshops zur Analyse von großen Sprachmodellen und NLP-Anwendungen thematisiert.

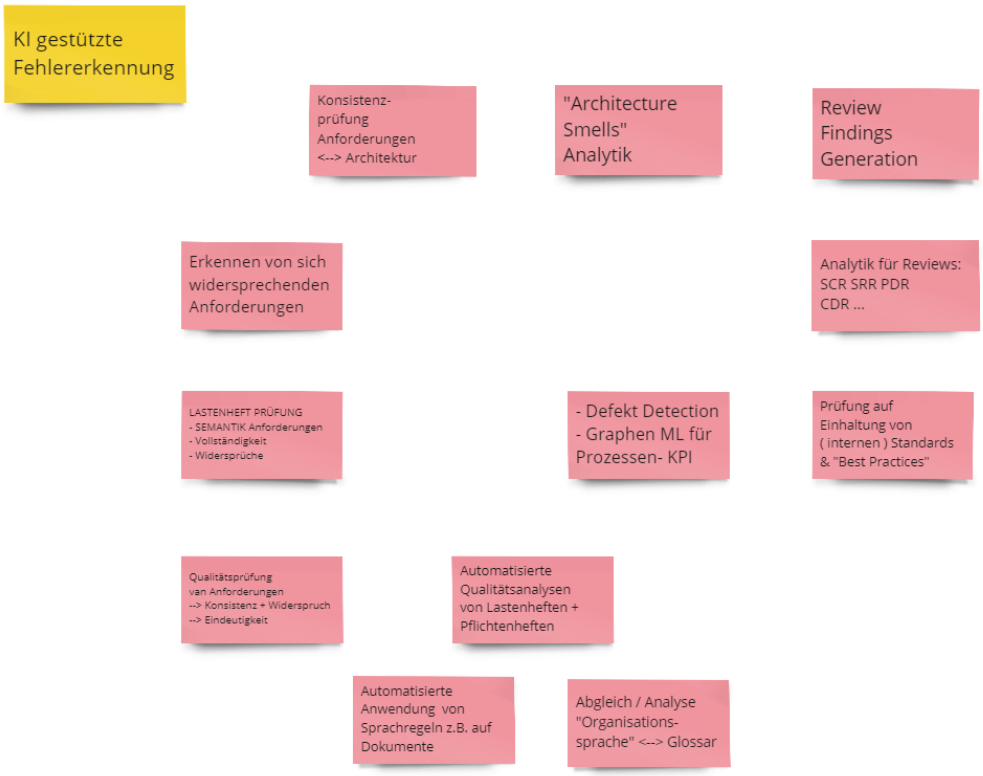

Abbildung 24: KI gestützte Fehlererkennung

- **Automatisierung wiederholender Aufgaben:** Ein zentraler Aspekt des Projekts war die Automatisierung von wiederkehrenden Aufgaben im Requirements-Engineering. KI-basierte Tools, die sich auf NLP und das semantische Web stützen, wurden in der Praxis implementiert, um repetitive Aufgaben effizienter zu gestalten.

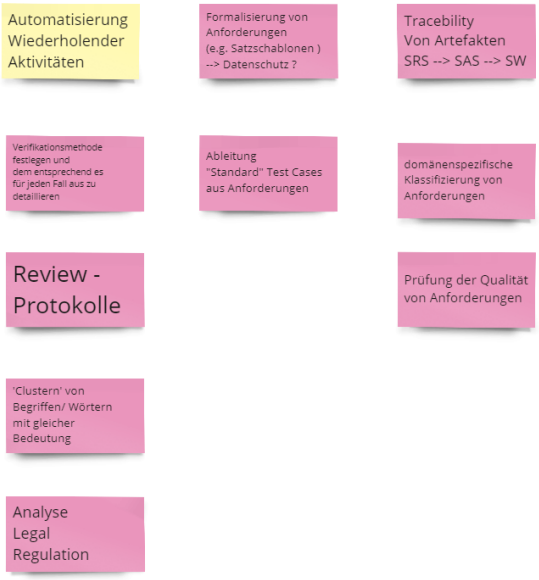

Abbildung 25: Automatisierung wiederholender Aktivitäten

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

Geplante Ergebnisse von AP3 waren:

- Im Zuge dieses Arbeitspakets wurden mehrere bedeutsame Ergebnisse angestrebt. Zunächst wurden Framework KI-Module für die Teilplattformen entwickelt und anschließend optimiert. Dies beinhaltete die Aufbereitung und Initialisierung der KI-Module, basierend auf etablierten Frameworks, sowie die Installation auf den erforderlichen Rechennetzen.

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

3.3.1 Teilaufgabe 3.4: 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 3.4.9: Verfahren zur Erfassung von Domänenwissen (09-HOOD)

Ziele

- **Erfassung von Domänenwissen**: Ziel ist es, das für Lastenheftanalysen notwendige Expertenwissen systematisch zu erfassen, insbesondere zur Ableitung von Design Constraints.
- **Schutz des geistigen Eigentums**: Ein weiterer Schwerpunkt liegt auf dem Schutz des erfassten Domänenwissens, um die Vertraulichkeit und das geistige Eigentum zu sichern.
- **Nutzbarmachung für KI-Systeme**: Das erfasste Domänenwissen soll in einer Form aufbereitet werden, die für den Einsatz in KI-gestützten Entwurfsprozessen geeignet ist

Problemstellung

Die Problemstellung dieses Teilbeitrags liegt in der systematischen Erfassung und Sicherung von Domänenwissen, das für die Analyse und Ableitung von Design Constraints aus Lastenheften unerlässlich ist. Domänenwissen ist oft implizit und nur in den Köpfen von Experten vorhanden, wodurch es schwer zugänglich und nicht in standardisierter Form verfügbar ist. Diese Herausforderung wird durch die Notwendigkeit verschärft, das erfasste Wissen so aufzubereiten, dass es für KI-gestützte Entwurfsprozesse nutzbar wird, während gleichzeitig der Schutz des geistigen Eigentums gewahrt bleibt.

Es muss ein Verfahren entwickelt werden, das nicht nur das implizite Wissen von Experten identifiziert und strukturiert, sondern auch sicherstellt, dass dieses Wissen sicher und geschützt bleibt, um Missbrauch oder unbefugten Zugriff zu verhindern. Darüber hinaus besteht die Herausforderung darin, dieses Wissen in einer Form zu erfassen, die es ermöglicht, in KI-Systemen eingesetzt zu werden, ohne dabei die Qualität und Integrität des Wissens zu verlieren.

Diese Problematik erfordert eine sorgfältige Balance zwischen der Erfassung detaillierter, wertvoller Informationen und der Wahrung der Vertraulichkeit dieser Daten. Gleichzeitig muss das Verfahren so gestaltet sein, dass es die Effizienz und Effektivität von KI-gestützten Entwurfsprozessen durch die Integration von Domänenwissen verbessert, ohne dass dabei das Risiko von Informationsverlust oder -verzerrung besteht.

Lösungsweg und Ergebnisse

Die Erfassung und Integration von Domänenwissen im Kontext des KI-gestützten Entwurfsprozesses erfordert eine Folge systematischer Schritten, die jeweils auf die spezifischen Herausforderungen der Problemstellung eingehen.

1. Systematische Erfassung von Domänenwissen

Der erste Schritt bestand darin, ein strukturiertes Verfahren zur Erfassung von Domänenwissen zu entwickeln. Dieses Verfahren zielt darauf ab, implizites Wissen, das oft nur in den Köpfen von Experten vorhanden ist, durch Interviews und andere Datenerhebungsmethoden zu identifizieren und explizit zu machen.

Im Rahmen dieser Erhebung wurde beispielsweise ein strukturiertes Interviewverfahren mit Requirements Engineering (RE) Experten entwickelt. Diese Interviews konzentrierten sich auf die „Identifikation von Anforderungen“ sowie die „Bewertung der Anforderungsqualität“. Hierbei wurde durch die Experten tiefgehendes Wissen erhoben, das anschließend in eine strukturierte Form gebracht wurde. Diese Methode gewährleistete, dass das erfasste Wissen sowohl qualitativ hochwertig als auch für die Weiterverarbeitung in KI-Systemen geeignet ist.

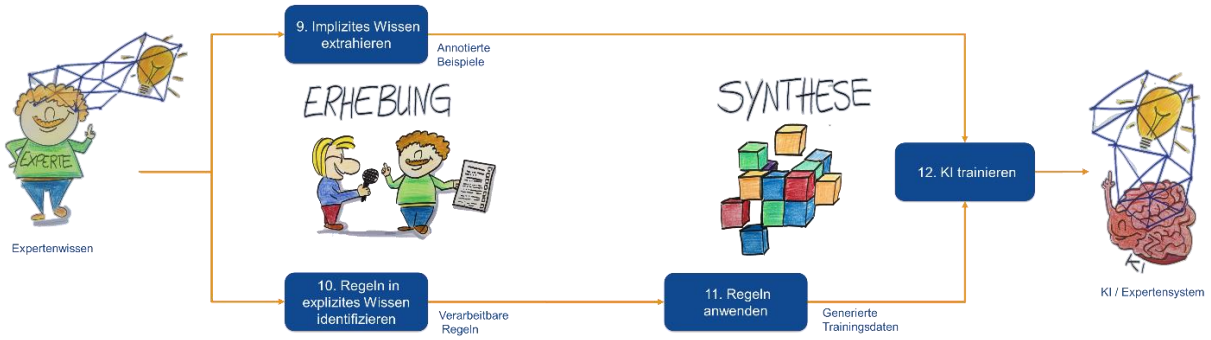

Abbildung 26: Erfassung von Expertenwissen für Implementierung in KI-Systemen

Diese Abbildung zeigt den Prozess der Erfassung und Aufbereitung von Expertenwissen, das anschließend in das KI-System integriert wird. Der Prozess beginnt mit der Extraktion impliziten Wissens, gefolgt von der Identifikation und Formalisierung dieses Wissens, bevor es in KI-Modulen implementiert wird.

2. Entwicklung von KI-Implementierungsstrategien

Nach der Erfassung des Domänenwissens folgte die Entwicklung von KI-Implementierungsstrategien. Diese Strategien wurden entwickelt, um das gesammelte Wissen in einer Form zu speichern, die von KI-Systemen effektiv genutzt werden kann. Ein besonderes Augenmerk lag hierbei auf der Unterscheidung zwischen internen und externen Merkmalen des Wissens. Interne Merkmale des Wissens erschließen sich aus dem betrachteten Dokument selbst, während externe Merkmale zusätzliches Wissen aus dem Kontext des Dokuments erfordern.

In einer detaillierten Tabelle wurden diese Merkmale systematisch beschrieben, um die Implementierung in KI-Systemen zu erleichtern. Diese Merkmale umfassen beispielsweise die Rolle des Dokumentenanwenders, den fachlichen Kontext, die Dokumentenart und -struktur sowie spezifische Schlüsselwörter und Begriffe, die in Anforderungen vorkommen.

Schritt	Stichwort	KI-Implementierungsstrategien	KI-Merkmal (Intern(I)/Extern (E))
1a	Rolle des Dokumentenanwenders	Rolle des Lesers ist nicht direkt aus dem Dokument ableitbar, kann aber extern bereitgestellt werden, z.B.: (a) Dokumentenersteller, (b) Dokumentenprüfer, (c) Implementierer Anmerkung: Ggf. Unterscheidung zwischen Einzeldokument und Dokumentenkorpus	M1a: RE-Rolle_Anwender (E)
1b	Fachlicher Kontext	Fachlicher Kontext ist hier als Dokumentationsmodell des Korpus gemeint, also welche Dokumente mit betrachtet werden müssen und in welcher Beziehung diese Dokumente zueinanderstehen. Im Dokumentationsmodell sollte das zu betrachtende Dokument ersichtlich sein. Das Dokumentationsmodell kann extern beigestellt werden.	M1b: Dokumentationsmodell (E)
1c	Background des Dokumentenerstellers	Wichtig ist der RE-Erfahrungsgrad (Anfänger, Erfahrener, Spezialist) oder die RE-Qualifikation (RE-Qualifikation: ja/nein) des Dokumentenerstellers	M1c1: RE-Erfahrungsgrad (E) M1C2: RE-Qualifikation (E)
2a	Dokumentenart	Die Intention des Autors und des Dokuments wird durch die Dokumentenart festgelegt. Die Dokumentenart kann in Ausnahmefällen durch Analyse des Dokuments erkannt werde. Leichter ist eine externe Bereitstellung der Information in Form einer Auswahlliste (Lastenheft, Pflichtenheft, Norm, Datenblatt, …)	M2a: Dokumentenart (E)
2b	Betrachtungsgegenstand	Vorschlagsliste für Betrachtungsgegenstand nach relativer Häufigkeit erstellen. Potenzielle Entwicklungsgegenstände sind in der Regel Nomen in ihrer Grundform. Hilfreich kann hier eine Blacklist oder Stoplist sein, in der häufige, aber in der Regel als	M2b: Betrachtungsgegenstand (I)

		Betrachtungsgegenstand irrelevante, Begriffe ausgeschlossen werden. Anmerkung: Der Betrachtungsgegenstand kann auch konkret im Dokument benannt sein, z.B. in einem entsprechenden Kapitel	
2c	Betrachtungsausschlüsse	Wird hier nicht weiterverfolgt.	
3a	Formatvorgaben für das Dokument	Folgt das Inhaltsverzeichnis einer Strukturvorgabe z.B. einer Guideline (Template) oder Norm? (Ansatz: Dokument enthält strukturierte Anforderungen: Ja/Nein) Kann unter Umständen aus der Dokumentenart abgeleitet werden. Ist das Dokument in einer bestimmten Sprache geschrieben? Englisch oder Deutsch? Diese Information ist wichtig, um das richtige Sprachmodell auszuwählen.	M3a: Erwartete_Anforderungsstrukturen (E) M3b: Dokumenten_Sprache (I)
3b	Identifizierbare Anforderungskapitel	Gibt es klar identifizierbare Kapitel mit Anforderungen bei Betrachtung des Inhaltsverzeichnisses? (Liste potenzieller Kapitel für Anforderungen)	M3b: potentielle_Anforderungskapitel (I)
3c	Erkennbare Anforderungsstrukturen	Können in dem Dokument Anforderungsstrukturen erkannt werden (ja/nein)? Falls ja, dann Liste identifizierter potenzieller Anforderungen.	M3c1: Erkannte_Anforderungsstrukturen (I) Z1: Potentielle_Anforderungen (I)
3d	Abstraktionslevel der Anforderungen	Sind Abstraktionslevel in Anforderungsstrukturen erkennbar? (ja/nein)	M3d: Anforderungshierarchien (I)
4a	Anforderungsschlüsselwörter	Siehe (3c). Sätze, die Schlüsselwörter enthalten, können in die Liste potenzieller Anforderungen aufgenommen werden (ja/nein). Potenzielle Schlüsselwörter können in einem diesbezüglichen Kapitel im Dokument oder einem referenzierten Dokument benannt sein. Automatische Erkennung, ob und welche Schlüsselworte benutzt worden sind.	M4a: Liste_Schlüsselwörter (E/I) M4b: Sätze_mit_Schlüsselwörtern (I) M4c: Sätze_ohne_Schüsselwörter (I) M4d: Liste_erkannter_Schlüsselwörter (I) Z1: Potentielle_Anforderungen (I)
4b	Zahlenwerte mit Einheiten	Physikalische Größen können Zielwerte / Soll-Eigenschaften des Entwicklungsgegenstands sein (z.B. SI-Einheiten) und sind daher ein Indikator für Anforderungen, Testfälle, etc. Das Nicht-Vorhandensein solcher Größen ist allerdings kein Indikator für Nicht-Anforderungen.	M4b1: Liste_zulässiger_Einheiten (E) M4b2: Liste_erkannter_Einheiten (I) M4b3: Sätze_mit_Einheiten (I) M4b4: Sätze_ohne_Einheiten (I) Z1: Potentielle_Anforderungen (I)

4c	Verwendete Fachausdrücke	Woran erkennt man Fachausdrücke? Liste muss als Glossar bereitgestellt werden.	M4c1: domänenspezifisches_Glossar (E/I) M4c2: identifizierte_Fachausdrücke (I)
4d	Prozessverben / Nominalisierungen	Funktionalitäten können durch Verben oder Nominalisierungen identifiziert werden.	M4d1: vorkommende_Verben (I) M4d2: vorkommende_Nomen (I)
4e	Bedingungswörter	Anforderungen gelten oft unter bestimmten Voraussetzungen oder in definierten Systemzuständen. Diese können an Schlüsselwörtern wie „Wenn“, „Falls“, „Im Zustand“, „Im Modus“, etc., oder auch an der Satzstruktur erkannt werden. Sätze, die mit Bedingungen beginnen oder Bedingen überhaupt enthalten sind potenzielle Anforderungen.	M4e1: Liste_Bedingungsindikatoren (E). M4e2: vorkommende_Bedingungswörter (I) M4e3: Sätze_mit_Bedingungen (I) Z1: Potentielle_Anforderungen (I)
4f	Gegenwarts- oder Zukunftsform	Üblicherweise sollten Anforderungen im Präsens beschrieben sein. Sätze in der Vergangenheits-Form sind nur mit sehr geringer Wahrscheinlichkeit Anforderungen.	M41f: Zeitform_Verben (I) M4f2: Sätze_Präsens (I) Z1: Potentielle_Anforderungen (I)
5a	Anforderungssubjekte	Wenn das Subjekt des Satzes dem Entwicklungsgegenstand oder einer bekannten Komponente des Systems entspricht, ist die Wahrscheinlichkeit hoch, dass es sich um eine Anforderung handelt. Der Entwicklungsgegenstand kann identisch mit dem Betrachtungsgegenstand sein. Das Anforderungssubjekt ist nicht immer das grammatikalische Subjekt. Sätze, die den Entwicklungsgegenstand beinhalten, sind potenzielle Anforderungen	M5a1: Entwicklungsgegenstand (E) M5a2: Liste_Systemkomponenten (I/E). M5a3: Identifizierte_Subjekte (I) Z1: Potentielle_Anforderungen (I)
5b	Anforderungsaussagen	Hypothese: Wenn das Anforderungssubjekt bekannt ist, wird die Anforderungsaussage für die Identifikation nicht benötigt. Die Anforderungsaussage ist in der Regel die Kombination eines Verbes mit einem Nomen-Konstrukt oder einer Eigenschaft. Hypothese: Die Häufigkeit von Passiv-Konstruktionen kann ein Indikator für Normen sein. Prädikatenlogik als Ansatz für die Identifikation der Anforderungsaussagen.	M5b1: Liste_Prädikat–Objekt_Kombinationen (I) M5b2: Verhältnis_aktiv_zu_passiv (I)
5c	Modellierbare Abhängigkeiten	Identifikation von Subjekt-Prädikat-Objekt Elementen für Knowledge-Graphen und entsprechende Modellierung. Interaktion mit dem Anwender, z.B. lokale Modellierung markierter Aspekte. Eingrenzung des Betrachtungsscopes z.B. auf einen Satz.	M5c1: SPO-Modell

		Begriffsmodellierung mit Synonymen, Antonymen, Meronymen, Homonymen, Hyperonymen aufgrund vorhandener Begriffe im Dokument. Modellierung der Abhängigkeiten der Anforderungsaussagen.	M5c2: Begriffsmodell M5c3: Abhängigkeitsmodell
5d	Inhalt zusammenfassbar	Lässt sich der Inhalt zusammenfassen? Z.B. Auflistung aller Nomen (Anforderungssubjekte) unter Berücksichtigung der Häufigkeit von Begriffen (z.B. TF-IDF zur Clustering)? Auflistung der Anforderungsaussagen und Erkennung von redundanten Informationen. Text Cleaning (verlustfrei / verlustbehaftet), z.B. syntaktisch (z.B. Stoppwörter entfernen) oder semantisch. Textklassifikation, z.B. durch Sentiment Analyse.	M5d1: Begriffshäufigkeit (I) M5d2: Identifizierte_Textklassen (I)
5e	Situationsbeschreibungen	Woran können Situationsbeschreibungen erkannt werden? Präsenzformulierung?	M5e: Zeitformstatistik (I)
5f	Charakteristik, Funktion, Verhalten, Schnittstelle	Ziel: Modellierung der Taxonomie und Abhängigkeiten mit Attributen.	M5f: Taxonomiemodell (I)

Tabelle 3: KI-Implementierungsstrategien

Diese Tabelle listet die verschiedenen Merkmale und ihre Zuordnung als interne oder externe Informationsquellen auf, die von der KI erkannt und verarbeitet werden sollen. Diese Systematisierung erlaubt eine präzise und effiziente Implementierung des Wissens in KI-gestützte Prozesse.

3. Automatisierte Bewertung der Anforderungsqualität

Ein zentraler Bestandteil des Lösungswegs war die Entwicklung von Automatisierungsstrategien zur Bewertung der Anforderungsqualität. Ausgangspunkt hierfür waren die 41 Regeln des INCOSE „Guide to Writing Requirements“. Diese Regeln wurden analysiert und es wurden spezifische KI-gestützte Prüfmethoden konzipiert, um die Einhaltung dieser Regeln zu überprüfen.

Diese Automatisierungsstrategien können in Form von KI-Modulen entwickelt werden, die es ermöglichen, Anforderungen systematisch zu analysieren und automatisch Verbesserungsvorschläge zu generieren.

Hierbei können verschiedene Techniken zum Einsatz kommen, wie beispielsweise NLP-basierte (Natural Language Processing) Methoden zur Satzanalyse, Regelwerke zur Überprüfung von Fachbegriffen und Einheiten sowie logische Konsistenzprüfungen.

Regel	Text	Fokus	Strategie
R1	Strukturierte, vollständige Sätze formulieren	Richtigkeit	Mittels Grammatik-Checker gegen vorgegebene Struktur prüfen
R2	Sätze im Aktiv formulieren	Richtigkeit	Mit NLP-Dependency-Analyse Satzbau prüfen

Regel	Text	Fokus	Strategie
R3	Geeignetes Subjekt-Verb verwenden	Richtigkeit	Anforderungssubjekte identifizieren und kontextspezifisch klassifizieren. Verben domänenspezifisch auf Kombinierbarkeit mit konkretem Anforderungssubjekt prüfen.
R4	Begriffe definieren	Richtigkeit	Automatisierte Glossarerstellung, ggf. mit domänenspezifischem Entity-Linking
R5	Bestimmte Artikel verwenden	Richtigkeit	Artikel mit NLP oder regulären Ausdrücken prüfen
R6	Geeignete Einheiten verwenden	Richtigkeit	Einheiten mit domänenspezifisch trainierter NER prüfen oder regelbasierte Einheitenprüfung
R7	Vage Begriffe vermeiden	Richtigkeit	Regelbasierte Ansätze zur Identifikation von „Weak Words“ oder Universalquantoren
R8	Ausweichbegriffe vermeiden	Richtigkeit	Regelbasiert Wortliste prüfen, z.B. Synsets
R9	Offene Klauseln vermeiden	Richtigkeit	Regelbasiert Wortliste prüfen, Grammatik gegen Vorgabe prüfen. Oder spezielles KI-Modell trainieren
R10	Überflüssige Infinitive vermeiden	Präzision	Regelbasierte Überprüfung
R11	Getrennte Klausel verwenden	Präzision	Satzbaumuster regelbasiert gegen Vorgabe prüfen,
R12	Korrekte Grammatik verwenden	Eindeutigkeit	Automatisierter Grammatik-Checker
R13	Korrekte Rechtschreibung verwenden	Eindeutigkeit	Automatisierte Rechtschreibprüfung mit Berücksichtigung domänenspezifischer Begriffe, z.B. im Glossar
R14	Korrekte Zeichensetzung verwenden	Eindeutigkeit	Regelbasierter Grammatik-Checker
R15	logischer Ausdruck	Eindeutigkeit	Logische Ausdrücke parsen um Fehler zu entdecken
R16	Verwendung von „nicht“ zu vermeiden	Eindeutigkeit	Regelbasierte Prüfung

Regel	Text	Fokus	Strategie
R17	Schrägstrich-Symbol vermeiden	Eindeutigkeit	Regelbasierte Prüfung mit besonderer Behandlung von zusammengesetzten Größeneinheiten
R18	Nur ein Gedanken pro Satz verwenden	Einzigartigkeit	NLP-POS-Analyse zur Bewertung der Satzkomplexität, ggf. auch Constituency Parsing
R19	Kombinatoren vermeiden	Einzigartigkeit	Regelbasierte Überprüfung auf Kombinatoren unter besonderer Berücksichtigung logischer Ausdrücke
R20	Zweck- und Begründungsphrasen vermeiden	Einzigartigkeit	Regelbasierte Erkennung von Begründungen, z.B. „um …. Zu erreichen“, ggf. durch NLP Satzanalyse unterstützt
R21	Klammern vermeiden	Einzigartigkeit	Regelbasierte Erkennung von Klammern, z.B. reguläre Ausdrücke, unter besonderer Beachtung logischer Ausdrücke
R22	Mengen explizit aufzählen	Einzigartigkeit	Regelbasierte Erkennung von Auslassungen („…“) oder Schlüsselbegriffen wie „usw.“
R23	Unterstützende Diagramme oder Modelle verwenden	Einzigartigkeit	Regelbasierte Verweise auf Abbildungen prüfen, ggf. in Verbindung mit Suche nach Schlüsselwörtern wie „Diagramm“
R24	Unbestimmte Pronomen vermeiden	Vollständigkeit	Unbestimmte Pronomen regelbasiert oder mit NLP Satzanalyse identifizieren
R25	Nicht auf Überschriften verlassen	Vollständigkeit	Komplexität von Überschriften prüfen, ggf. auch Wortwiederholungen in folgenden Absätzen
R26	Unrealistische Absolut-Angaben vermeiden	Realistisch	Regelbasierte Erkennung von Absolut-Angaben wie z.B. „100%“. Ggf. Trainieren eines Modells.
R27	Anwendbarkeit von Bedingungen explizit angeben	Bedingungen	Regelbasierte Erkennung von Bedingungen und Aufzählungen und Auswertung logischer Zusammenhänge in Teilaussagen

Regel	Text	Fokus	Strategie
R28	Für spezifische Aktionen einzeln Bedingungen angeben	Bedingungen	Regelbasierte Überprüfung der Auswertbarkeit von Teilaussagen
R29	Nach Typ oder Kategorie klassifizieren	Einzigartigkeit	Automatisierte Klassifizierung mittels eines geeigneten Modells
R30	Nur einmal ausdrücken	Einzigartigkeit	Automatisierte Prüfung auf Wiederholungen auch unter Berücksichtigung von Synonymen
R31	Angabe einer Lösung vermeiden	Abstraktion	Automatisierte Identifikation der Abstraktionsebene eines Satzes in Bezug auf andere Sätze
R32	"jedes" für eine universelle Quantifizierung verwenden	Quantoren	Regelbasierte Prüfung der Universalquantoren
R33	Größen mit einem Wertebereich definieren	Toleranz	Regelbasierte Überprüfung auf Toleranzangaben bei Größen
R34	Spezifische, messbare Leistungsziele formulieren	Quantifizierung	Regelbasierte Prüfung auf Verwendung von quantifizierenden Universalquantoren anstatt konkreten Zahlenwerte
R35	Zeitliche Abhängigkeiten explizit definieren	Quantifizierung	Prüfung auf bestimmte nichtspezifische zeitliche Weak-Words, die nicht als Bedingung gesehen werden dürfen
R36	Begriffen und Maßeinheiten konsistent verwenden	Einheitliche Sprache	Regelbasierte Prüfung von Begriffen gegen ein Glossar. Regelbasierte Prüfung von Einheiten gegen Vorgaben
R37	Akronyme einheitlich verwenden	Einheitliche Sprache	Regelbasierte Prüfung gegen Vorgaben, z.B. im Glossar
R38	Verwendung von Abkürzungen zu vermeiden	Einheitliche Sprache	Regelbasierte Prüfung auf Verwendung von Abkürzungen unter Berücksichtigung eines gegebenen Glossars oder einer Abkürzungsliste
R39	Projektweite Styleguides verwenden	Einheitliche Sprache	Regelbasierte Prüfung gegen Vorlage
R40	Zusammengehörige Anforderungen gruppieren	Modularität	NLP Similiarityanalyse von Anforderungen zur Identifikation potentieller Cluster

Regel	Text	Fokus	Strategie
R41	Einer bestimmten Struktur oder Vorlage folgen	Modularität	Regelbasierte Prüfung gegen Vorlage

Tabelle 4: Automatisierungsstrategien für INCOSE Regeln zur Anforderungsqualität

Diese Tabelle zeigt die entwickelten Automatisierungsstrategien, die auf die INCOSE-Regeln angewendet wurden. Sie bietet eine detaillierte Übersicht darüber, welche Aspekte der Anforderungen durch die KI überprüft werden und welche Methoden dafür verwendet werden.

4. Implementierung in KI-Systeme

Nach der Entwicklung und Erprobung der Strategien wurde das Wissen in KI-Systeme integriert, um dessen praktische Anwendbarkeit zu testen. Dabei wurden unter anderem ein BERT-basiertes Modell zur Textklassifikation und der HOOD Requirements Assistant entwickelt.

Textklassifikation:

Das BERT-Modell wurde speziell darauf trainiert, Texte als funktionale Anforderungen oder Kontextinformationen zu klassifizieren. Es wurde auf Basis qualitativ hochwertiger, von Fachexperten erstellter Trainingsdaten trainiert und erzielte eine Testgenauigkeit von 97,1%. Zur praktischen Anwendung wurde eine Webanwendung entwickelt, die es Anwendern ermöglicht, Texte zur Klassifikation einzugeben und sofortige Rückmeldungen zu erhalten.

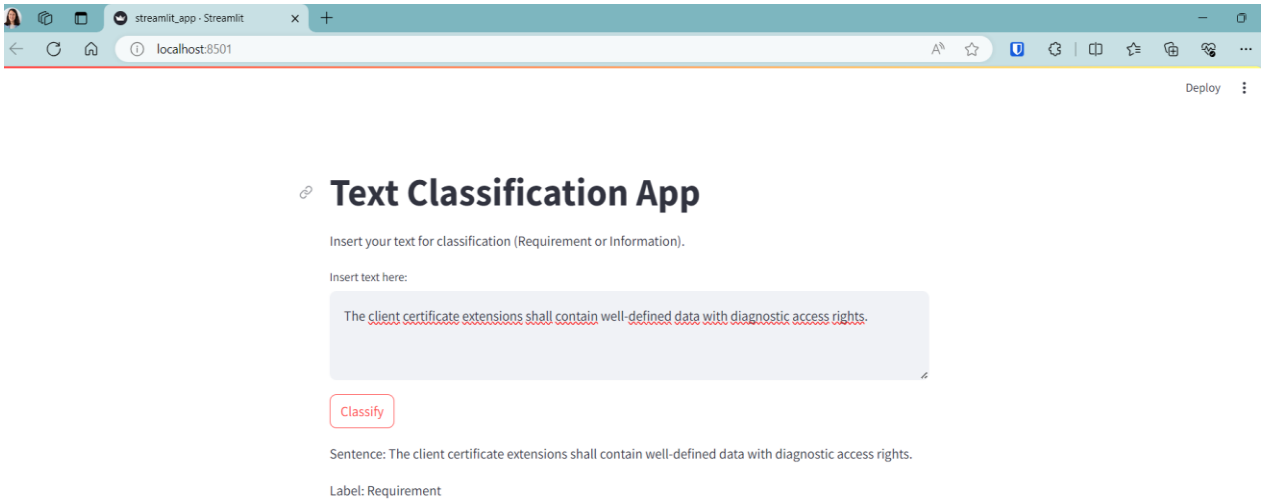

Abbildung 27: HOOD Text Classification App

Diese Abbildung zeigt die Oberfläche der Textklassifikations-App, die das BERT-Modell verwendet. Sie ermöglicht eine schnelle und effiziente Analyse von Anforderungen, indem sie diese automatisch klassifiziert.

HOOD Requirements Assistant:

Der HOOD Requirements Assistant, eine auf OpenAI GPT basierende KI, wurde entwickelt, um die Analyse und Verbesserung von Anforderungen zu unterstützen. Diese KI kann Anforderungen überprüfen, kommentieren, Verbesserungsvorschläge machen und potenzielle Anforderungen identifizieren. Der Assistant wurde so entwickelt, dass die Ausgabe qualitativ hochwertige Ergebnisse liefert, die nahe an die eines menschlichen Fachexperten heranreichen.

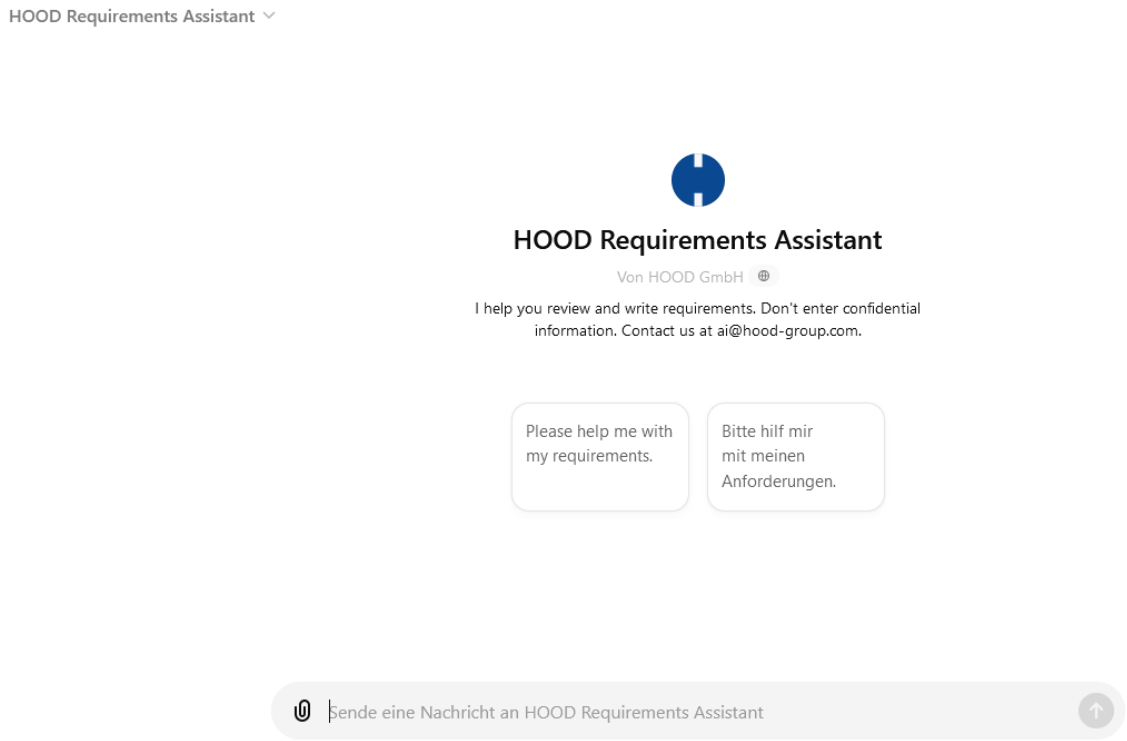

Abbildung 28: HOOD Requirements Assistant: Eingabe Maske

Dieses Bild zeigt die Benutzeroberfläche des HOOD Requirements Assistant, der es Anwendern ermöglicht, Anforderungen direkt einzugeben und automatisierte Rückmeldungen zu erhalten. Die KI liefert strukturierte Ausgabe, die zur Verbesserung der Anforderungen genutzt werden kann.

Die Herausforderungen bei der Umsetzung lagen vor allem in der Formulierung des System Prompts um

a) Die gewünschte Funktionalität zu erhalten,

b) Die Ausgabe in einem gewünschten Format zu erhalten,

c) Den System Prompt vor Veröffentlichung zu schützen, und

d) Die Ausgabe in der gleichen Sprache wie die Eingabe zu erreichen.

Zusammenfassung der Ergebnisse:

1. **Effiziente Erfassung von Domänenwissen**: Durch das entwickelte Verfahren wurde es möglich, implizites Expertenwissen systematisch zu erfassen und für KI-gestützte Entwurfsprozesse aufzubereiten.

2. **Automatisierte Qualitätsprüfung**: Die entwickelten KI-Module ermöglichen eine automatisierte, regelbasierte Überprüfung und Optimierung der Anforderungsqualität, basierend auf den INCOSE-Regeln.

3. **Integration in KI-Systeme**: Die Implementierung der entwickelten Strategien in KI-Systeme, wie das BERT-Modell und der HOOD Requirements Assistant, zeigt, dass das erfasste Wissen effektiv genutzt werden kann, um die Qualität und Effizienz des Requirements Engineering zu verbessern.

4. **Schutz des geistigen Eigentums**: Während des gesamten Prozesses sollte darauf geachtet werden, dass das erfasste Domänenwissen geschützt bleibt und die Vertraulichkeit sensibler Daten gewahrt wird. Dies ist bei der Nutzung von openAI ChatGPT nicht unbedingt gegeben.

3.3.2 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 erstellen 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 3.6.9: Dokumentationsanforderungen an KI-Systeme (09-HOOD)

Ziele

Nachvollziehbarkeit von Designentscheidungen: Sicherstellen, dass die durch KI-Systeme getroffenen Designentscheidungen im Entwicklungsprozess transparent dokumentiert und nachvollziehbar sind.

Dokumentation im Requirements-Engineering-Kontext: Entwicklung eines Konzepts zur strukturierten Dokumentation, das den Anforderungen im Requirements Engineering gerecht wird.

Ableitung von Anforderungen an Daten: Bestimmung der Anforderungen an die Daten, die für das Training der KI-Modelle erforderlich sind, um den Trainingsaufwand und die benötigten IT-Ressourcen effektiv planen zu können.

Problemstellung

Die automatische Generierung von Designentscheidungen durch KI-Systeme stellt neue Anforderungen an die Dokumentation im Entwicklungsprozess, insbesondere im Hinblick auf Transparenz und Nachvollziehbarkeit. Traditionelle Dokumentationsmethoden sind oft unzureichend, um die komplexen und dynamischen Entscheidungsprozesse, die KI-Systeme beeinflussen, vollständig abzubilden. Es besteht die Notwendigkeit, diese Anforderungen systematisch zu erfassen und zu dokumentieren, um die Planbarkeit und Risikoanalyse innerhalb des Requirements Engineering zu verbessern.

Lösungsweg und Ergebnisse

- **Entwicklung eines Dokumentationskonzepts**: Der erste Schritt bestand in der Entwicklung eines Konzepts zur Dokumentation von Anforderungen und Designentscheidungen im Kontext von KI-Systemen. Ziel war es, eine methodische Grundlage zu schaffen, die die komplexen Entscheidungsprozesse, die durch KI-Systeme beeinflusst werden, abbildet und nachvollziehbar macht. Hierzu wurden die Anforderungen, die an das KI-System gestellt werden, identifiziert und analysiert. Diese Analyse diente als Grundlage, um die spezifischen Anforderungen an die Daten abzuleiten, die für das Training der KI-Modelle benötigt werden.
- **Verknüpfung von User Stories mit Datenanforderungen**: Zur Verbesserung der Transparenz und Nachvollziehbarkeit wurde ein Konzept entwickelt, bei dem User Stories als geeignetes Format zur Dokumentation der Anforderungen identifiziert wurden. Diese User Stories wurden mit den notwendigen Datenanforderungen verknüpft. Diese Vorgehensweise ermöglichte es, den Umfang und Aufwand des erforderlichen Modelltrainings abzuschätzen und die erforderlichen IT-Ressourcen entsprechend zu planen.

- **Festlegung und Evaluation von Akzeptanzkriterien**: Ein weiterer wichtiger Schritt bestand in der Definition von Akzeptanzkriterien, die durch die Referenzierung manueller Tätigkeiten von Fachexperten abgeleitet wurden. Diese Kriterien fokussierten sich insbesondere auf Ziel-Korridore für Performance und Genauigkeit der Modelle. Die Evaluation der Modelle diente dazu, zu überprüfen, ob diese Akzeptanzkriterien erfüllt werden konnten. Falls dies nicht der Fall war, wurden die Ursachen analysiert, insbesondere ob die Erwartungen zu hoch angesetzt waren oder ob die zugrundeliegenden Daten ungeeignet waren.
- **Untersuchung von Mitigationstechniken für Halluzinationen**: Während des Projekts wurde erkannt, dass Halluzinationen in großen Sprachmodellen eine bedeutende Herausforderung darstellen, insbesondere in sicherheitskritischen Anwendungen. Daher wurden umfassende Studien zu Mitigationstechniken durchgeführt, die darauf abzielen, diese Halluzinationen zu reduzieren. Die Ergebnisse dieser Studien wurden systematisiert und in der folgenden Tabelle zusammengefasst:

Tabelle 5: LLM-Halluzinations-Mitigationstechniken nach Towhidul Islam Tonmoy et.al. [xxx]

Methode	Beschreibung	Quelle
1. Retrieval-Augmented Generation [http://arxiv.org/abs/2311.09114]		
1a. Retrieval Augmented Generation before generation		
• LLM-Augmenter	Der „LLM-Augmenter“ verbessert große Sprachmodelle durch die Integration von externem Wissen und automatisiertem Feedback, um genaue und überprüfbare Antworten zu erzeugen. Dies erfolgt in den Schritten: 1. relevante externe Informationen abrufen 2. Beweisketten bilden 3. Antwort generieren 4. Antwort auf Halluzinationen prüfen 5. Feedback erzeugen 6. Prompt des Modells iterativ verfeinern	http://arxiv.org/abs/2302.12813
• FreshPrompt	„FreshPrompt“ verbessert die Anpassungsfähigkeit von großen Sprachmodellen an sich schnell änderndes Wissen, indem es aktuelle Informationen durch eine Suchmaschine in die Prompt-Erstellung integriert. Diese Methode des "Few-Shot Prompting" übertrifft andere Methoden in Bezug auf Korrektheit und reduziert Halluzinationen, was ihre Wirksamkeit bei der Anpassung von LLMs an schnell wechselnde Wissensumgebungen demonstriert.	http://arxiv.org/abs/2310.03214
1b. Retrieval Augmented Generation during generation		

Methode	Beschreibung	Quelle
• Knowledge Retrieval	„Knowledge Retrieval“ verbessert die Genauigkeit großer Sprachmodelle, indem es potenzielle Halluzinationen während des Generierungsprozesses aktiv erkennt und mithilfe abgerufenen Wissens korrigiert. Es nutzt die Logit-Ausgabewerte des Modells, um potenzielle Halluzinationen zu identifizieren, deren Genauigkeit zu validieren und erkannte Halluzinationen zu mindern. Dieser Ansatz ist entscheidend für die Verbesserung der Wahrscheinlichkeit, genaue und zuverlässige Sätze zu produzieren.	http://arxiv.org/abs/2307.03987
• Decompose and Query framework (D&Q)	Das „Decompose and Query (D&Q)-Framework“ bekämpft Halluzinationen und Herausforderungen bei Mehrschritt-Beziehungen durch Nutzung externen Wissens und Beschränkung des Reasonings auf zuverlässige Informationen. Dies führt zu einer signifikanten Leistungssteigerung in Frage-Antwort-Aufgaben und vor allem zu verbesserter Robustheit und Genauigkeit des LLMs.	http://arxiv.org/abs/2311.07491
• Real-time Verification and Rectification (EVER)	Das „Real-time Verification and Rectification (EVER)-Framework“ begegnet dem Problem ungenauer oder halluzinierter Inhalte in großen Sprachmodellen (LLMs), indem es eine Echtzeit-, schrittweise Strategie während der Generierung implementiert. Diese Methode identifiziert und korrigiert effektiv sowohl intrinsische als auch extrinsische Halluzinationen, was zu signifikanten Verbesserungen bei der Erzeugung vertrauenswürdiger und faktisch genauer Texte in verschiedenen Aufgaben führt.	http://arxiv.org/abs/2311.09114
1c. Retrieval Augmented Generation after generation		
• Retrofit Attribution using Research and Revision (RARR)	„Retrofit Attribution using Research and Revision (RARR)“ ist ein modellunabhängiges System zur Automatisierung des Attributierungsprozesses, bei dem Inhalte nach der Generierung mit abgerufenen Beweisen abglichen und dabei die ursprünglichen Textqualitäten bewahrt wird.	https://arxiv.org/pdf/2210.08726.pdf
• High Entropy Word Spotting and Replacement	„High Entropy Word Spotting and Replacement“ ist eine Technik, die darauf abzielt, hochentropische Wörter in von großen Sprachmodellen (LLMs) generierten Texten zu identifizieren und zu ersetzen, um Halluzinationen zu verringern. Dieser Ansatz behandelt aufeinanderfolgende hochentropische Wörter als eine Einheit und ersetzt sie durch ein LLM mit niedrigerem Halluzinationsanfälligkeitsindex.	http://arxiv.org/abs/2310.04988
1d. End-to-End RAG		

Methode	Beschreibung	Quelle
• End-to-End Process of RAG	Der „End-to-End-Process of Retrieval-Augmented Generation (RAG)“ kombiniert einen vortrainierten Sequenz-zu-Sequenz-Transformator mit einem dichten Vektorindex von Wikipedia, der über den Dense Passage Retriever (DPR) zugänglich ist. Diese Methode ermöglicht es dem Modell, seine Ausgabe sowohl auf die Eingabeanfrage als auch auf relevante Dokumente abzustimmen und sorgt so für informiertere und kontextuell genauere Antworten.	https://arxiv.org/pdf/2005.11401.pdf
2. Self-Refinement through Feedback and Reasoning		
• Prompting GPT-3 To Be Reliable	„Prompting GPT-3 To Be Reliable“ verbessert die Zuverlässigkeit von GPT-3 durch Einführung spezifischer Prompts, welche die Leistung in verschiedenen Zuverlässigkeitsaspekten wie Generalisierbarkeit, soziale Verzerrungen, Kalibrierung und Faktizität verbessern. Dieser Ansatz verwendet Few-Shot Prompting, um kleinere überwachte Modelle in Zuverlässigkeitsmetriken zu übertreffen und bietet praktische Strategien für reale Sprachaufgaben, wobei eine umfassende Methode zur Verbesserung der Zuverlässigkeit von GPT-3 demonstriert wird.	https://arxiv.org/pdf/2210.09150.pdf
• ChatProtect	„ChatProtect“ will Selbstwidersprüche in den von großen Sprachmodellen (LLMs) generierten Antworten mindern durch Verwendung einer dreistufige Pipeline, die Selbstwidersprüche im generierten Text effektiv identifiziert und adressiert. Diese auf Prompt Strategien basierende Methode ist auf Black-Box-LLMs anwendbar, ohne dass externes fundiertes Wissen erforderlich ist.	http://arxiv.org/abs/2305.15852
• Self-Reflection Methodology	Die "Self-Reflection Methodology" verbessert die Genauigkeit und Zuverlässigkeit von Antworten in medizinischen generativen Frage-Antwort-Systemen, indem sie in einem interaktiven Ansatz Wissenserwerb und iteratives Verfeinern kombiniert, um Halluzinationen zu reduzieren.	http://arxiv.org/abs/2310.06271
• Structured Comparative (SC) reasoning	"Structured Comparative (SC) Reasoning" ist eine Methode, die die Textpräferenzvorhersage in großen Sprachmodellen (LLMs) verbessert, indem sie strukturierte Textvergleiche unter bestimmten Aspekten generiert. Sie verwendet einen paarweisen Konsistenzvergleich, um sicherzustellen, dass jeder Vergleich Texte deutlich voneinander unterscheidet, wodurch Halluzinationen reduziert und die Konsistenz verbessert wird.	http://arxiv.org/abs/2311.08390

Methode	Beschreibung	Quelle
• Mind's Mirror	"Mind's Mirror" ist eine Methodik, die entwickelt wurde, um die Selbstbewertungsfähigkeiten kleiner Sprachmodelle (SLMs) zu verbessern, insbesondere um Halluzinationen und fehlerhaftes Denken zu reduzieren. Sie beinhaltet das Destillieren der Selbstbewertungsfähigkeiten großer Sprachmodelle (LLMs) in SLMs, wodurch diese unzuverlässiges Denken und Halluzinationen erkennen und korrigieren können.	http://arxiv.org/abs/2311.09214
• DRESS	"DRESS" ist eine Methode, die natürliches Sprachfeedback (NLF), insbesondere Kritik und Verfeinerung, nutzt, um die Ausrichtungs- und Interaktionsfähigkeiten von großen visuell-sprachlichen Modellen (LVLMs) zu verbessern. Sie integriert bedingtes Reinforcement Learning, um nicht-differenzierbares NLF effektiv zu nutzen und trainiert das Modell darauf, Antworten basierend auf dem NLF zu generieren	https://arxiv.org/pdf/2311.10081.pdf
• MixAlign	„MixAlign" ist ein Rahmenwerk, welches sowohl mit dem Benutzer als auch mit der Wissensbasis interagiert, um zu klären, wie die Frage des Benutzers mit den gespeicherten Informationen zusammenhängt. Es verwendet ein Sprachmodell für die automatische Wissensabstimmung und verbessert bei Bedarf diese Abstimmung durch benutzergestützte Wissensabstimmung, also der Generierung von Fragen an den Benutzer zur Klarstellung, wenn Benutzerfragen nicht gut mit gespeicherten Informationen übereinstimmen.	http://arxiv.org/abs/2305.13669
• Chain-of-Verification (CoVe)	„Chain-of-Verification (CoVe)" umfasst einen vierstufigen Prozess zur unabhängigen Entwurfsüberprüfung und Sicherstellung, dass die endgültige Antwort genauer und faktenbasiert ist: 1. das Erstellen einer ersten Antwort, 2. das Planen von Verifizierungsfragen zur Überprüfung des Entwurfs, 3. das unabhängige Beantworten dieser Fragen für unvoreingenommene Antworten und 4. das Erzeugen einer endgültig verifizierten Antwort. Der Ansatz soll gut bei Aufgaben wie listenbasierten Wikidata-Fragen und der Generierung von Langtexten wirken.	http://arxiv.org/abs/2309.11495

Methode	Beschreibung	Quelle
• Chain of Natural Language Inference (CoNLI)	„Chain of Natural Language Inference (CoNLI)“ ist ein hierarchisches Framework zur Erkennung und Minderung von Halluzinationen in großen Sprachmodellen, ohne dass Feinabstimmungen oder domänenspezifische Aufforderungen erforderlich sind. Dieses Framework kann nicht fundierte Inhalte identifizieren und dann Post-Editing einsetzen, um Halluzinationen zu reduzieren und die Textqualität zu verbessern, ohne dass Anpassungen am Modell selbst erforderlich sind. Besonders wirksam soll dieser Ansatz sowohl in der Erkennung als auch in der Reduzierung von Halluzinationen in Text-zu-Text-Datensätzen sein.	http://arxiv.org/abs/2310.03951
3. Prompt Tuning [https://doi.org/10.18653/v1/2021.emnlp-main.243]		
• Universal Prompt Retrieval for Improving Zero-Shot Evaluation (UPRISE)	„Universal Prompt Retrieval for Improving Zero-Shot Evaluation (UPRISE)“ beinhaltet das Abstimmen eines leichten und vielseitigen Retrievers, der automatisch relevante Prompts für eine gegebene Aufgabe abruft. Diese Methode verbessert die Fähigkeit des LLMs, genauere und zuverlässigere Antworten zu generieren, insbesondere in Zero-Shot-Szenarien, in denen das Modell auf Aufgaben stößt, die es während des Trainings nicht gesehen hat.	http://arxiv.org/abs/2303.08518
• SynTra	„SynTra“ nutzt einen synthetischen Task für das Prefix-Tuning des LLMs, um dessen Systemnachricht speziell für die Minderung von Halluzinationen zu optimieren. Nach dem Training mit dieser synthetischen Aufgabe wird die verbesserte Fähigkeit dann auf komplexere, realistischere Zusammenfassungsaufgaben übertragen. Dieser Ansatz begegnet der Herausforderung von Halluzinationen, indem er die Reduzierung von Halluzinationen während des Trainingsprozesses des Modells sorgfältig bewertet und optimiert.	http://arxiv.org/abs/2310.06827
4. Decoding Strategy [https://doi.org/10.18653/v1/2023.emnlp-main.172]		
• Context-Aware Decoding (CAD)	„Context-Aware Decoding (CAD)“ ist eine Methode zur Verstärkung der Unterschiede in den Ausgabewahrscheinlichkeiten, wenn ein Modell mit und ohne Kontext arbeitet. Die Wirksamkeit von CAD liegt im Überschreiben des vorherige Wissen eines Modells, wenn dieses dem bereitgestellten Kontext widerspricht. CAD zeigt so sein Potenzial zur Reduzierung von Halluzinationen in der Textgenerierung, indem es zuverlässige und vertrauenswürdige Informationen über bestehende Modell Biases priorisiert. Bemerkenswerterweise kann CAD bei fertig vortrainierten Sprachmodellen ohne zusätzliches Training angewendet werden.	http://arxiv.org/abs/2305.14739

Methode	Beschreibung	Quelle
• Decoding by Contrasting Layers (DoLa)	„Decoding by Contrasting Layers (DoLa)“, ist eine Decodierungsstrategie zur Minderung von Halluzinationen in vorab trainierten großen Sprachmodellen (LLMs), die keine externe Wissenskonditionierung oder zusätzliche Feinabstimmung benötigt. DoLa funktioniert, indem es Logit-Unterschiede zwischen späteren und früheren Transformer-Schichten im Vokabularraum kontrastiert. Diese Methode nutzt die Lokalisierung von faktischem Wissen in bestimmten Schichten, um die Identifikation von Faktenwissen zu verbessern und die Erzeugung falscher Fakten zu minimieren. Angewendet auf verschiedene Aufgaben, einschließlich Multiple-Choice- und offenen Generierungsaufgaben wie TruthfulQA, verbessert DoLa konsequent die Wahrhaftigkeit und erhöht die Leistung von LLMs.	http://arxiv.org/abs/2309.03883
• Inference-Time Intervention (ITI)	„Inference-Time Intervention (ITI)“ zielt darauf ab, die Wahrhaftigkeit großer Sprachmodelle (LLMs) zu verbessern. ITI verschiebt Modellaktivierungen während der Inferenz und folgt dabei einer Menge von Richtungen über eine begrenzte Anzahl von Attention Heads. Diese Intervention beginnt mit der Identifizierung eines Sparce Sets von Attention Heads, die eine hohe lineare Testgenauigkeit für Wahrhaftigkeit aufweisen. Während der Inferenz werden Aktivierungen entlang dieser wahrheitskorrelierten Richtungen verschoben, und diese Intervention wird autoregressiv wiederholt, bis die vollständige Antwort generiert ist.	https://arxiv.org/pdf/2306.03341.pdf
5. Utilization of Knowledge Graph (KG) [https://arxiv.org/pdf/2308.10168.pdf]		
• RHO	„RHO“ ist ein Framework zur Minderung von Halluzinationen bei der Generierung von Dialogantworten durch Verwendung von externem Wissens in Form von Repräsentationen verknüpfter Entitäten und Beziehungsaussagen aus einem Wissensgraphen (KG). RHO führt lokale und globale Wissensverankerungstechniken in die Dialoggenerierung ein, ergänzt durch ein konversationelles Schlussfolgerungsmodell zur Neubewertung generierter Antworten. Diese Verankerungstechniken ermöglichen es dem Modell, Wissen aus kontextbezogenen Teilgraphen effektiv zu kodieren und zu integrieren. Durch die Integration von externem Wissen mit dem Dialogkontext und der Nutzung verschiedene Verankerungs- und Schlussfolgerungstechniken können Halluzinationen in generierten Antworten weiter reduziert werden.	https://aclanthology.org/2023.findings-acl.275.pdf

Methode	Beschreibung	Quelle
• FactuaL Error detection and correction with Evidence Retrieved from external Knowledge (FLEEK)	"FactuaL Error Detection and Correction with Evidence Retrieved from external Knowledge (FLEEK)" ist ein intelligentes, modellagnostisches Werkzeug, das zur Überprüfung und Korrektur von Fakten dient. FLEEK verfügt über eine benutzerfreundliche Oberfläche und identifiziert autonom potenziell überprüfbare Fakten im Eingabetext. Es formuliert Fragen zu jedem Fakt und fragt sowohl kuratierte Wissensgraphen als auch das offene Web ab, um Beweise zu sammeln. Anschließend überprüft das Tool die Richtigkeit der Fakten anhand der erworbenen Beweise und schlägt Änderungen am Originaltext vor. Der Prozess ist transparent und interpretierbar, wobei das Tool visuell überprüfbare Fakten in verschiedenen Farben hervorhebt, um deren Faktizitätsniveaus anzuzeigen und den Benutzern das Verständnis des Überprüfungsprozesses zu erleichtern.	http://arxiv.org/abs/2310.17119
6. Faithfulness-Based Loss Function [https://arxiv.org/pdf/2108.13759.pdf]		
• Text Hallucination Mitigating (THAM) Framework	Das „Text Hallucination Mitigating (THAM) Framework" ermittelt den Text Hallucination Regularization (THR) Verlust, der aus der gegenseitigen Information zwischen dem Antwort-Sprachmodell und einem vorgeschlagenen Halluzinations-Sprachmodell abgeleitet wird. Dieser auf informationstheoretischen Prinzipien basierende Ansatz zielt darauf ab, Halluzinationseffekte auf Feature-Ebene in Sprachmodellen zu mindern. Durch die Minimierung des THR-Verlustes reduziert das THAM-Framework willkürliches Textkopieren und verbessert die Leistung von Dialogsystemen.	https://doi.org/10.18653/v1/2022.emnlp-main.280
• Loss Weighting Method	Die „Loss Weighting Methode" konzentriert sich auf die Reduktion von Halluzinationen im Kontext der mehrsprachigen Zusammenfassung für große Sprachmodelle (LLMs). Diese Methode beinhaltet die Gewichtung des Verlusts der Trainingssamples basierend auf ihrem Treue-Score, unter Verwendung der mFACT Metrik. Dieser Ansatz hat gezeigt, dass während allgemeine Methoden des cross-lingualen Transfers die Zusammenfassungsleistung verbessern, sie auch Halluzinationen im Vergleich zu einsprachigen Methoden verstärken. Durch die Anpassung einsprachiger Methoden an den cross-lingualen Transfer und die Anpassung der Verlustgewichtung basierend auf dem mFACT-Score jedes Trainingsexamples reduziert diese Methode effektiv Halluzinationen in mehrsprachigen LLMs.	http://arxiv.org/abs/2305.13632
7. Supervised Fine-Tuning (SFT) [https://arxiv.org/pdf/2304.12244v2.pdf]		

Methode	Beschreibung	Quelle
• Knowledge Injection and Teacher-Student Approaches	„Knowledge Injection und Teacher-Student-Approaches“, wie z.B. HALOCHECK, konzentrieren sich auf die Minderung von Halluzinationen in kleinen Large Language Models mit niedrigem Parameterzahl. Dieser Ansatz verwendet Satzlevel-Entailment, um Halluzinationsniveaus quantitativ zu bewerten und verbessert so kleinere LLMs durch Knowledge Injection (KI) mittels Feinabstimmung mit Domänenwissen. Es nutzt leistungsfähigere LLMs wie GPT-4, um schwächere LLMs bei der Generierung detaillierter Frage-Antworten zu leiten und optimiert das Engagement von Lehrer-LLMs. Diese Methode reduziert effektiv die Rechenkosten und den Bedarf an häufigen Abfragen an stärkere Lehrermodelle durch Optimierung kleinerer Modelle für die gleiche Aufgabenstellung.	http://arxiv.org/abs/2308.11764
• Hallucination Augmented Recitations (HAR)	„Hallucination Augmented Recitations (HAR)“ repräsentiert einen neuen Ansatz zur Verbesserung der Fähigkeiten von Sprachmodellen im Umgang mit Halluzinationen. Die Erwähnung von HAR neben anderen bedeutenden Techniken wie Feinabstimmung für Faktualität und verhaltensbasierte Feinabstimmung zeigt die Relevanz im breiteren Kontext der Verbesserung der Genauigkeit und Zuverlässigkeit von Sprachmodellausgaben.	http://arxiv.org/abs/2311.07424
• Fine-tuning Language Models for Factuality	Fine-tuning von Sprachmodellen für Faktualität zielt auf die Reduktion von Halluzinationen in Sprachmodellen ab durch den Einsatz von automatisierten Faktenprüfungsmethoden und Präferenz-basiertem Lernen mit Hilfe des Direct Preference Optimization-Algorithmus. Die Forscher haben das Llama-2-Modell für Faktualität ohne manuelle Annotatierung feinabgestimmt und dabei signifikante Fehlerreduktionen erzielt, insbesondere bei Biografien und medizinischen Fragen. Dieser Ansatz umfasst sowohl referenzbasierte als auch referenzfreie Wahrheitsbewertungen und demonstriert eine kosteneffektive Methode zur Verbesserung der Faktualität von Modellen bei der Generierung von Langtexten. Die Studie schlägt neue Benchmark-Aufgaben vor, diskutiert zukünftige Forschungsrichtungen und hebt die Skalierbarkeit des faktischen Reinforcement Learnings für größere Modelle in sicherheitskritischen Bereichen hervor.	http://arxiv.org/abs/2311.08401

Methode	Beschreibung	Quelle
• BEINFO	„BEINFO“ ist eine Methode, die 'verhaltensorientierte Feinabstimmung' verwendet, um die Treue der generierten Antworten in informationsorientierten Dialogen zu erhöhen. Diese Methode beinhaltet das Abstimmen des Modells auf eine große Sammlung von Dialogen, die an wahre Wissensquellen gekoppelt sind, erweitert um zufällig ausgewählte Fakten aus einer großen Wissensbasis. Der Ansatz von BEINFO verbessert die Genauigkeit und Zuverlässigkeit der Antworten von Dialogsystemen erheblich, indem sichergestellt wird, dass sie auf faktischen Inhalten basieren, wodurch die Wahrscheinlichkeit von Halluzinationen in den generierten Antworten verringert wird.	http://arxiv.org/abs/2311.09800
• Refusal-Aware Instruction Tuning (R-Tuning)	„Refusal-Aware Instruction Tuning (R-Tuning)“ ist eine Methodik, die zwei Hauptphasen umfasst: 1. Identifikation unsicherer Fragen durch Messung der Wissenslücke zwischen dem parametrischen Wissen eines großen Sprachmodells und den Anweisungen zur Feinabstimmung. Dies geschieht durch Inferenz auf Trainingsdaten und Vergleich von Vorhersagen mit Labeln. 2. Aufbau von ablehnungsbewussten Trainingsdaten, indem Verweigerungsausdrücke zu unsicheren Trainingsbeispielen hinzugefügt werden, bevor das LLM mit diesen Daten feinabgestimmt wird. Dieser Ansatz stattet LLMs mit der Fähigkeit aus, Fragen zu identifizieren und darauf zu verzichten, auf Fragen zu antworten, die außerhalb ihres Wissensbereichs liegen, wodurch die Erzeugung von inkorrekten oder halluzinierten Inhalten reduziert wird.	https://arxiv.org/pdf/2311.09677.pdf
• Think While Effectively Articulating Knowledge (TWEAK)	“Think While Effectively Articulating Knowledge (TWEAK)” ist eine neue Decodierungsmethode, die in jedem Schritt generierten Sequenzen und ihre zukünftigen Sequenzen als Hypothesen behandelt. TWEAK verwendet ein Hypothesen-Verifizierungsmodell (HVM), um jeden Generierungskandidaten danach zu bewerten, wie gut ihre entsprechenden Hypothesen die Eingabefakten unterstützen.	https://arxiv.org/pdf/2311.09467.pdf

- **Kombination von Ontologie und Knowledge Graphen**: Zur weiteren Verbesserung der Dokumentation wurde eine Ontologie entwickelt, die die Struktur und Klarheit von Anforderungen sicherstellt. Diese Ontologie wurde dann genutzt, um Knowledge Graphen zu generieren, die eine strukturierte Darstellung des Wissens ermöglichen. Verschiedene Large Language Models (LLMs) wurden getestet, um ihre Effektivität bei der Erkennung von

Stakeholdern und Adressaten zu vergleichen. Die Visualisierung dieser Knowledge Graphen in der Neo4j-Datenbank ermöglichte eine tiefere Analyse und ein besseres Verständnis der komplexen Zusammenhänge.

Zusammenfassung der Ergebnisse:

- Dokumentationskonzept: Ein systematisches Konzept zur Dokumentation von Anforderungen an KI-Systeme wurde erfolgreich entwickelt und implementiert. Dieses Konzept nutzt User Stories in Verbindung mit spezifischen Datenanforderungen, um die Nachvollziehbarkeit der KI-gestützten Designentscheidungen zu gewährleisten.
- Akzeptanzkriterien und Evaluation: Es wurden klare Akzeptanzkriterien festgelegt, die auf den manuellen Tätigkeiten von Fachexperten basieren. Diese Kriterien wurden erfolgreich in die Evaluation der entwickelten Modelle integriert, was zu einer besseren Planung und Risikoanalyse führte.
- Mitigationstechniken für Halluzinationen: Eine umfassende Untersuchung und Systematisierung von Mitigationstechniken zur Reduzierung von Halluzinationen in großen Sprachmodellen wurde durchgeführt. Diese Techniken wurden in verschiedenen Szenarien getestet und in einer Tabelle zusammengefasst.
- Ontologie und Knowledge Graphen: Die Kombination einer Anforderungs-Ontologie mit der Generierung von Knowledge Graphen führte zu einer verbesserten strukturierten Darstellung von Wissen. Die Visualisierung dieser Graphen in der Neo4j-Datenbank ermöglichte eine tiefere Analyse der Beziehungen und eine verbesserte Kommunikation im Projektmanagement.

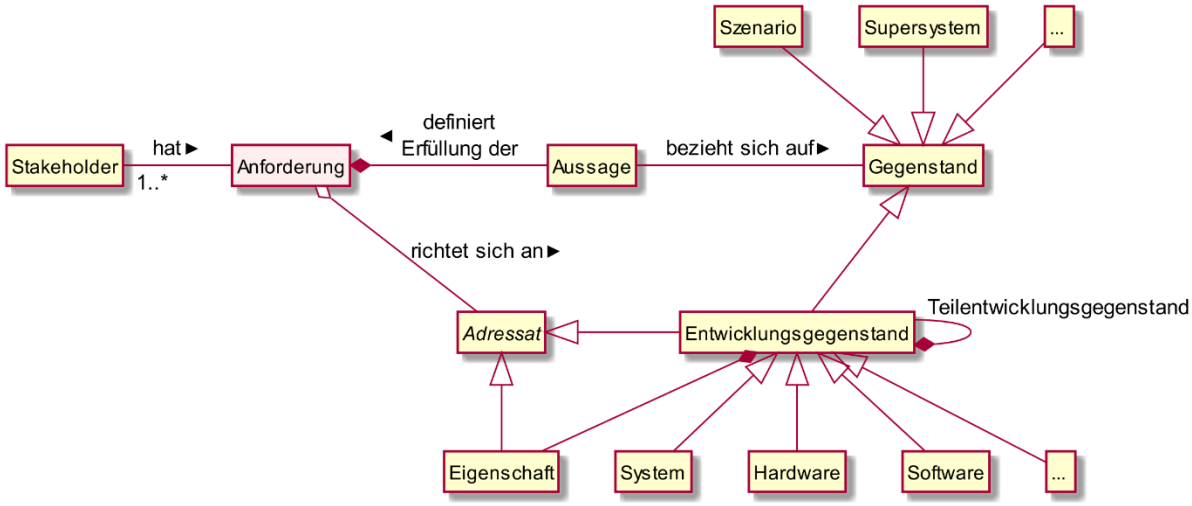

Abbildung 29: Ontologie einer Anforderung

Ontologie einer Anforderung: Die Ontologie einer Anforderung definiert die relevanten Begriffe und deren Beziehungen innerhalb des Anforderungsmanagements. Sie bietet eine klare Struktur und hilft dabei, die Nachvollziehbarkeit der Anforderungen zu gewährleisten.

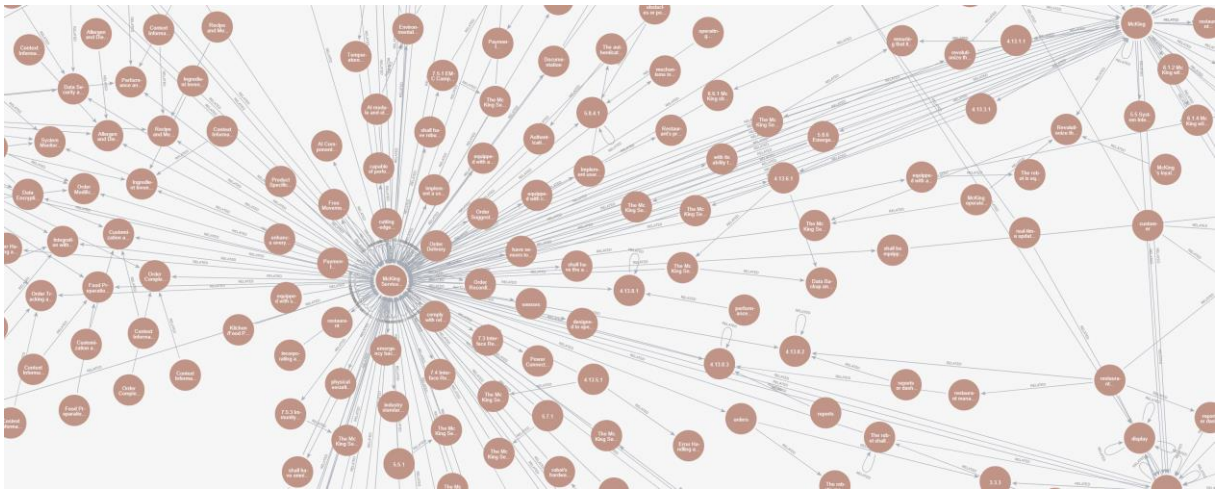

Abbildung 30: Visualisierung von Relationen

Visualisierung der Knowledge Graphen in Neo4j: Die generierten Knowledge Graphen wurden in der Neo4j-Datenbank visualisiert, was eine tiefere Analyse der Beziehungen zwischen den Anforderungen, Stakeholdern und anderen relevanten Entitäten ermöglichte.

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

Für diese Nutzer war im Vorhaben progressivKI vorgesehen:

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

- rigorose Bewertung des Lernfortschrittes und der Verlässlichkeit von Entwurfsvorschlägen durchzuführen;
- die implementierten User-Interfaces auf ein kontextabhängiges Arbeiten zu überprüfen.

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

Da jedoch das Meta-Modul aufgrund des umfassenden Forschungsbedarfs während der Projektlaufzeit nicht das TRL der übrigen Plattformmodule erreichen wurde (TRL 5 statt 6), sollte es vorerst nur als Option bereitgestellt werden und seine Funktionalität im Rahmen der Verwertung zunächst auch als Beratungsservice angeboten werden. Den finalen Schritt in diesem AP stellte die Dokumentation der gefundenen Entwurfsentscheidungen hinsichtlich der für die UseCases erzielten Ergebnisse (z.B. Bauelementauswahl oder Layoutvorschläge; …) dar. Die Erstellung dieser Dokumente erfolgte parallel zum Test der Plattformausprägungen #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 Plattformausprägungen 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 Plattformausprägungen insbesondere auch von Nutzern kleiner und mittlerer Unternehmen zur Lösung ihrer Entwurfsprobleme verwendet werden können. Gleichzeitig muss geprüft werden, ob die gewählten KI-Ansätze ausreichend modular sind, um sich auch an die Prozesse von Großkunden anpassen zu lassen.
- Umfassende Dokumentation der gefundenen Entwurfsentscheidungen hinsichtlich der für die UseCases erzielten Ergebnisse.

Geplante Ergebnisse von AP4 waren:

- 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) beruhten 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 Problemkreis |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 4.1.9: Demonstration der KI-basierten Generierung von Lastenheftderivaten (09-HOOD)

Ziele

Dieser Teilbeitrag zielt auf die Verbesserung des gesamten Prozesses der Lastenhefterstellung und -analyse im Requirements Engineering ab, um so die Effizienz und Genauigkeit zu erhöhen:

1. **Verbesserung der Lastenheftqualität:** Entwicklung und Demonstration von KI-Methoden zur Unterstützung bei der Erstellung und dem besseren Verständnis von Lastenheften.

2. **Extraktion von Design-Constraints:** Automatische Identifikation und Extraktion entwurfsrelevanter Spezifikationen und Design-Constraints aus Lastenheften und Expertenwissen.

3. **Unterstützung durch KI:** Einsatz von KI zur Generierung von Lastenheftderivaten, die den Entwickler im Verständnis des ursprünglichen Lastenhefts unterstützen.

Problemstellung

Die Problemstellung für diesen Teilbeitrag ergibt sich aus der Komplexität und den Herausforderungen, die bei der Erstellung und dem Verständnis von Lastenheften im Requirements Engineering auftreten. Insbesondere sind Lastenhefte oft schwer verständlich und enthalten eine Fülle von Informationen, die manuell nur mühsam ausgewertet werden können. Dies erschwert die Identifikation und Extraktion von kritischen Design-Constraints und spezifikationsrelevanten Inhalten, was zu Fehlern oder Missverständnissen im Entwicklungsprozess führen kann. Zudem ist die Unterstützung des Entwicklers durch bestehende Werkzeuge oft unzureichend, was den Bedarf an intelligenten, KI-basierten Lösungen zur Verbesserung der Effizienz und Genauigkeit bei der Lastenhefterstellung und -analyse verdeutlicht.

Lösungsweg und Ergebnisse

1. Entwicklung und Konzeption des KI4RE Toolkits

Der erste Ansatz soll die Entwicklung eines **KI4RE Toolkits sein**, einer Softwareplattform speziell für das Requirements Engineering. Dieses Toolkit soll verschiedene Methoden des Natural Language Processing (NLP) integrieren, um die Verarbeitung und Analyse von Lastenheften zu automatisieren und zu unterstützen. Das primäre Ziel des Toolkits ist es, die Effizienz bei der Erstellung von Lastenheften zu steigern und den Wissenstransfer von NLP-Technologien in den Bereich des Requirements Engineerings zu fördern.

Kernkomponenten des KI4RE Toolkits:

- **PDF-Einlesen und Textverarbeitung**: Das Toolkit soll das Einlesen von PDF-Dokumenten und die anschließende Verarbeitung des Textes ermöglichen, da diese Funktionalität die Grundlage für die weiteren NLP-Analysen ist.
- **Subjektextraktion**: Eines der wichtigsten Features des Toolkits soll die Fähigkeit sein, automatisch Subjekte aus Lastenheften zu extrahieren, was für die nachfolgenden Analysen und Glossarerstellungen unerlässlich ist.
- **Glossarerstellung**: Das Toolkit soll ein Glossar generieren können, das wichtige Begriffe aus dem Lastenheft extrahiert und deren Definitionen mithilfe von WordNet abgleicht. Dies erleichtert das Verständnis und die Nachvollziehbarkeit der Inhalte.

Ein zentraler Bestandteil des KI4RE Toolkits ist die Konzeption eines **Minimum Viable Product (MVP)** für das Glossar, welches die ersten funktionalen Anforderungen der Anwendung erfüllt. Die Entwicklung des MVPs konzentriert sich auf die Schaffung einer einfachen, aber effektiven Lösung zur Begriffsdefinition und Textanalyse in Lastenheften.

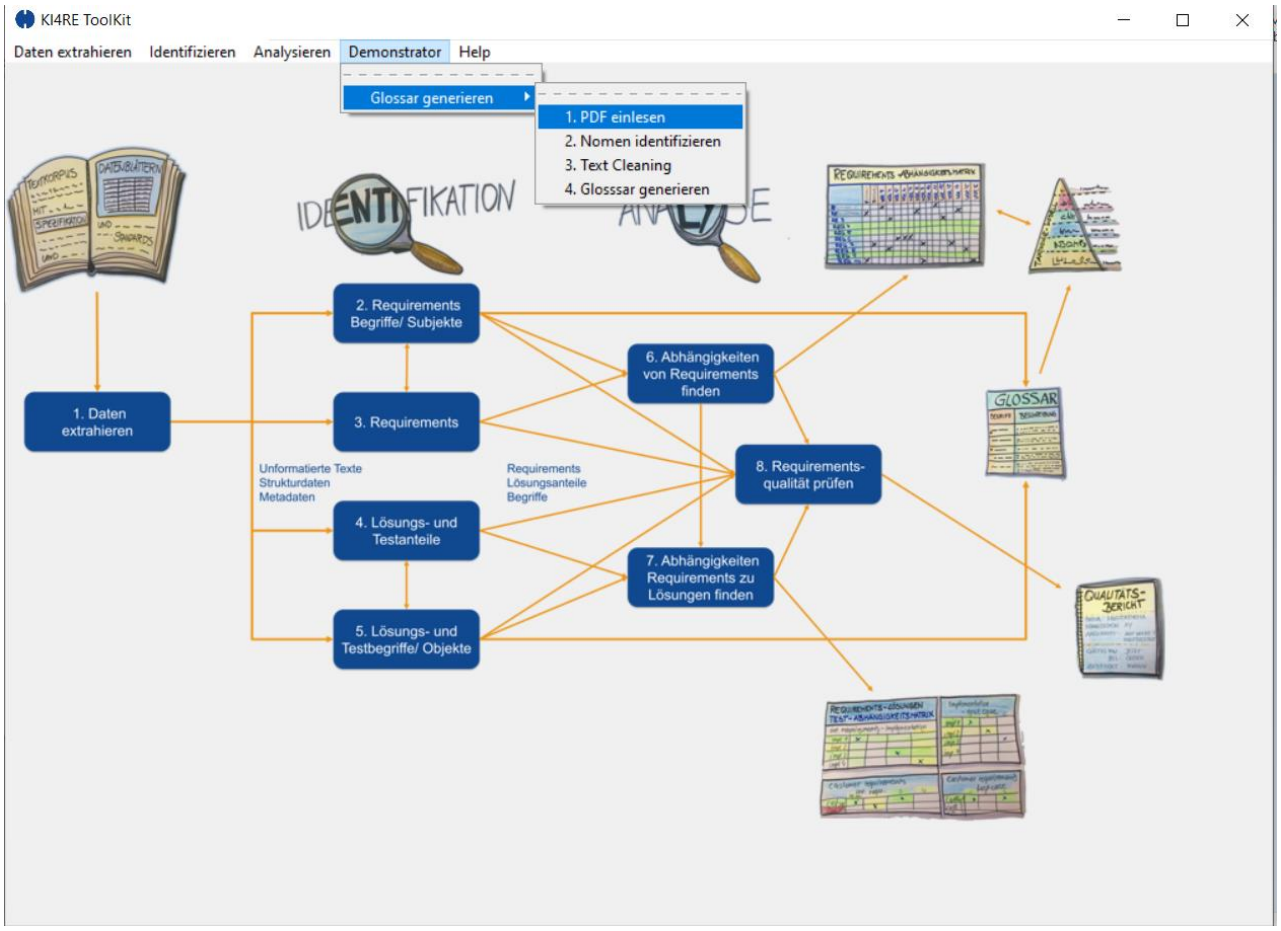

Abbildung 31: KI4RE Toolkit, Workflow Glossar generieren

2. Integration und Anwendung von NLP-Frameworks

Für die Durchführung der NLP-Analysen sollen im KI4RE Toolkit verschiedene NLP-Frameworks integriert werden, darunter **spaCy** und **NLTK**. Diese Frameworks ermöglichen es, linguistische Analysen durchzuführen und Begriffe aus Lastenheften präzise zu extrahieren. Ein besonderes Augenmerk soll auf der Einschränkung der gefundenen Glossarbegriffe auf die Domäne „Engineering“ liegen. Dies ist notwendig, da Begriffe in unterschiedlichen Domänen variieren und unterschiedliche Bedeutungen haben können. **WordNet** soll dabei als eine Quelle für Begriffsdefinitionen verwendet, während spaCy für die eigentliche Textverarbeitung genutzt werden soll.

Schlüsselfunktionen:

- **Wortartenanalyse**: Mithilfe von spaCy soll eine umfassende Analyse der Wortarten durchgeführt werden, um relevante Begriffe und Konzepte in den Lastenheften zu identifizieren.
- **Domänenspezifische Begriffsanalyse**: Durch die Kombination von spaCy und WordNet soll das Toolkit sicherstellen, dass nur solche Begriffe in das Glossar aufgenommen wurden, die im Kontext des Engineerings relevant sind.

3. Verbesserung der Benutzerfreundlichkeit und des Wissenstransfers

Ein wesentlicher Aspekt des KI4RE Toolkits ist die Verbesserung der Benutzerfreundlichkeit. Dies soll durch die Implementierung eines benutzerfreundlichen Menüs und durch die Möglichkeit zur

schrittweisen Durchführung der Glossarerstellung erreicht werden. Benutzer können im Menü den Punkt „**Glossar generieren**“ auswählen, woraufhin die einzelnen notwendigen Schritte nummeriert und untereinander angezeigt werden. Diese Funktionalität soll nicht nur die **Usability** verbessern, sondern auch das Verständnis der Benutzer für die einzelnen Schritte innerhalb der NLP-Pipeline fördern.

4. Implementierung umfangreicher Textbereinigungsoptionen

Ein weiteres zentrales Feature des KI4RE Toolkits ist das **Text Cleaning**. Diese Funktion erlaubt es den Benutzern, umfangreiche Textbereinigungsoptionen zu konfigurieren, welche für die nachfolgenden NLP-Analysen von entscheidender Bedeutung sind. Die Optionen umfassen unter anderem:

- **Kleinschreibung (Lowercasing)**: Standardisierung der Groß- und Kleinschreibung, um die Konsistenz in der Textanalyse zu gewährleisten.
- **Lemmatization und POS-Tagging**: Reduzierung der Wörter auf ihre Grundform und Zuordnung von Wortarten, um die syntaktische Struktur des Textes zu analysieren.
- **Entfernung von Punktuation und Duplikaten**: Bereinigung des Textes von unnötigen Zeichen und wiederholten Inhalten, um die Analyse zu erleichtern.
- **Ersatz von Zahlen durch Platzhalter**: Behandlung von numerischen Werten, die in der Regel keine semantische Bedeutung im Analysekontext tragen.

Die Möglichkeit, diese Bereinigungsschritte in einer JSON-Datei zu speichern und wieder zu laden, erleichtert die Zusammenarbeit zwischen verschiedenen Benutzern und ermöglicht den Vergleich unterschiedlicher Textreinigungsstrategien.

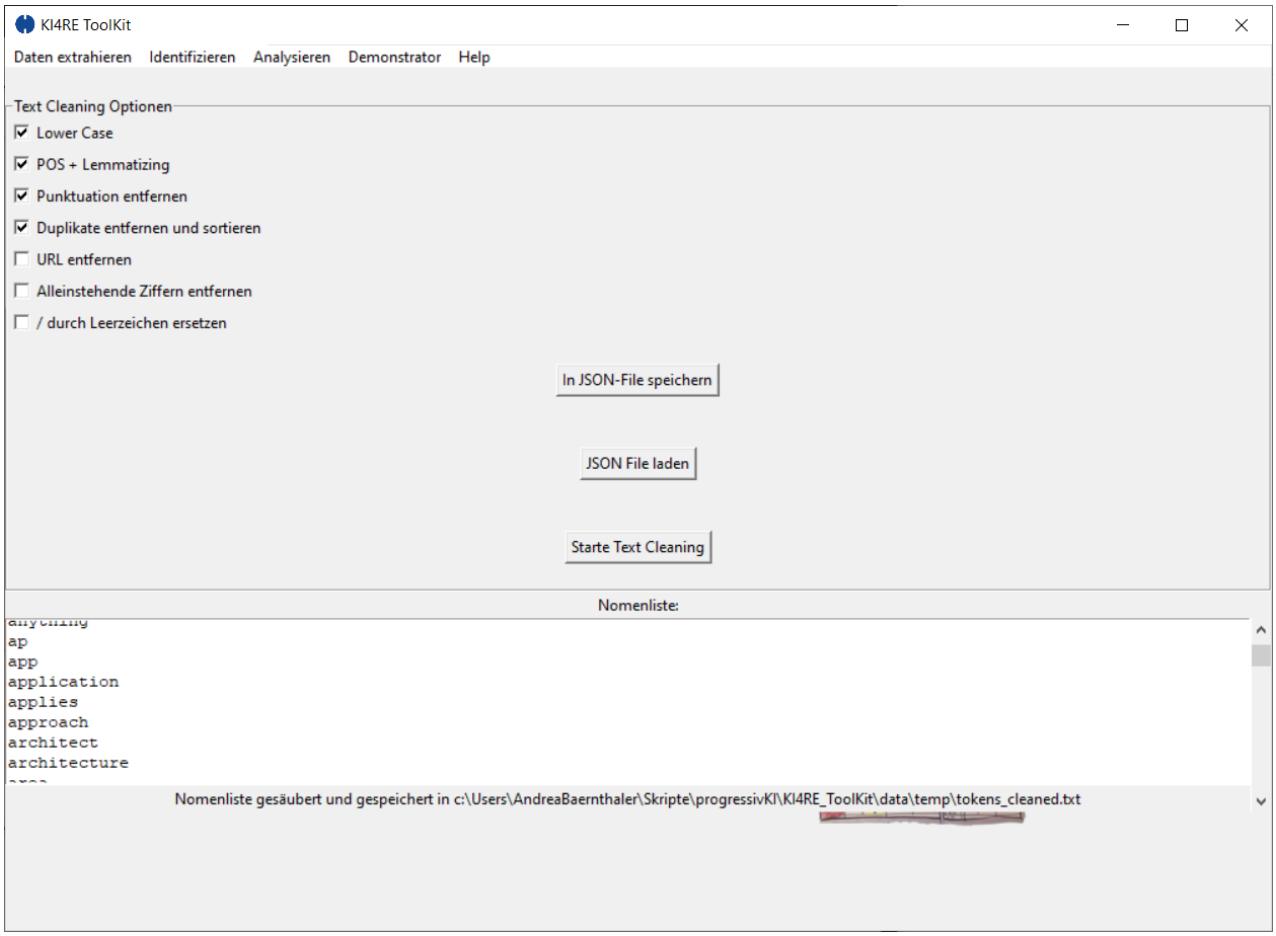

Abbildung 32: KI4RE-Toolkit: GUI Text Cleaning

5. Visuelle Darstellung der PDF-Verarbeitung und ROI-Erkennung

Um den Verarbeitungsprozess transparenter zu machen, soll eine Funktion zur **Anzeige der verarbeiteten Seiten** von PDF-Dokumenten implementiert werden. Diese Funktion zeigt den Benutzern, welche Bereiche des PDFs als „**Regions of Interest (ROIs)**“ erkannt werden, die für die Textextraktion relevant sind. Diese ROIs sind mit grünen Rechtecken markiert und ermöglichen eine einfache Überprüfung, ob alle wichtigen Textbereiche erfasst werden, einschließlich kritischer Bereiche wie Fuß- und Kopfzeilen.

Diese visuelle Darstellung ist besonders wichtig, um sicherzustellen, dass keine relevanten Informationen bei der Textextraktion verloren gehen und dass die Benutzer nachvollziehen können, wie der Text verarbeitet wurde.

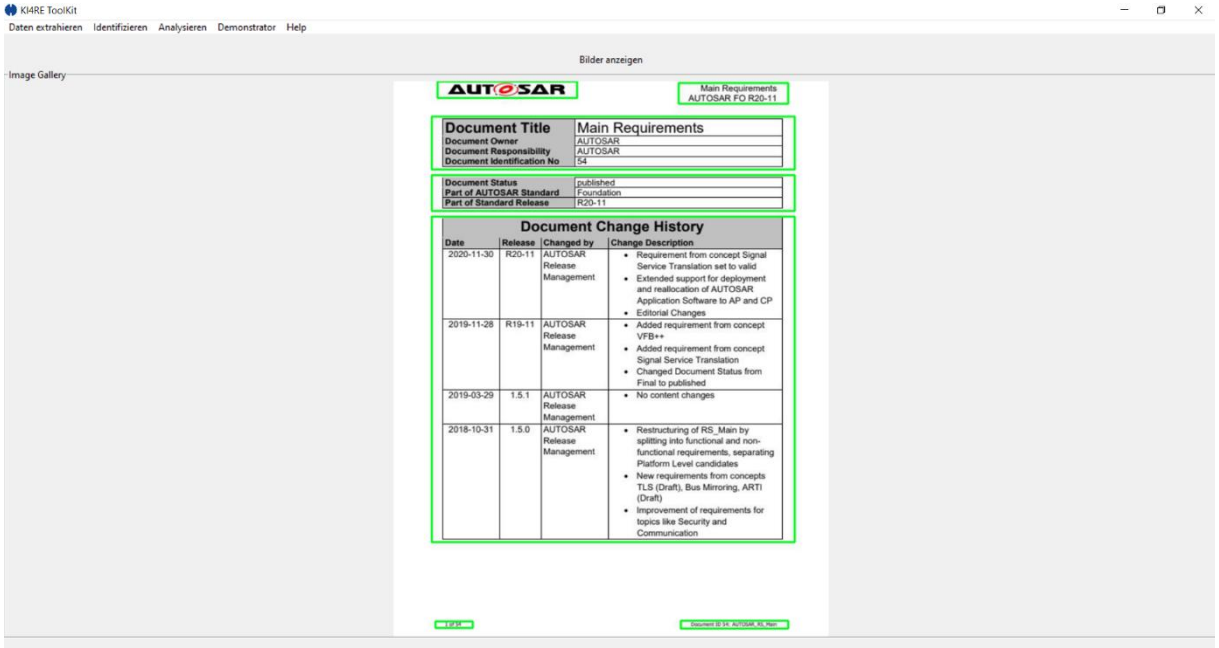

Abbildung 33: KI4RE-Toolkit: Anzeige der verarbeiteten Seiten des PDF-Dokuments. In grün sind die ROIs markiert.

6. Automatisierte Qualitätsprüfung von Anforderungen

Ein weiteres zentrales Ergebnis des Projekts sollte die Entwicklung und Implementierung eines Ansatzes zur **automatisierten Qualitätsprüfung von Anforderungen** sein. Diese Qualitätsprüfung soll auf Basis von NLP und generativer KI erfolgen, wobei zwei Hauptansätze untersucht werden sollten:

- **Nutzung generativer KI im Internet**: Zum Beispiel durch die Verwendung von ChatGPT, das qualitativ hochwertige Ergebnisse lieferte, jedoch Bedenken hinsichtlich der Datensicherheit aufwarf.
- **Nutzung lokaler KI**: Diese Lösung wurde bevorzugt, um Datensicherheitsanforderungen zu erfüllen, auch wenn sie qualitativ nicht ganz an die Ergebnisse der generativen KI heranreichte.

Das entwickelte Verfahren nutzt ein dreistufiges Modell zur Qualitätsprüfung:

1. **Algorithmische Prüfung**: Basierend auf vordefinierten Qualitätsregeln, die direkt implementiert werden.
2. **NLP-Framework-basierte Prüfung**: Verwendung von Frameworks wie spaCy oder NLTK, um die Qualitätsregeln zu prüfen.
3. **Prüfung durch generative KI**: Einsatz lokaler generativer KI, beispielsweise via Inferenz-Server mit LM-Studio, um die verbleibenden Qualitätsaspekte zu evaluieren.

Die Ergebnisse der Qualitätsprüfung werden in einem **Pandas Dataframe** dokumentiert und können anschließend in eine Excel-Datei exportiert werden, die den Requirements Engineer bei der finalen Bewertung der Anforderungsqualität unterstützt.

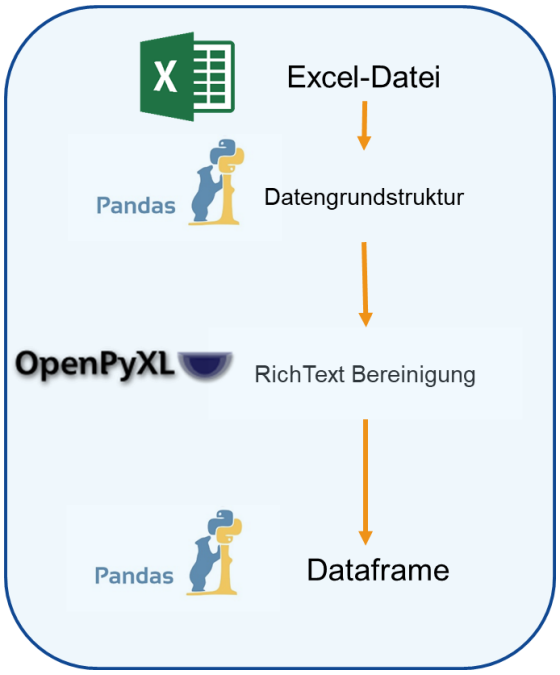

Abbildung 34: Einlesen und Bereinigen von Anforderungen aus einer Excel-Datei

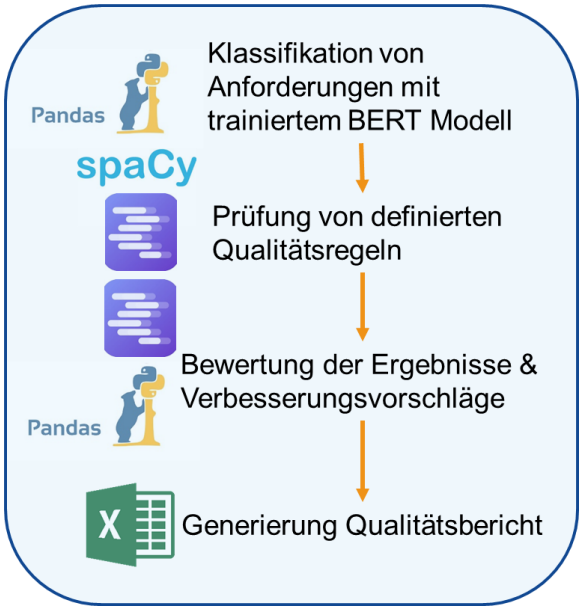

Abbildung 35: Automatisierte Qualitätsprüfung

7. Evaluierung großer Sprachmodelle

Im Rahmen des Projekts wurden auch **Experimente mit großen Sprachmodellen** wie dem Falcon-78B-Instruct-Modell durchgeführt. Ziel dieser Experimente war es, die Leistungsfähigkeit dieser Modelle in der Qualitätsprüfung von Anforderungen zu evaluieren. Die Implementierung solcher Modelle auf der FIT progressivKI Plattform wurde untersucht, um herauszufinden, ob sie die Inferenzleistung in spezifischen Anwendungsszenarien verbessern könnten. Die Ergebnisse waren jedoch nicht vollständig zufriedenstellend, was auf die noch bestehenden Herausforderungen bei der Nutzung großer Sprachmodelle in bestimmten Kontexten hinweist. Trotzdem zeigen die kontinuierlichen Fortschritte in der Entwicklung dieser Modelle, dass zukünftige Implementierungen bessere Ergebnisse liefern könnten.

Zusammenfassung der Ergebnisse

Der entwickelte Lösungsweg hat gezeigt, dass durch den Einsatz von KI und NLP im Requirements Engineering erhebliche Verbesserungen erzielt werden können. Die Integration von NLP-Frameworks wie spaCy und NLTK, kombiniert mit generativen KI-Ansätzen, ermöglicht es, komplexe Dokumente wie Lastenhefte effizienter zu verarbeiten und die Qualität der erstellten Anforderungen zu verbessern.

Das KI4RE Toolkit bietet eine Plattform für die Verarbeitung und Analyse von Lastenheften. Es integriert eine Reihe von Tools, die die Benutzerfreundlichkeit erhöhen und den Wissenstransfer erleichtern. Durch die umfassende Textbereinigung, visuelle Darstellung von Verarbeitungsprozessen und die automatisierte Qualitätsprüfung konnten wesentliche Herausforderungen bei der Lastenhefterstellung und -analyse bewältigt werden.

3.5 Arbeitspaket 5: Projektmanagement & Dissemination

Um den zentralen Ansatz der Entwicklung einer modular strukturierten KI-Plattform optimal bearbeiten zu können, war es notwendig, ein möglichst breit aufgestelltes Projektteam in die geplanten F+E-Arbeiten einzubinden. Aufgrund der sich daraus ergebenden Heterogenität des Projektkonsortiums stellte dieses AP ein Schlüsselelement 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 Projektresultate gegenüber der KI- und MikroelektronikCommunity durch Publikationen beigesteuert.

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

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

Geplante Ergebnisse von AP5 waren:

- Im Rahmen des Arbeitspakets 5 waren mehrere Schlüsselergebnisse geplant, um eine effiziente und strukturierte Projektabwicklung zu gewährleisten. Zunächst wurde ein Projekthandbuch (PHB) erstellt, das als umfassende Richtlinie und Informationsquelle für alle Beteiligten diente.
- Des Weiteren wurde das progressivKI-ProjektOffice in einen arbeitsfähigen Zustand versetzt, um die reibungslose Koordination und Verwaltung sämtlicher Projektaktivitäten sicherzustellen.
- Ein dreistufiger Ansatz zur Umsetzung der progressivKI F+E-Ergebnisverbreitung und Nutzungsplanung wurde installiert, um sicherzustellen, dass die erzielten Forschungs- und Entwicklungsresultate 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 dien 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 Simulations-verfahren im Vorhaben vorgesehen.

Teilbeitrag 5.2.9: Präsentation F+E-Ergebnisse + F+E-Nutzungsplanung (09-HOOD)

Ziele

Ziel ist die Kommunikations- und Verbreitung der Projektergebnisse des Teilvorhabens KI4RE. Dies umfasst die Präsentation der Ergebnisse in geeigneten Formaten sowie die kontinuierliche Veröffentlichung von Blogartikeln, um die Forschungsergebnisse einem breiten Publikum zugänglich zu machen und den Wissenstransfer in die Praxis zu fördern.

Blogartikel:

Zur Laufzeit des Projektes wurden die folgenden Blogartikel unter https://blog.hood-group.com/ veröffentlicht:

- 10.09.2024, Markus Eberhardt: „Abschluss des Forschungsprojekts “progressivKI” – Einblick in die Zukunft des RE mit KI“
- 30.01.2024, Markus Eberhardt: „KI@HOOD-Requirements Analyst: Jetzt kann auch DOORS Requirements mit Hilfe von KI reviewen“
- 20.12.2023, Hichem Bouricha: „Ein Weg zur automatischen Erstellung einer Glossar-Definition“
- 15.10.2023, Andrea Bärnthaler: „Wie das Problem umgehen, dass ChatGPT nur den Stand von 2021 wiedergibt?“
- 21.09.2023, Hichem Bouricha: „Die Macht und die Herausforderungen großer Sprachmodelle: Wie Expertenwissen den Unterschied macht“
- 30.05.2023, Hichem Bouricha: „Die aufwändige Suche nach bestimmten Informationen in PDF-Dokumenten“
- 12.04.2023, Hichem Bouricha: „Wie könnte man mit dem Problem der mangelnden Daten umgehen?“
- 25.01.2023, Hichem Bouricha: „Besseres Requirements Engineering durch NLP?“
- 11.10.2022, Michael Jastram: „Auf Knopfdruck bessere Anforderungen schreiben — geht das?“
- 08.12.2021, Michael Jastram: „Was ist MLOps? Und brauchen wir es?“
- 19.09.2021, Michael Jastram: „KI: Zwischen heißer Luft und echtem Nutzen“
- 27.05.2021, Michael Jastram: „Die 11 Fallen im Machine Learning“
- 18.05.2021, Nadine Knur: „Künstliche Intelligenz für Elektroniksysteme – HOOD im Forschungsteam progressivKI“

Veröffentlichungen:

Neben den Blogartikeln gab es außerdem die folgenden Veröffentlichungen in Zeitschriften und projektinterne und externe Workshops und Vorträge:

- 02/2023, Fachartikel „RE für KI-Systeme: Neue Herausforderungen für das RE“, IT Spektrum 02/2023
- 26.04.2022; Vortrag; Jan Ebert: „Requirements- und Systems-Engineering für künstlich intelligente Systeme“, REConf 2022 in München
- 17.11.2022; Vortrag; Markus Eberhardt; „KI4RE – Wie künstliche Intelligenz das Requirements Engineering unterstützen kann“ TdSE 2022 in Paderborn
- 24.04.2023; Workshop; Markus Eberhardt und Hichem Bouricha: „NLP4RE: Natural Language Processing (NLP) for Requirements Engineering – wie Künstliche Intelligenz im RE unterstützen kann“; REConf 2023 in München
- 26. 04.2023, Vortrag, Markus Eberhardt und Jan Ebert, „NLP4RE – Wie künstliche Intelligenz das Requirements Engineering unterstützen kann“, REConf 2023 in München
- 15.11.2023; Tutorial; Markus Eberhardt, Hichem Bouricha und Daniel Hansch: „NLP4SE – Was bringt Natural Language Processing für das Systems Engineering“, TdSE 2023 in Würzburg
- 22.04.2024; Workshop; Markus Eberhardt und Hichem Bouricha: „KI4SE: Mit künstlicher Intelligenz das Systems Engineering revolutionieren“; REConf 2024 in München

Abschlusspräsentation:

- 28.08.2024; Abschlusspräsentation und Demonstration; Markus Eberhardt und Andrea Bärnthaler: „KI-Unterstützung für Requirements Engineering (RE)“; Abschlussseminar progressivKI in Hildesheim

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 beinhielten die systematische Zusammenstellung und Strukturierung sämtlicher relevanten Informationen, um eine übersichtliche und leicht zugängliche Dokumentation zu gewährleisten.

4 Verwertung und voraussichtlicher Nutzen

Ausgangslage

09-HOOD ist als mittelständisches Beratungsunternehmen für Anforderungsmanagement und agile Entwicklung in unterschiedlichen Domänen wie z.B. Automotive, Medizintechnik, Luft- und Raumfahrt, Versicherungen und Banken aktiv. Künstliche Intelligenz spielte in dem Zeitraum vor 2020 lediglich in Form von Expertensystemen eine Rolle und wurde von 09-HOOD nicht aktiv vorangetrieben. Im Projektzeitraum 2020-2024 fanden einige KI Innovationen im Kontext des Requirements Engineerings statt, z.B.:

2020-2021: Erste Schritte zur Automatisierung durch KI, insbesondere in der Anforderungsanalyse und -validierung mittels Natural Language Processing (NLP) und Maschinellem Lernen (ML).

2022: Vermehrte Nutzung KI-gestützter Tools zur Effizienzsteigerung und Qualitätsverbesserung im Anforderungsmanagement.

2023: KI hilft bei der Extraktion und Analyse von Anforderungen aus unstrukturierten Datenquellen.

2024: KI wird zunehmend in alle Phasen des RE integriert, von der Erhebung bis zur Validierung, um die Komplexität moderner Softwareprojekte zu bewältigen.

Ergebnisse in progressivKI

09-HOOD verfolgte in progressivKI das Ziel, die Effizienz und Effektivität des Requirements Engineerings (RE) durch den Einsatz von Künstlicher Intelligenz (KI) zu steigern. Die wesentlichen Forschungsergebnisse lassen sich wie folgt zusammenfassen:

1. Entwicklung und Spezifikation einer modular strukturierten KI-Plattform

- Arbeitspaket 1 fokussierte auf die Analyse des KI-Einflusses auf Entwicklungsprozesse innerhalb spezifischer Wertschöpfungsketten. Es wurden KI-Anforderungen der Partner ermittelt, Einsatzpotenziale identifiziert und Kriterien für die Akzeptanz von KI-basierten Entwurfsvorschlägen definiert.
- Arbeitspaket 3 umfasste die praktische Implementierung der modular strukturierten KI-Plattform.

2. Optimiertes Requirements Engineering für KI-basierte Entwicklung (Arbeitspaket 2)

- In Teilbeitrag 2.1.9 wurde eine optimierte RE-Methodik speziell für KI-Systeme entwickelt. Diese berücksichtigt die speziellen Anforderungen und Randbedingungen von KI-Anwendungen, einschließlich neuer Qualitätskriterien wie Datenqualität und Nachvollziehbarkeit von KI-Entscheidungen.
- Ein wissenschaftlicher Artikel „RE für KI-Systeme: KI & maschinelles Lernen - Neue Herausforderungen für das RE“ wurde veröffentlicht, der die erarbeiteten Methoden und Erkenntnisse detailliert darstellt.

3. KI-Datenaufbereitung und Datengenerierung (Arbeitspaket 2)

- Teilbeitrag 2.2.9 beschäftigte sich mit Strategien für angepasstes KI-Training. Trotz Herausforderungen bei der Beschaffung und Annotation von Trainingsdaten wurden alternative Ansätze wie die Nutzung von Expertenregeln und Transfer Learning entwickelt.
- Ein umfangreicher Datenkorpus zur Identifikation von physikalischen Einheiten wurde erstellt und zum Nachtrainieren von BERT-Sprachmodellen verwendet, was die Genauigkeit der Named Entity Recognition (NER) im RE-Kontext signifikant verbesserte.

4. Erstellung und Demonstration von Anwendungsebenen (Arbeitspaket 4)

- Teilbeitrag 4.1.9 demonstrierte die KI-basierte Generierung von Lastenheftderivaten. Ein KI4RE Toolkit wurde entwickelt, das NLP-Ansätze integriert und Entwicklern ermöglicht, Anforderungen automatisch zu extrahieren und zu klassifizieren.
- Die Implementierung eines Glossars als Minimum Viable Product (MVP) im KI4RE Toolkit zeigte die praktische Anwendbarkeit der entwickelten Methoden zur Verbesserung des Verständnisses von Lastenheften.

5. Kriterien für die Akzeptanz von KI-basierten Entwurfsvorschlägen (Arbeitspaket 1)

- In Teilbeitrag 1.3.9 wurden spezifische Akzeptanzkriterien für KI-Entscheidungen im RE definiert, die den Einfluss auf Entwicklerebene, die Nachvollziehbarkeit der Entscheidungen und die Qualität der extrahierten Design Constraints berücksichtigen.
- Ein Ansatz zur automatisierten Qualitätsprüfung von Anforderungen unter Anwendung der INCOSE-Regeln wurde entwickelt.

6. Ermittlung von Automatisierungspotentialen durch KI-Einsatz (Arbeitspaket 1)

- Die Analyse der Automatisierungspotentiale in der Elektronikentwicklung (Teilbeitrag 1.4.9) identifizierte insbesondere die Datenaufbereitung und Arbeitsvorbereitung als Bereiche mit hohem Automatisierungspotenzial durch KI.
- Der Leiterplattenhersteller HOTOPRINT bestätigte die Machbarkeit und den Nutzen von KI-gestützten Tools zur Verbesserung der Datenqualität und zur automatischen Erkennung von Layout-Schwachstellen.

7. Verfahren zur Erfassung von Domänenwissen (Arbeitspaket 3)

- Ein systematisches Verfahren zur Erfassung und Integration von Domänenwissen wurde in Teilbeitrag 3.4.9 entwickelt. Dies umfasst strukturierte Interviews mit RE-Experten und die Erstellung von Wissensgraphen zur besseren Darstellung und Nutzung des erfassten Wissens in KI-Systemen.
- Die Generierung von Knowledge Graphen basierend auf einer definierten Ontologie verbesserte die Strukturierung und Priorisierung von Anforderungen erheblich.

8. Dokumentationsanforderungen an KI-Systeme (Arbeitspaket 3)

- In Teilbeitrag 3.6.9 wurde ein Konzept zur Dokumentation und Nachvollziehbarkeit von KI-getriebenen Designentscheidungen im RE entwickelt. User Stories wurden als geeignetes Format identifiziert, um Anforderungen an KI-Systeme zu dokumentieren und die Akzeptanzkriterien zu definieren.
- Die Untersuchung von Halluzinationen in großen Sprachmodellen führte zur Evaluierung verschiedener Mitigationstechniken, die die Zuverlässigkeit und Faktizität der generierten Anforderungen sicherstellen sollen.

9. Projektmanagement und Dissemination (Arbeitspaket 5)

- Kontinuierliche Wissensverbreitung durch Trainings, Workshops und Veröffentlichungen trug zur Sensibilisierung und Schulung der Projektpartner und der breiteren Fachgemeinschaft bei. Zahlreiche Blogartikel, Fachvorträge und Workshops auf Konferenzen wie REConf und TdSE dokumentierten und verbreiteten die Forschungsergebnisse.

Nutzen und Verwertbarkeit

In diesem Forschungsvorhaben werden die Grundsteine von Requirements-Engineering für KI, für KI-unterstütztes Requirements-Engineering sowie die dafür notwendigen Zusammenarbeitsmodelle gelegt.

Dies bietet die Basis, um über neue Märkte, Bedürfnisse und dafür geeignete Produkte nachzudenken und zu forschen, sodass die deutschen Mittelstandsunternehmen auch die Technologieführerschaft außerhalb der Automobilindustrie übernehmen.

1. Die Projektergebnisse aus der Entwicklung der KI-Plattform werden in den Ausbau des eigenen Produkt- und Dienstleistungsportfolio im Bereich des Requirements Engineering überführt.

Kurzfristig plant 09-HOOD die Erkenntnisse aus diesem Forschungsvorhabens in sein Dienstleistungsportfolio zu integrieren und zu vermarkten:

- Analyse der unternehmensspezifischen Prozesse und Anwendungsfälle für KI bei seinen Kunden in und außerhalb der Automobilindustrie
- Unterstützung seiner Kunden bei der Auswahl der richtigen Art von KI (GenAI mit Large Language Model, Knowledge Graphen etc.) als Lösung

Mittelfristig sind vorgesehen:

- Ausweitung der oben genannten Dienstleistungen vom Bereich des Requirements Engineerings auf weitere Vorgehensweisen des Systems Engineerings, wie etwa Modellbildung und Qualitätssicherung.
- Direkte Unterstützung seiner Kunden beim Einsatz der ausgewählten KI (GenAI mit Large Language Model, Knowledge Graphen etc.)

2. Zudem werden die Erkenntnisse genutzt, um spezifische Requirements-Engineering-Praktiken zur Entwicklung von KI-basierten Systemen zu entwickeln.

Kurzfristig plant 09-HOOD die Erkenntnisse aus diesem Forschungsvorhaben im Bereich des Requirements Engineering für KI-Systeme in seinen Fundus an Requirements Engineering Praktiken aufzunehmen, seinen Kunden als Dienstleistung anzubieten und bei ihnen einzusetzen.

Mittelfristig ist vorgesehen, diese Requirements Engineering Praktiken für KI-Systeme in seine Schulungen und Workshops für Requirements Engineering einzubringen und so in die Ausbildung für Requirements Engineers zu integrieren und damit für eine Verbreitung dieses Wissens und der Fähigkeiten, sowohl in der Automobilindustrie wie auch in anderen Branchen zu sorgen.

3. Darüber hinaus werden die Ergebnisse des Projekts in Forschungs- und Entwicklungsarbeiten für andere Anwendungsgebiete neben der Automobilindustrie genutzt.

09-HOOD bringt die Erkenntnisse aus dem Forschungsvorhaben zeitnah in die Forschungsvorhaben KI4Boardnetz und KIMBA ein. Die weitere Verwertung in KMU-Innovativ Vorhaben zur Verbesserung der Stakeholder Kommunikation und zu kollaborativen Engineering Prozessen mit Augmented Reality ist geplant.

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“

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

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

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

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

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

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

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

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

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

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

(15) Z. Nezhi, N. Ghafarian, M. Stiemer, „Zur Platzierung von Entkopplungskondensatoren mittels Optimierungsalgorithmen und ANN-Bewertung der PDN-Impedanz“, Kleinheubacher Tagung 2022

(16) Bartels, Choy, Brüning, Stube, „KI basierte DeCaps Platzierung“, Kleinheubacher Tagung 2022

(17) Marcel Olbrich, Michael Kleinen, Dr.-Ing. Sebastian Jeschke, „KI-gestützte Entstörungsmethodik zur Verbesserung der elektromagnetischen Verträglichkeit von Fahrzeugelektroniksystemen“, Dortmunder Autotag 2022

(18) Sven Lange, Ivan Kaufmann, Dominik Schröder, Christian Hedayat, "Generierung von Trainingsdaten für die Entwicklung eines KI-basierten Verfahrens zur Analyse von EMV-Problematiken im Bereich Automotive", Dortmunder Autotag 2022

(19) Daniela Sánchez Lopera, Lorenzo Servadei, Gamze Naz Kiprit, Robert Wille, Wolfgang Ecker, „A Comprehensive Survey on Electronic Design Automation and Graph Neural Networks: Theory and Applications“, Journal-TODAES, Juni 2022

(20) Daniela Sánchez Lopera, Lorenzo Servadei, Sebastian Prebeck, Wolfgang Ecker, „Early RTL Delay Prediction Using Neural Networks“, Journal-MICPRO, Oktober 2022

(21) Christian Lück, Daniela Sánchez Lopera, Sven Wenzek, and Wolfgang Ecker, „Industrial Experience with Open-Source EDA Tools“, MLCAD22, September 2022

(22) Daniela Sánchez Lopera and Wolfgang Ecker, „Applying GNNs to Timing Estimation at RTL“, ICCAD22, November 2022

(23) Daniela Sánchez Lopera, Prajwal Kashyap, Nicolas Gerlin, Sven Wenzek, Wolfgang Ecker, „Using Open-Source EDA Tools in an Industrial Design Flow“, DVCON22, Dezember 2022

2023

(24) Hichem Bouricha: „Besseres Requirements Engineering durch NLP?”, HOOD-Blogartikel, 25.01.2023, https://blog.hood-group.com/blog/2023/01/25/besseres-requirements-engineering-durch-nlp/

(25) Markus Eberhardt, Jan Ebert, Hichem Bouricha, Philip Stolz, Andreas Kress: „RE für KI-Systeme: KI & maschinelles Lernen: Neue Herausforderungen für das RE“, Fachartikel im IT-Spektrum 02/2023, 24.02.2023

(26) Dennis Hemker, Stefan Kreutter and Harald Mathis: „On Reducing Complexity in AI Pipelines: Modularisation to Retain Control“, ERCIM News 133, April 2023, Special theme: Data Infrastructures and Management

(27) C. Grob, F. Gehring and O. Bringmann, "Towards Sustainable Energy Communities: Local Optimization of Battery Usage in P2P Energy Trading," in 2023 IEEE International Conference on Omni-layer Intelligent Systems (COINS), Berlin, Germany, 2023 pp. 1-7. doi: 10.1109/COINS57856.2023.10189231

(28) J. Withöft, W. John, E. Ecik and J. Götze, "AI-Based SI-Compliant PCB Design Support for DDR Technology Enhanced by Transfer Learning," 2023 International Symposium on Electromagnetic Compatibility – EMC Europe, Krakow, Poland, 2023, pp. 1-6, doi: 10.1109/EMCEurope57790.2023.10274407.

(29) E. Ecik, W. John, J. Withöft, R. Brüning and J. Götze, "Signal Integrity Design of PCB Transmission Paths using a Decision Tree Approach," 2023 International Symposium on Electromagnetic Compatibility – EMC Europe, Krakow, Poland, 2023, pp. 1-6, doi: 10.1109/EMCEurope57790.2023.10274174.

(30) E. Ecik; J. Withöft; J. Götze (17-TUDO); W. John (PYRAMIDE2525); R. Brüning (04-ZUKEN) „Signal Integrity Design of PCB Transmission Paths using a Decision Tree Approach“, EMC Europe 2023

(31) J. Withöft; E. Ecik; J. Götze (17-TUDO); W.John (PYRAMIDE2525), „AI-Based SI-Compliant PCB Design Support for DDR Technology Enhanced by Transfer Learning“, EMC Europe 2023

(32) E. Ecik; J. Withöft; J. Götze (17-TUDO); W. John (PYRAMIDE2525); R.Brüning (04-ZUKEN) „Analyse von Entwurfsräumen für den SI-gerechten PCB-Entwurf mit Hilfe von Entscheidungsbäumen“ Kleinheubacher Tagung 2023 (VORTRAG)

(33) J. Withöft; E. Ecik; J. Götze (17-TUDO); W. John (PYRAMIDE2525); R. Brüning (04-ZUKEN), „Unterstützung des signalintegritätsgerechten Entwurfs von PCB-Leitungsstrukturen mithilfe von Reinforcement Learning“, Kleinheubacher Tagung 2023 (VORTRAG)

(34) N. G. Shoaee; J. Götze (17-TUDO); Z. Nehzi (18-HSU); W. John (PYRAMIDE2525); R.Brüning (04-ZUKEN), „KI-basierte Optimierung von Stromversorgungs-Strukturen auf Leiterplatten“, Kleinheubacher Tagung 2023 (VORTRAG)

(35) J. Withöft; E. Ecik; J. Götze (17-TUDO); W. John (PYRAMIDE2525); R. Brüning (04-ZUKEN), „AI Models for Supporting SI Analysis on PCB Net Structures: Comparing Linear and Non-Linear Data Sources“, Advances in Radio Science - Journal

(36) N. G. Shoaee; J.Götze (17-TUDO); W. John (PYRAMIDE2525) Z.Nehzi (18-HSU); R.Brüning (04-ZUKEN), „Generating AI Modules for Decoupling Capacitor Placement Using Simulation“, Advances in Radio Science - Journal

(37) E. Ecik; J.Withoeft; J. Götze (17-TUDO); W. John (PYRAMI-DE2525) „Anomaly Detection with Decision Trees for AI Assisted Evaluation of Signal Integrity Effects on PCB Transmission Lines“, Advances in Radio Science - Journal

(38) J. Withöft; E. Ecik; J. Götze (17-TUDO); W. John (PYRAMI-DE2525); R. Brüning (04-ZUKEN), „Optimization of a Daisy Chain PCB Memory System through Reinforcement Learning under Consideration of Signal Integrity Constraints“, Kleinheubacher Tagung 2023 (IEEE Xplore)

(39) N. G. Shoaee; B. Hua; J.Götze (17-TUDO); W.John (PYRA-MIDE2525) Z.Nehzi (18-HSU); R.Brüning (04-ZUKEN), „AI-based Optimization of Power Delivery Networks on Printed Circuit Boards“, Kleinheubacher Tagung 2023 (IEEE Xplore)

(40) I. Cahani and M. Stiemer, „Autoencoders in the Machine Learning Supported Design of PCBs“, 2023 Kleinheubach Conference. IEEE, 2023.

(41) Z. Nezhi, M. Stiemer, M. Schierholz and Ch. Schuster, „Dimensional Reduction by Auto-Encoders in Machine Learning Based Power Integrity Analysis“ in 28th IEEE Workshop on Signal and Power Integrity, 2024 (accepted).

(42) M. Schierholz, Z. Nezhi, M. Stiemer and Ch. Schuster, „PCB based Power Deliver Network Analysis Using Transfer Learning and Artificial Neural Networks“, in Proc. 28th IEEE Workshop on Signal and Power Integrity 2024 (submitted).

(43) M. Stiemer, R. Ueltzen, I. Cahani, Z. Nezhi, M. Hagel, H. Mathis, D. Hemker and J. Maalouly, „Automated model selection in an AI platform to support PCB design“, oral presentation at 2023 Kleinheubacher Tagung, 2023.

(44) Z. Nezhi, N. Ghafarian Shoaee and M. Stiemer, „Multi-Agent Reinforcement Learning for Decoupling Capacitor Placement Optimization in Power Distribution Networks“, oral presentation at 2023 Kleinheubacher Tagung, 2023.

(45) N. Ghafarian Shoaee, Z. Nezhi, W. John, R. Brüning and J. Götze, „KI-basierte Optimierung von Stromversorgungs-Strukturen auf Leiterplatten“, oral presentation at 2023 Kleinheubacher Tagung, 2023.

(46) Sanchez Lopera, Daniela, Ishwor Subedi and Wolfgang Ecker, „Using Graph Neural Networks for Timing Estimations of RTL Intermediate Representations“, MLCAD 09.2023

(47) E. S. Alcorta et al., „Special Session: Machine Learning for Embedded System Design“, CODES+ISSS

(48) Dennis Hemker, Stefan Kreutter and Harald Mathis: „On Reducing Complexity in AI Pipelines: Modularisation to Retain Control“, ERCIM News 133, April 2023, Special theme: Data Infra-structures and Management

(49) C. Grob, F. Gehring and O. Bringmann, "Towards Sustainable Energy Communities: Local Optimization of Battery Usage in P2P Energy Trading," in 2023 IEEE International Conference on Omni-layer Intelligent Systems (COINS), Berlin, Germany, 2023 pp. 1-7. doi: 10.1109/COINS57856.2023.10189231

(50) J. Withöft, W. John, E. Ecik and J. Götze, "AI-Based SI-Compliant PCB Design Support for DDR Technology Enhanced by Transfer Learning," 2023 International Symposium on Electro-magnetic Compatibility – EMC Europe, Krakow, Poland, 2023, pp. 1-6, doi: 10.1109/EM-CEurope57790.2023.10274407.

(51) E. Ecik, W. John, J. Withöft, R. Brüning and J. Götze, "Signal Integrity Design of PCB Transmission Paths using a Decision Tree Approach," 2023 International Symposium on Electro-magnetic Compatibility – EMC Europe, Krakow, Poland, 2023, pp. 1-6, doi: 10.1109/EM-CEurope57790.2023.10274174.

(52) D. Hemker, J.Maalouly , H. Mathis, R. Klos, E. Ravanan: "From Schematics to Netlists - Electrical Circuit Analysis Using Deep Learning Methods", Kleinheubacher Tagung 2023

(53) Jad Maalouly, Dennis Hemker, Christian Hedayat, Marcel Olbrich, Sven Lange, and Harald Mathis: “Using Autoencoders to Classify EMC Problems in Electronic System Development”, Kleinheubacher Tagung 2023 (Vortrag)

(54) Dennis Hemker, Stefan Kreutter and Harald Mathis: „On Reducing Complexity in AI Pipelines: Modularisation to Retain Control“, ERCIM News 133, April 2023, Special theme: Data Infrastructures and Management

(55) C. Grob, F. Gehring and O. Bringmann, "Towards Sustainable Energy Communities: Local Optimization of Battery Usage in P2P Energy Trading," in 2023 IEEE International Conference on Omni-layer Intelligent Systems (COINS), Berlin, Germany, 2023 pp. 1-7. doi: 10.1109/COINS57856.2023.10189231

(56) J. Withöft, W. John, E. Ecik and J. Götze, "AI-Based SI-Compliant PCB Design Support for DDR Technology Enhanced by Transfer Learning," 2023 International Symposium on Electromagnetic Compatibility – EMC Europe, Krakow, Poland, 2023, pp. 1-6, doi: 10.1109/EMCEurope57790.2023.10274407.

(57) E. Ecik, W. John, J. Withöft, R. Brüning and J. Götze, "Signal Integrity Design of PCB Transmission Paths using a Decision Tree Approach," 2023 International Symposium on Electromagnetic Compatibility – EMC Europe, Krakow, Poland, 2023, pp. 1-6, doi: 10.1109/EMCEurope57790.2023.10274174.

(58) Öffentlichkeitsarbeit über eigene Website; Jürgen Kutter, Michael Kemkes: https://www.innozent-owl.de/foerderprojekte-erkunden/progressivki/

(59) OWL GmbH Solutions Veranstaltungsreihe: https://www.ostwestfalenlippe.de/owl-gmbh/innovation-und-wissen/solutions/morgenist-jetzt-transformation-leben-39-solutions-veranstaltungen-bieten-impulseloesungen-und-kontakte/

(60) Marcel Olbrich, Michael Kleinen, Dr.-Ing. Sebastian Jeschke, “AI assisted interference suppression – Provision of EMC domain knowledge for AI training and test processes”, Posterbeitrag, progressivKI Projekttreffen, Karlsruhe, 04/2023

2024

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

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

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

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

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

(66) 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.
(67) 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.

6 Quellen

[AbelRein] A. Abel and J. Reineke, "Measurement-based modeling of the cache replacement policy," 2013 IEEE 19th Real-Time and Embedded Technology and Applications Symposium (RTAS), Philadelphia, PA, 2013, pp. 65-74, doi: 10.1109/RTAS.2013.6531080.

[Agerri] Agerri R. und German Rigau (2016) Robust multilingual named entity recognition with shallow semisupervised features. Artificial Intelligence, 238:63–82.

[AhaNovVi] A. Ahari, J. Novacek, A. Viehl, O. Bringmann and W. Rosenstiel, "CTEF: Collaborative Technology Evaluation Framework," 2018 IEEE International Systems Engineering Symposium (ISSE), Rome, 2018

[AI Software] The Best 7 Free and Open-Source Artificial Intelligence Software; https://www.goodfirms.co/blog/best-free-open-source-Artificial-Intelligence-software

[AlsAdHi] Alsioufy, Adnan; Hirler, Alexander; Lehndorff, Thomas; Sulima, Torsten; Lochner, Helmut; Simon, Stefan; Siddabathula, Mahesh; Wiatr, Maciej; Hansch, Walter, Technology Black Box : A Pioneering Tool for Semiconductor Technology Development in the Automotive Industry, 2020

[AMELI] BMBF-Förderprojekt „Mikro-elektromechanisches Elektroniksystem zur Zustandsüberwachung in der Industrie 4.0“, https://www.elektronikforschung.de/projekte/ameli-4.0

[Andecy] d'Andecy, V. P., Hartmann, E., & Rusinol, M. (2018, April). Field extraction by hybrid incremental and a-priori structural templates. In 2018 13th IAPR International Workshop on Document Analysis Systems (DAS) (pp. 251-256). IEEE.

[BainSammut] Michael Bain and Claude Sammut. 1999. A Framework for Behavioural Cloning. In Machine Intelligence 15, Intelligent Agents [St. Catherine’s College, Oxford, July 1995]. Oxford University, GBR, 103–129.

[Chinesta] Francisco Chinesta, From Data-based engineered models to Model-based engineered data, Compumag, Paris, 2019

[Chu] Chu, X., He, Y., Chakrabarti, K., & Ganjam, K. (2015, May). Tegra: Table extraction by global record alignment. In Proceedings of the 2015 ACM SIGMOD international conference on management of data (pp. 1713-1728).

[Clark] Clark, C. A., & Divvala, S. (2015, April). Looking beyond text: Extracting figures, tables and captions from computer science papers. In Workshops at the Twenty-Ninth AAAI Conference on Artificial Intelligence.

[Collobert] Collobert R. und Weston J. (2008) A unified architecture for natural language processing: Deep neural networks with multitask learning. In Proceedings of the 25th international conference on Machine learning, pp. 160–167.

[CornVie] Alessandro Cornaglia, Alexander Viehl, Oliver Bringmann, and Wolfgang Rosenstiel. 2019. SIMULTime: Context-sensitive timing simulation on intermediate code representation for rapid platform explorations. In Proceedings of the 24th Asia and South Pacific Design Automation Conference (ASPDAC ’19).

[Coüasnon] Coüasnon, B., & Lemaitre, A. (2014). Handbook of Document Image Processing and Recognition, chapter Recognition of Tables and Forms.

[Csaba] Csaba Szepesvári, Algorithms for Reinforced Learning, Morgan & Claypool, 2010

[Csurka] Domain Adaptation for Visual Applications: A Comprehensive Survey, Csurka, 2007, arXiv:1702.05374

[DAC_AI] Machine Learning/AI, DAC 2019; https://www.dac.com/content/machine-learningai

[DACPan20] DAC Panel – Artificial Intelligence Comes to CAD: Where's the Data? by Tom Simon on 07-30-2020 at 10:00 am, Categories: AI, EDA, Events, Synopsys https://semiwiki.com/eda/288904-dac-panel-ai-artificial-intelligence-comes-to-cad-wheres-the-data/

[DCP] https://dcp-standard.org/

[DeepPCB] Chip Placement with Deep Reinforcement Learning (https://arxiv.org/pdf/2004.10746.pdf), A Deep Reinforcement Learning Approach for Global Routing (https://arxiv.org/abs/1906.08809), DeepPCB™: Pure AI-powered, cloud-native PCB routing (https://deeppcb.ai/), Demystifying Machine Learning for Signal and Power Integrity Problems in Packaging (https://ieeexplore.ieee.org/document/9149655

[Dernoncourt] Dernoncourt F., Young Lee J. und Szolovits P. (2017) Neuroner: an easy-to-use program for named-entity recognition based on neural networks. arXiv preprint arXiv:1705.05487

[Dhiran] Dhiran, T., & Sharma, R. (2013). Table detection and extraction from image document. International Journal of Computer & Organization Trends, 3(7), 275-278.

[Dierig] Dierig, C. (2018, April 22). Fachkräftemangel kostet Deutschland 30 Milliarden Euro. WELT. Retreived from: https://www.welt.de/wirtschaft/article175699077/Fachkraeftemangel-kostet-Deutschland-30-Milliarden.html

[DiKMU] Karl Lichtblau, Thomas Schleiermacher, Henry Goecke, Peter Schützdeller: Digitalisierung der KMU in Deutschland – Konzeption und empirische Befunde, iwconsult, Köln, 2018

[DiWiGe] Karl Lichtblau, Manuel Fritsch, Agnes Millack: Digitalisierung von Wirtschaft und Gesellschaft in Deutschland – ein Überblick, iwconsult, Köln, 2018

[DREAMplace] DREAMPlace: Deep Learning Toolkit-Enabled GPU Acceleration for Modern VLSI Placement (https://www.cerc.utexas.edu/utda/publications/C252.pdf

[EffectivePCB] Effective PCB Decoupling Optimization by Combining an Iterative Genetic Algorithm and Machine Learning (https://www.mdpi.com/2079-9292/9/8/1243)

[Ertel] Wolfgang Ertel: Grundkurs Künstliche Intelligenz - Eine praxisorientierte Einführung, 4., überarbeitete Aufla-ge, Springer Vieweg, 2016

[Esteban] Arroyo Esquivel Esteban, Capturing and Exploiting Plant Topology and Process Information as a Basis to Support Engineering and Operational Activities in Process Plants, Dissertation, HSU / UNiBw H 2017

[Eurostat] Eurostat. (November 20, 2018). Number of enterprises in the manufacture of electronic components industry in Germany from 2008 to 2016 [Graph]. In Statista. Retrieved May 07, 2020, from

https://www.statista.com.login.bibproxy.whu.edu/statistics/383830/enterprises-manufacturing-electronic-components-germany/

[Evertiq] Evertiq (2018, Januar 08). Top 25 der EMS-Dienstleister in Europa. Retreived from: https://evertiq.de/news/21703

[Farrukh] Farrukh, W., Foncubierta-Rodriguez, A., Ciubotaru, A. N., Jaume, G., Bejas, C., Goksel, O., & Gabrani, M. (2017, November). Interpreting data from scanned tables. In 2017 14th IAPR International Conference on Document Analysis and Recognition (ICDAR) (Vol. 2, pp. 5-6). IEEE.

[Fisher] Fisher, R. A.: The Use of Multiple Measurements in Taxonomic Problems. Annals of Eugenics. 7 (2), Seiten 179–188, 1936

[FMI] https://fmi-standard.org

[Gatos] Gatos, B., Danatsas, D., Pratikakis, I., & Perantonis, S. J. (2005, August). Automatic table detection in document images. In International Conference on Pattern Recognition and Image Analysis (pp. 609-618). Springer, Berlin, Heidelberg.

[Gilani] Gilani, A., Qasim, S. R., Malik, I., & Shafait, F. (2017, November). Table detection using deep learning. In 2017 14th IAPR International Conference on Document Analysis and Recognition (ICDAR) (Vol. 1, pp. 771-776). IEEE.

[GloBay] A Global Bayesian Optimization Algorithm and Its Application to Integrated System Design (https://ieeexplore.ieee.org/abstract/document/8253829)

[Graeber] F. Graeber; Sechs KI-Trends in 2019; Elektronik 04-2019 (GMM); Seiten 25 – 26

[Graves] Graves, Alex & Wayne, Greg & Reynolds, Malcolm & Harley, Tim & Danihelka, Ivo & Grabska-Barwińska, Agnieszka & Gómez, Sergio & Grefenstette, Edward & Ramalho, Tiago & Agapiou, John & Badia, Adrià & Hermann, Karl & Zwols, Yori & Ostrovski, Georg & Cain, Adam & King, Helen & Summerfield, Christopher & Blunsom, Phil & Kavukcuoglu, Koray & Hassabis, Demis. (2016). Hybrid computing using a neural network with dynamic external memory. Nature. 538. 10.1038/nature20101.

[Gupta] Gupta, A., Tiwari, D., Khurana, T., & Das, S. (2019). Table detection and metadata extraction in document images. In Smart Innovations in Communication and Computational Sciences (pp. 361-372). Springer, Singapore.

[ISO26262] ISO 26262: „Road vehicles – functional safety“, 2018-12

[ITAS] BMBF-Förderprojekt „Integrationstechnolgien für autonome Sensorsysteme“, https://www.binder-elektronik.de/referenzen#itas-integrationtechnologien-fuer-autonome-sensorsysteme

[Jahan] Jahan Mac A. und Ragel R. G. (2014) Locating Tables in Scanned Documents for Reconstructing and Republishing (ICIAfS14).

[JITX] Startup JITX Uses AI to Automate Complex Circuit Board Design, https://spectrum.ieee.org/tech-talk/computing/hardware/startup-jitx-uses-ai-to-automate-complex-circuit-board-design (Artikel vom 31.07.18)

[KabYed] M. R. Kabir, B. B. Yedla Ravi, and S. Ray, “A virtual prototyping platform for exploration of vehicular electronics,” IEEE Internet of Things Journal, vol. 10, no. 18, pp. 16 144–16 155, 2023.

[Kavasidis] Kavasidis, I., Pino, C., Palazzo, S., Rundo, F., Giordano, D., Messina, P., & Spampinato, C. (2019, September). A saliency-based convolutional neural network for table and chart detection in digitized documents. In International Conference on Image Analysis and Processing (pp. 292-302). Springer, Cham.

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

[KIment] Deliver “smarter” faster: Mentor introduces new AI/ML toolkit, adds AI/ML power to Calibre tools to speed smarter IC innovation; https://www.mentor.com/company/news/siemens-mentor-introduces-new-ai-ml-toolkit-adds-ai-ml-power-to-calibre-tools-to-speed-smarter-ic-innovation

[KIsyn] Artificial Intelligence Solutions, Unlock the Transformative Power of AI; https://www.synopsys.com/ai.html

[KI-MUSIK40] BMBF-Förderprojekt „Mikroelektronik-basierte universelle Sensor-Schnittstelle mit Künstlicher Intelligenz für Industrie 4.0“, https://www.elektronikforschung.de/projekte/ki-musik4.0

[Krizhevsky] Krizhevsky, Sutskever, Hinton; ImageNet Classification with Deep Convolutional Neural Networks; 2012; Advances in Neural Information Processing Systems 25

[Kuru] Kuru O., Can O. A., und Yuret D. (2016) Charner: Character-level named entity recognition. In Proceedings of COLING 2016, the 26th International Conference on Computational Linguistics: Technical Papers, pp. 911–921.

[Lample] Lample G. , Ballesteros M., Subramanian S., Kawakami K. und Dyer C. (2016) Neural architectures for named entity recognition. arXiv preprint arXiv:1603.01360.

[LiHanLi] Li J.,Sun A., Han J. und Li C. (2020) A Survey on Deep Learning for Named Entity Recognition. In Proceedings of the Seventh Joint Conference on Lexical and Computational Semantics, pp. 167-172.

[Liu] Liu, Y. (2009). Tableseer: automatic table extraction, search, and understanding.

[LuSun] T. Lu, J. Sun, K. Wu and Z. Yang; High-Speed Channel Modeling With Machine Learning Methods for Signal Integrity Analysis; IEEE Transactions on Electromagnetic Compatibility, vol. 60, no. 6, pp. 1957 - 1964, Dec. 2018.

[Mandal] Mandal, S., Chowdhury, S. P., Das, A. K., & Chanda, B. (2004). A Very Efficient Table Detection System from Document Images. In ICVGIP (pp. 411-416).

[Masudul] Masudul H. Quraishi, Hessam S. Sarjoughian, and Soroosh Gholami. 2018. Co-simulation of hardware RTL and software system using FMI. In Proceedings of the 2018 Winter Simulation Conference (WSC ’18). IEEE Press, 572–583.

[Mikolov] Tomas Mikolov, Kai Chen, Greg Corrado, Jeffrey Dean: Efficient Estimation of Word Representations in Vector Space. https://arxiv.org/abs/1301.3781

[Miloševic] Miloševic, N. (2018). A multi-layered approach to information extraction from tables in biomedical documents.

[Minsky] M. Minsky, Neural Nets and the Brain Model Problem, Ph.D. dissertation in Mathematics, Princeton, 1954; siehe auch: M. Minsky, Seymour Papert: Perceptrons. An Introduction to Computational Geometry. MIT Press, Cambridge MA u. a. 1969

[MueBel] D.Mueller, M.Beltle, S.Tenbohlen: Automated Filter Optimization for High-Voltage Cable Harness Based on Circuit Simulations for Conducted Emissions Prediction, EMC Europe 2018, Amsterdam 2018

[NgLimKoo] Ng, H. T., Lim, C. Y., & Koo, J. L. T. (1999, June). Learning to recognize tables in free text. In Proceedings of the 37th annual meeting of the Association for Computational Linguistics on Computational Linguistics (pp. 443-450). Association for Computational Linguistics.

[OWL2] https://www.w3.org/TR/owl2-overview/

[Pomerleau] Dean A. Pomerleau. 1988. ALVINN: an autonomous land vehicle in a neural network. In Proceedings of the 1st International Conference on Neural Information Processing Systems (NIPS'88). MIT Press, Cambridge

[PythonML] Pros and Cons of Python in Machine Learning, https://www.zarantech.com/blog/pros-and-cons-of-python-in-machine-learning/

[Qiao] Qiao, Kai; Zeng, Lei; Chen, Jian; Hai, Jinjin; Yan, Bin; Wire segmentation for printed circuit board using deep convolutional neural network and graph cut model; IET Image Processing, 2018, 12, (5), p. 793 – 800

[RamaSingh] Ramasubramanian K., Singh A.; Deep Learning Using Keras and TensorFlow; Machine Learning Using R. Apress, Berkeley, CA, 2019

[RDF] https://www.w3.org/TR/rdf-schema/

[RDF11] https://www.w3.org/TR/rdf11-concepts/

[Redmon] Redmon, J., & Farhadi, A. (2018). Yolov3: An incremental improvement. arXiv preprint arXiv:1804.02767

[Sarawagi] Sunita Sarawagi: Information Extraction. In: Foundations and Trends in Databases. Volume1, Issue 3, 2008 https://doi.org/10.1561/1900000003

[Schreiber] Schreiber, S., Agne, S., Wolf, I., Dengel, A., & Ahmed, S. (2017, November). Deepdesrt: Deep learning for detection and structure recognition of tables in document images. In 2017 14th IAPR International Conference on Document Analysis and Recognition (ICDAR) (Vol. 1, pp. 1162-1167). IEEE.

[SciKit] scikit-learn, Machine Learning in Python;https://scikit-learn.org/stable/

[Silva] e Silva, A. C., Jorge, A., & Torgo, L. (2003, December). Automatic selection of table areas in documents for information extraction. In Portuguese Conference on Artificial Intelligence (pp. 460-465). Springer, Berlin, Heidelberg.

[SKOS] https://www.w3.org/TR/skos-primer/

[SSP] https://ssp-standard.org/

[Statista] Statistisches Bundesamt. (May 28, 2019). Industry revenue of “manufacture of electronic components and boards“ in Germany from 2011 to 2023 (in billion U.S. Dollars) [Graph]. In Statista. Retrieved May 07, 2020, from https://www.statista.com.login.bibproxy.whu.edu/forecasts/883959/manufacture-of-electronic-components-and-boards-revenue-in-germany

[SurTay] Transfer Learning for Reinforcement Learning Domains: A Survey, Tayler et al., 2009, Journal of Machine Learning Research 10 1633-1685

[Teich] Irene Teich: Meilensteine der Entwicklung künstlicher Intelligenz. Informatik Spektrum 43, Seiten 276-284, 2020

[Tengli] Tengli, A., Yang, Y., & Ma, N. L. (2004, August). Learning table extraction from examples. In Proceedings of the 20th international conference on Computational Linguistics (p. 987). Association for Computational Linguistics.

[Torabi] Faraz Torabi and Garrett Warnell and Peter Stone, Behavioral Cloning from Observation, 2018

[TrainingModel] A Data-Efficient Training Model for Signal Integrity Analysis based on Transfer Learning (https://ieeexplore.ieee.org/document/8953103

[TransLearn] Journal of Machine Learning Research 10 (2009) 1633-1685Submitted 6/08; Revised 5/09; Published 7/09, Transfer Learning for Reinforcement Learning Domains: A Survey;

[TUDO1] Marian Patrik Felder, Michael Kiffmeier, Jürgen Götze, Stephan Frei, Daniel Renner, Fusion of measurements by existing nodes in an on-board power supply system for condition monitoring with focus on the battery, In Beiträge der 8. GMM-Fachtagung, VDE VERLAG GMBH, vol. 8, pp. 75-80, 2017.

[TUDO2] P. Jansen, T. Gebel, D. Renner, D. Vergossen, W. John, J. Götze, An approach to determine the state of charge of a lithium iron phosphate cell using classification methods based on frequency domain data, In 8th IET International Conference on Power Electronics, Machines and Drives (PEMD 2016), Glasgow, 2016.

[TUDO3] M. P. Felder, J. Götze, State of Charge-Klassifizierung für Lithium-Ionen-Batterien anhand von impedanzbasierten Merkmalen, In Advances in Radio Science, Copernicus Publications, vol. 14, Miltenberg, Germany, pp. 1-5, 2016.

[TUDO4] Jansen, M. Vollnhals, D. Renner, D. Vergossen, W. John, J. Götze, Advanced binary search pattern for impedance spectra classification for determining the state of charge of a lithium iron phosphate cell using a support vector machine, In Advances in Radio Science, vol. VI, no. 14, pp. 55-62, 2016.

[TUDO5] P. Jansen, D. Vergossen, D. Renner, W. John, J. Götze, Impedance spectra classification for determining the state of charge on a lithium iron phosphate cell using a support vector machine, In Advances in Radio Science, Copernicus Publications, vol. 13, Miltenberg, Deutschland, pp. 127-132, 2015.

[TUDO6] P. Jansen, D. Vergossen, D. Renner, W. John, J. Götze, Bestimmung des Ladezustands von Batterien mittels zustandsraumbasierter Verfahren mit online-Parameterschätzung, In Elektrik/Elektronik in Hybrid- und Elektrofahrzeugen und elektrisches Energiemanagement, expertverlag, vol. VI, no. 138, Bad Boll, Deutschland, pp. 361-376, 2015.

[TUDO7] T. Nick, Signalverarbeitungsmethoden zur Lokalisierung passiver UHF RFID Label in der Logistikbranche, In 6. Dresdner RFID-Symposium, Dresden, Germany, 2012.

[TUDO8] T. Nick, J. Götze, Multi-Hypothesis Kalman Filter for RFID-Based Localization and Tracking, In URSI Kleinheubacher Tagung 2012, Miltenberg, Germany, 2012.

[TUDO9] M. Lechtenberg, J. Götze, K. Görner, C. Rehtanz, Parameter Estimation under Non-Stationary Circumstances using extended Signal Model, In Kleinheubacher Tagung (KH 2013)/Advances in Radio Science 2014, Miltenberg, Germany, 2013.

[UNECE10] Regelung Nr. 10 der Wirtschaftskommission der Vereinten Nationen für Europa (UN/ECE) — Einheitliche Bedingungen für die Genehmigung der Fahrzeuge hinsichtlich der elektromagnetischen Verträglichkeit, Rev. 6, Europäische Union, 20.12.2018

[VRue] Von Rueden, Laura, et. al., „Informed Pre-Training on Prior Knowledge“, arXiv preprint arXiv:2205.11433, 2022

[Weiss] Weiss, D. (2019, Dezember). Die Europäische EMS Industrie, eine detaillierte Analyse. Weiss Engineering. Retreived from: https://www.in4ma.de

[WIKImem] https://de.wikipedia.org/wiki/Long_short-term_memory

[Yadav] Yadav V., Sharp R., und Bethard S. (2018) Deep affix features improve neural named entity recognizers. In Proceedings of the Seventh Joint Conference on Lexical and Computational Semantics, pp. 167–172.

[Zhang] L. Zhang et al.; Convolutional neural network-based multi-label classification of PCB defects; The Journal of Engineering, vol. 2018, no. 16, pp. 1612 - 1616, 11 2018.

[Zhu] Semi-Supervised Learning Literature Survey, Zhu, 2005, Technical Reports Archive for the Department of Computer Science at the University of Wisconsin-Madison; The Simple and Efficient Semi-Supervised Learning Method for Deep Neural Networks, Lee, 2013

[Ziebart] Brian D. Ziebart, Andrew Maas, J. Andrew Bagnell, Anind K, Dey, Maximum Entropy Inverse Reinforced Learning, Proc. 23th AAAI Conf. On Artificial Inteligence, 2008

[ZVEI2019] ZVEI, (2019, Juli 11). Die globale Elektroindustrie – Daten, Zahlen und Fakten. Retrieved from: https://www.zvei.org/presse-medien/publikationen/die-globale-elektroindustrie-daten-zahlen-und-fakten/

[ZVEI2020] ZVEI, (2020, April 21). The German Electric Industry – Facts & Figures. Retrieved from: https://www.zvei.org/en/press-media/publications/the-german-electric-industry-facts-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: KI-Unterstützung für Requirement-Engineering	
4. Autor(en) [Name(n), Vorname(n)] Eberhardt, Markus Bärnthaler, Andrea	5. Abschlussdatum des Vorhabens 30.09.2024
	6. Veröffentlichungsdatum
	7. Form der Publikation Schlussbericht
8. Durchführende Institution(en) (Name, Adresse) HOOD GmbH 82041 Oberhaching	9. Ber. Nr. Durchführende Institution
	10. Förderkennzeichen 19A21006H
	11. Seitenzahl 147
12. Fördernde Institution (Name, Adresse) Bundesministerium für Wirtschaft und Klimaschutz (BMWK) 53107 Bonn	13. Literaturangaben 67
	14. Tabellen 5
	15. Abbildungen 35
16. Zusätzliche Angaben	
17. Vorgelegt bei (Titel, Ort, Datum)	

18. Kurzfassung

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

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

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

Ziel des Projektes war es, durch den kooperativen Betrieb von KI-Systemen Elektroniksysteme schneller und zuverlässiger zu entwickeln, um somit für zukünftige Schlüsseltechnologien für die Automobilindustrie eine weltweit wirkende Innovations- und Technologieführerschaft der beteiligten Unternehmen zu erreichen. Typische elektronische Komponenten sind zum Beispiel: ABS oder ESP bzw. ACC. Weiterhin sollen hier genannt werden: Umfelderfassung durch kompakte Sensorik sowie die Sensordatenfusion und -interpretation in Echtzeit mittels leistungsfähiger Steuereinheiten und Multiprozessorsysteme. Zur Entwicklung sicherer und zuverlässiger elektronischer Komponenten und Systeme sind u. a. neue Entwurfs- und Validierungsmethoden auf KI-Basis notwendig.

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: AI support for requirement engineering	
4. author(s) (family name, first name(s)) Eberhardt, Markus Bärnthaler, Andrea	5. end of project 30.09.2024
	6. publication date
	7. form of publication Final Report
8. performing organization(s) (name, address) HOOD GmbH 82041 Oberhaching	9. originator's report no.
	10. reference no. 19A21006H
	11. no. of pages 147
12. sponsoring agency (name, address) Bundesministerium für Wirtschaft und Klimaschutz (BMWK) 53107 Bonn	13. no. of references 67
	14. no. of tables 4
	15. no. of figures 35
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