Finanziert von der Europäischen Union
NextGenerationEU

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

BMWK-Verbundprojekt: progressivKI
Förderkennzeichen: 19A21006G
Projektlaufzeit: 01.04.2021 bis 30.09.2024

Schlussbericht

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

Teilvorhaben Automatische KI-basierte Analyse von Tabellen, Skizzen und Textelementen

Version: 0.03
Erstelldatum: 02.12.2024

Autoren: Timon Ruban

Zuwendungsempfänger: Luminovo GmbH (Fkz: 19A21006G)

Ansprechpartner: Luminovo GmbH
Timon Ruban
80799 München
timon@luminovo.com

Das diesem Bericht zugrundeliegende Vorhaben wurde mit Mitteln des Bundesministeriums für Wirtschaft und Klimaschutz unter dem Förderkennzeichen 19A21006G gefördert. Die Verantwortung für den Inhalt dieser Veröffentlichung liegt bei den Autoren.

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

Inhalt

1 Zusammenfassung 4

2 Ziele 4

2.1.1 Bisherige Arbeiten des Antragstellers 4

3 Technische Ergebnisse 5

3.1.1 Teilaufgabe 1.3: KI-Module/KI-Algorithmen/Analyse Synergien 5

3.1.2 Teilaufgabe 1.4: KI-Module für KI-Plattformen der Anwendungsebenen #1 - #2 + Struktur der KI-Plattformen 6

3.2 Arbeitspaket 2: KI-Datenaufbereitung/-generierung 7

3.2.1 Teilaufgabe 2.2: Test-/Lerndatenerzeugung 7

3.2.2 Teilaufgabe 2.4: Entwicklung und Validierung eines Meta-Algorithmus 9

3.2.3 Teilaufgabe 2.5: Datenbasierte Trainings-/Lernmodule 9

3.3 Arbeitspaket 3: Verzahnte Entwicklung von Automobilkomponenten 11

3.3.1 Teilaufgabe 3.1: Framework KI-Module für AW-Ebenen #1 und #2 + Optimierung KI-Module 11

3.3.2 Teilaufgabe 3.3: Implementation spezifischer und vor-trainierter KI-Module für die Anwendungsebenen #1 und #2 11

3.3.3 Teilaufgabe 3.5: Implementierung Meta-Algorithmen 12

3.3.4 Teilaufgabe 3.6: Validierung KI-Module/KI-Framework für Plattformen Anwendungsebenen #1 und #2 12

3.4 Arbeitspaket 4: Erstellung Teilplattformen (#1: PCB-Entwurf; #2: IC-Anwendung/Sensorik) 14

3.4.1 Teilaufgabe 4.1: KI-Plattform Anwendungsebene #1 PCB-Entwurf 14

3.5 Arbeitspaket 5: Projektmanagement & Dissemination 15

3.5.1 Teilaufgabe 5.2: F+E-Ergebnisverbreitung + F+E-Nutzungspotentiale 15

4 Verwertung und voraussichtlicher Nutzen 16

5 Veröffentlichungen 17

6 Quellen 23

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

2.1.1 Bisherige Arbeiten des Antragstellers

Unternehmensvorstellung

Luminovo ist ein 2017 gegründetes Münchener Unternehmen, welches zunächst branchenübergreifend Firmen entlang der gesamten Wertschöpfungskette im Bereich KI unterstützt hat: Vom Verstehen und Beratung zu KI-Anwendungsfällen bis hin zur Umsetzung und nachhaltigen Implementierung von KI-Systemen. Dabei hat sich Luminovo auf die zwei Bereiche Natural Language Processing (NLP) und Computer Vision (CV) spezialisiert. Seit Ende 2019 hat sich Luminovo zu einem produktorientierten Unternehmen entwickelt, und entwickelt ein umfassendes Elektronik-Betriebssystem, dass auf intelligenten Algorithmen und einem kooperativen Ansatz basiert, um eine nahtlose Kommunikation über die gesamte Wertschöpfungskette zu ermöglichen und Engineering und Overhead-Prozesse zu optimieren.

Projektbezogene Kompetenzen und Schwerpunkte

Luminovo bringt ins Förderprojekt die langjährige Erfahrung und Kompetenz im Bereich des maschinellen Lernens und NLP, sowie die gesammelte Erfahrung im Bereich der Elektronikentwicklung ein. Ihr Team kombiniert fundierte Kenntnisse über Software und KI mit elektrotechnischem Know-how und ist bestrebt, den technologischen Fortschritt in der Elektronikindustrie mithilfe von progressivKI zu beschleunigen. Für die Bearbeitung des Projekts wird Luminovo vorrangig bei der Analyse der Anforderungen und Spezifikation, der Datengenerierung und Aufbereitung und der Implementation der modular strukturierte KI-Plattform unterstützten. Insbesondere liegt hier der Fokus auf der KI-gestützten Informationsextraktion, um Informationen von elektronischen Komponenten aus semi-strukturierten Datenblättern in Echtzeit für beteiligte Stakeholder im Entwicklungsprozess über die KI-Plattform verfügbar zu machen.

Relevante Vorgängerprojekte

Luminovo hat als Entwicklungsdienstleister über 30 Projekte mit KMUs und DAX Konzernen im Bereich der Bild- und Textverarbeitung durchgeführt. Im Rahmen eines erfolgreichen Projektes mit Infineon hat Luminovo einen KI-Algorithmus zur Erkennung von Neuerungen entwickelt, der die Redundanz in Simulationen reduzieren kann. Durch den Algorithmus kann der Kunde 2.400.000 Stunden Rechenzeit, sowie einen zweistelligen Millionenbetrag pro Chipdesign einsparen und die Time-to-Market um 3 Monate verkürzen. In einem vom BMBF geförderten Forschungsprojekt hatte Luminovo die Möglichkeit eine Infrastruktur zur KI-basierten Verarbeitung von unstrukturierten Dokumenten zu entwickelt. Die Technologie, welche maschinelles Lernen und menschliche Fähigkeiten kombiniert, hilft repetitive Prozesse wie Inhaltsüberprüfung und Datenextraktion aus Dokumenten zu automatisieren.

3 Technische Ergebnisse

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

Teilbeitrag 1.3.7: Analyse von KI-Algorithmen zur Erkennung von Gerber-Dateien (07-LUMI)

Ziele

Analyse von KI-Algorithmen und Open-Source Deep Learning-Algorithmen zur Extraktion relevanter Daten aus Gerber-Dateien. Analyse von Computer Vision Algorithmen zur Layer-Klassifiizerung von Gerber-Dateien. Auswahl und Konzeption einer geeigneten Modellarchitektur

zur automatischen Identifikation und Klassifikation von relevanten Informationen auf Gerber-Dateien unter Berücksichtigung der geometrischen, visuellen und textlichen Merkmale.

Problemstellung

Es gibt eine große Anzahl an KI-Frameworks die sich zur Implementierung der im Rahmen von ProgressivKI angegangenen Projekte eignet. Zunächst galt es also die besten Open-Source-Frameworks zur späteren Implementierung auszuwählen.

Lösungsweg und Ergebnisse

Die wichtigsten Kriterien für die Auswahl der Frameworks waren

- Bekanntheit mit unseren Mitarbeitern
- Generelle Bekanntheit und damit verbundener Support in der Open-Source-Community

Unsere Wahl zur Implementierung der KI-Algorithmen fiel auf PyTorch Lightning (für die Modellarchitektur) und ray.tune (für die Hyperparameter-Suche). Für das Pre-processing der Daten und die Implementierung der Metriken (zur Analyse der Performance der Modelle) fiel unsere Wahl auf die komplementären Open-source-Pakete torchmetrics (für die Implementierung der Metriken) und sklearn und torchvision (zum Pre-processing der Daten).

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

Teilbeitrag 1.4.7: Festlegung KI-Architektur zur Informationsextraktion aus Datenblättern (07-LUMI)

Ziele

Auswahl und Konzeption einer geeigneten Modellarchitektur zur automatischen Extraktion von relevanten Informationen aus Gerber-Dateien aus unterschiedlichen ECAD-Programmen unter Berücksichtigung der geometrischen, visuellen und textlichen Merkmale.

Problemstellung

Um später ein KI-Modell trainieren und auswerten zu können, muss zunächst eine geeignete Modellarchitektur ausgewählt werden für die zwei Anwendungsfälle Gerber2Layer und PCB Panel Counter.

Lösungsweg und Ergebnisse

Da die Konzeption einer komplett neuen Architektur den Rahmen dieses Projektes sprengen würden, haben wir uns auf die Auswahl verschiedener in der Forschung gut dokumentierter Deep Learning Modelle begrenzt.

Nach der initialen Recherche und Durchführung erster Experimente, haben wir uns auf die ResNet-18 und ResNet-50 KI-Architekturen für die Bild-Analyse entschieden. Beide haben sich als leicht zu trainierende und leistungsstarke Architekturen in vielen anderen Anwendungen bewiesen. Diese Architektur wurde sowohl für den Gerber2Layer (mit einem KI-Modell automatisiert jede Lage der

Gerber-Dateien zu klassifizieren) als auch für den PCB Panel Counter (mit einem KI-Modell automatisiert die Anzahl der PCBs auf einem Panel zählen) Anwendungsfall ausgewählt. Beim PCB Panel Counter wurde zudem ein Random Forest Modell ausgewählt (ein Standard-Algorithmus des klassischen Machine Learnings).

3.2 Arbeitspaket 2: KI-Datenaufbereitung/-generierung

3.2.1 Teilaufgabe 2.2: Test-/Lerndatenerzeugung

Teilbeitrag 2.2.7: Datenvorverarbeitung und Datentransformation zur Erzeugung von Ziel-Datensätzen für das Training von aus-gewählten KI-Algorithmen (07-LUMI)

Ziele

Datenvorverarbeitung und Datentransformation zur Erzeugung des Ziel-Datensatzes für das Training von KI-Modellen (e.g., wie künstlichen Neuronalen Netzen). Vereinheitlichung der Datenstruktur und Datenformate der Gerber-Dateien aus unterschiedlichen ECAD-Programmen. Methoden zur Erkennung von Abhängigkeiten, Verteilungen und Merkmalsausprägungen in den strukturell unterschiedlichen Gerber-Dateien mithilfe von statistischen und numerischen Methoden und Datenvisualisierungen.

Problemstellung

Die Verarbeitung von Gerber-Dateien, welche aus unterschiedlichen ECAD-Programmen stammen, stellt eine zentrale Herausforderung dar, da diese Dateien in verschiedenen Datenstrukturen und Formaten vorliegen. Für das Training von KI-Modellen, wie künstlichen neuronalen Netzen, ist es notwendig, die Daten zu vereinheitlichen und zielgerichtet aufzubereiten. Darüber hinaus müssen Abhängigkeiten, Verteilungen und Merkmalsausprägungen der Gerber-Daten analysiert und aufbereitet werden, um einen robusten und nutzbaren Datensatz (bestehend aus Train-, Validation- und Test-Set) für spezifische KI-Anwendungsfälle wie die Layer-Klassifikation oder das Zählen von PCBs auf Panels zu erstellen.

Lösungsweg und Ergebnisse

Eine Pipeline wurde implementiert, die Gerber-Dateien verschiedener ECAD-Programme verarbeitet und für jeden Layer ein Bild (.jpeg) generiert. Diese Bilder dienen als Grundlage für die Erstellung gelabelter Datensätze zur Entwicklung von KI-Algorithmen für den Gerber2Layer und PCB Panel Counter Anwednungfall. Zudem wurden alle gängigen data-preprocessing-Techniques im Computer Vision Bereich auf ihre Anwendbarkeit auf aus Gerber-Dateien generierten Bildern geprüft und als data-preprocessing-Pipeline implementiert. Diese beinhaltetet Transformationen, u.a. eine Normalisierung (um Mean auf 0 und Standard Deviation auf 1 zu bringen), Transformation in einen Tensor und Resizing-Algorithmen, Transformation von Farbe zu Grayscale und Salt und Pepper (eine Transformation, bei der zufällige Pixelwerte in Bildern auf 0 gesetzt und gelöscht werden). Gängige Augmentierungen wie Flipping und ColorJitter wurden als nicht sinnvoll für Gerber-Bilder erkannt.

Die Pipeline wurde sowohl zur Datenvorbereitung für den PCB Panel Counter Anwendungsfall und den Gerber2Layer-Anwendungsfall genutzt.

In beiden Fällen generierte ein manueller Labeling-Prozess die notwendige Ground Truth, wodurch ein umfangreicher Datensatz entstand, der in Trainings-, Validierungs- und Test-Sets aufgeteilt werden kann. Die Ergebnisse legen eine solide Grundlage für die weitere Optimierung und Anwendung der KI-Modelle.

Für den PCB Panel Counter wurden 3427 Bilder generiert, die eine Vielzahl unterschiedlicher Leiterplatten abbilden. Für Gerber2Layer wurde ein mehrere Hundert Datenpunkte umfassendes Datenset erstellt.

Die genauen Labels und Anzahl Datenpunkte der beiden Anwendungsfälle können der untenstehenden Tabelle entnommen werden.

FileFunction	N
AdhesiveBottom	3
AdhesiveTop	7
CopperBottom	361
CopperMid	279
CopperTop	340
Drill	12

FileFunction	N
KeepOut	75
Mechanical	238
Outline	182
PasteBottom	108
PasteTop	191
PeelableTop	23

FileFunction	N
PHDrill	5
PlaneMid	29
SilkscreenBottom	302
SilkscreenTop	370
SoldermaskBottom	386
SoldermaskTop	381

Tabelle 1: Übersicht des erstellten Datensatzes für den Gerber2Layer Anwendungsfall aus Gerber-Dateien und zugehörigen Labels der Layer

```
---------------------- STATS ---------------------
Total number of images:                          3427
Number of images with a single PCB:              2920
Number of images with more than one PCB:          507
Number of images marked ambiguous or mislabeled:   94
Percentage of images with a single PCB:  85.206%
```

Abbildung 1: Auflistung des Datensets für den PCB Panel Counter Anwendungsfall

```
Number of images with    1 PCBs:   2920
Number of images with    2 PCBs:     64
Number of images with    3 PCBs:     14
Number of images with    4 PCBs:     69
Number of images with    5 PCBs:     23
Number of images with    6 PCBs:     46
Number of images with    8 PCBs:     36
Number of images with    9 PCBs:     14
Number of images with   10 PCBs:     43
Number of images with   11 PCBs:      1
Number of images with   12 PCBs:     20
Number of images with   14 PCBs:      4
Number of images with   15 PCBs:     13
Number of images with   16 PCBs:     18
Number of images with   18 PCBs:      8
Number of images with   20 PCBs:     27
Number of images with   21 PCBs:      2
Number of images with   24 PCBs:      8
Number of images with   25 PCBs:     16
Number of images with   27 PCBs:      1
Number of images with   28 PCBs:      2
Number of images with   30 PCBs:      3
Number of images with   35 PCBs:      3
Number of images with   36 PCBs:      3
Number of images with   40 PCBs:      8
Number of images with   42 PCBs:      1
Number of images with   48 PCBs:      3
Number of images with   50 PCBs:     20
Number of images with   54 PCBs:      1
Number of images with   56 PCBs:      1
Number of images with   60 PCBs:      3
Number of images with   70 PCBs:      3
Number of images with   75 PCBs:      1
Number of images with   78 PCBs:      1
Number of images with   80 PCBs:      3
Number of images with   81 PCBs:      1
Number of images with   96 PCBs:      1
Number of images with  100 PCBs:      9
Number of images with  108 PCBs:      2
Number of images with  126 PCBs:      1
Number of images with  130 PCBs:      1
Number of images with  140 PCBs:      1
Number of images with  150 PCBs:      3
Number of images with  176 PCBs:      1
Number of images with  224 PCBs:      1
Number of images with  243 PCBs:      1
Number of images with  250 PCBs:      2
```

Abbildung 2: Detaillierte Auflistung des Datensets für den PCB Panel Counter Anwendungsfall

3.2.2 Teilaufgabe 2.4: Entwicklung und Validierung eines Meta-Algorithmus

Teilbeitrag 2.4.7: Entwicklung eines Meta-Algorithmus: Konzeption und Festlegung eines geeigneten KI-Frameworks (07-LUMI)

Ziele

Konzeption, Kombination und Auswahl von relevanten Open-Source Algorithmen und Performance-Metriken zur KI-basierten Erkennung und Extraktion der Informationen aus Gerber-Dateien.

Problemstellung

Bei der Auswahl geeigneter Open-Source-Algorithmen und Performance-Metriken, stellt die die Ungleichverteilung der Labels im Datensatz eine besondere Herausforderung dar, da dadurch die Analyse der Modell-Performance verfälscht werden kann. Darüber hinaus muss das eingesetzte Framework flexibel genug sein, um unterschiedliche KI-Algorithmen effizient zu implementieren und anzupassen.

Lösungsweg und Ergebnisse

Für die Entwicklung des KI-Frameworks wurden auch hier PyTorch Lightning und ray.tune ausgewählt, die sich gut für die Implementierung verschiedenster Open-Source Algorithmen eignen. In einem weiteren Schritt wurde die Performance-Metrik “Balanced Accuracy” definiert: einer Art “averaged Recall” die in Fällen wie unseren glänzt, wenn die Labels im Datenset sehr ungleich verteilt sind und wir verhindern wollen, dass einzelne Klassen die Performance-Analyse dominieren. Zudem haben wir die Erzeugung von sogenannten “Confusion Matrices” implementiert, die sowohl bei der qualitativen (welche Klassen werden mit welchen Klassen verwechselt) und quantitativen (wie oft?) Performance-Analyse dienlich sind.

Das bisher entwickelte KI-Framework (inkl. der ausgewählten Open-Source Algorithmen und Performance-Metriken) wurde dann auf seine Anwendbarkeit auf den PCB Panel Counter-Anwendungsfall geprüft. Das Ergebnis fiel positiv aus und es wurden nur kleine Anpassungen getätigt (wie die Implementierung einer standardmäßigen “Accuracy”-Metrik, statt der für “unbalanced” Datensets geeignete “Balanced Accuracy”).

3.2.3 Teilaufgabe 2.5: Datenbasierte Trainings-/Lernmodule

Teilbeitrag 2.5.7: Datenbasierte Aufbereitung und Datenaufteilung von Bauelement-Datenblättern (07-LUMI)

Ziele

Aufteilung und Aufbereitung der Eingangs- und Ausgangsdaten der Gerber-Dateien in einen Trainings-, Validierungs-, und Testdatensatz unter Berücksichtigung der aus B2.4.7 identifizierten relevanten Merkmale, um eine hohe Generalisierbarkeit der KI-Modelle zu gewährleisten.

Problemstellung

Die Generalisierbarkeit von KI-Modellen für die Verarbeitung von Gerber-Dateien erfordert eine sorgfältige Aufbereitung und Aufteilung der Daten in Trainings-, Validierungs- und Testdatensätze. Dabei müssen die strukturellen Unterschiede der Gerber-Dateien, die uneinheitliche Qualität der

Labels sowie die Herausforderungen bei der Sicherstellung konsistenter Datenaufteilungen berücksichtigt werden.

Lösungsweg und Ergebnisse

Für den Gerber2Layer-Anwendungsfall wurden ein paar hundert Gerber-Dateien von unterschiedlichen Leiterplatten und unterschiedlichen ECAD-Programmen gesammelt und mithilfe der Pipeline aus 2.2.7. für alle Layer Bilder aus den Dateien generiert. Der gesamte Datensatz wurde dann im ersten Durchgang mit Hilfe von Heuristiken (die auf den Dateiendungen, Namen und einer sogenannten FileFunction aus der Gerber-Spezifikation basieren) gelabelt (das Label ist die Art der Layer, z.B. SoldermaskTop, SoldermaskBottom, CopperTop, CopperBottom etc.). Im Nachgang wurde dann nochmal von Hand jedes einzelne Bild kontrolliert und gegebenenfalls angepasst. Im Anschluss wurde ein Train/Val Split durchgeführt, bei dem sicher gestellt wurde, dass alle Layers von einer Leiterplatte zusammenblieben (sich also entweder im Train oder Val-Datensatz wiederfinden) um so eine bessere Generalisierung zu erlauben und feststellen zu können.

FileFunction	Train	Validation	Test
CopperBottom	289	36	36
CopperMid	219	30	30
CopperTop	272	34	34
Mechanical	178	30	30
Outline	122	30	30
PasteBottom	48	30	30
PasteTop	131	30	30
SilkscreenBottom	242	30	30
SilkscreenTop	296	37	37
SoldermaskBottom	310	38	38
SoldermaskTop	305	38	38

Tabelle 2: Split des Datensatzes in Train, Validation und Test-Set

Für den PCB Panel Counter Anwendungsfall, wurden 3427 Bilder von Leiterplatten (aus den Gerber-Dateien erstellt) gesammelt. Vor der Datenaufteilung der mehreren tausend neuen Gerber-Dateien, bedarf es einem “Labeling” (dem Hinzufügen des korrekten Wertes den das KI-Modell nachher vorhersagen soll) der Dateien. Hierzu wurde ein Labeling-Frontend implementiert und getestet, das uns erlaubt Datei für Datei die korrekte Anzahl an Leiterplatten in den Gerber-Dateien einzutragen.

Das entwickelte “Labeling”-Tool wurde genutzt um die 3427 Bilder korrekt zu labeln. Bei 94 der Bilder war das Ergebnis zweideutig und die Bilder wurden von dem Datensatz entfernt (siehe Abbildung 1 und Abbildung 2). Danach wurde der Datensatz in ein Train-, Validations- und Test-Set gesplitted, und in die End-to-End Trainings- und Evaluierungspipelines für den Panel Counter Use-Case integriert. Um diese Pipelines leichter zwischen mehreren Maschinen transferieren zu können (hilfreich um parallel Hyperparameter-Tuning durchführen zu können), wurden zusätzlich unterschiedlichen Bildkompression-Algorithmen ausprobiert um die Größe in MB des Datensatzes (aller drei Splits) zu reduzieren. Um die Performance des fertigen Modells nicht zu beinträchtigen wurde am Ende allerdings doch der Datensatz ohne Kompression verwendet.

3.3 Arbeitspaket 3: Verzahnte Entwicklung von Automobilkomponenten

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

Teilbeitrag 3.1.7: Implementierung ML-Architektur und Optimierung für Datenanalyse (07-LUMI)

Ziele

Implementierung und Initialisierung einer geeigneten Modellarchitektur für eine KI-basierten Erkennung und Extraktion von relevanten Informationen auf strukturell unterschiedlichen Gerber-Dateien..

Problemstellung

Die Wiederverwendbarkeit der Modellarchitektur und Integration in eine End-to-End-Pipeline stellen die zentrale Herausforderung dar bei der Implementierung mit Hilfe des ausgewählten KI-Frameworks.

Lösungsweg und Ergebnisse

Das in 1.4.7. erwähnten KI-Modelle (ResNet 18 und ResNet 50) wurden mit PyTorch-Lightning in einer End-to-End-Pipeline implementiert. Diese erlaubt die Hyperparameter-Parametrisierung, um eine Anpassung auf unser spezifischen Datensatz zu erlauben, und beinhaltet zudem die Datenaufbereitung und Pre-processing als auch die Verknüpfung der Modelle mit den Performance-Metriken (siehe Teilbeitrag 1.3.7.)

Die für den Gerber2Layer-Anwendungsfall implementierte End-to-end Pipeline (basiered auf PyTorch Lightning) wurde wo nötig erweitert und getestet um auch für den PCB Panel Counter Anwendungsfall wiederverwendet werden zu können.

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

Teilbeitrag 3.3.7: Implementation produkt-spezifischer vortrainierter KI-Module zwecks Informationsextraktion auf Datenblättern/-büchern (07-LUMI)

Ziele

Implementation von vortrainierten KI-Modellen zur Erkennung und Extraktion von relevanten Informationen auf einem generellen Datensatz basierend auf der ML-Architektur aus B3.1.1. um ein späteres Transfer Learning (TL) zu ermöglichen.

Problemstellung

Durchführen eines guten Hyperparameter-Tuning und Implementierung aller ausgewählten KI-Modelle um das beste vortrainierte Modell auswählen zu können.

Lösungsweg und Ergebnisse

Die zuvor ausgewählten und implementierten KI-Modelle (ResNet 50 und ResNet 18) wurden mehrfach trainiert und durch wiederholtes Hyperparameter-Tuning wurden die besten Hyperparameter für die Optimierung dieser spezifischen KI-Modelle auf die zwei spezifischen Anwendungsfälle ausgewählt. Zudem wurden die KI-Modelle um einen RandomForest-Classifier erweitert. RandomForests haben für gewöhnlich niedrige Varianz und erlauben einen neuen

Trade-Off im Klassichen Bias-Variance Trade-Off. Der Classifier wurde in die End-to-End Pipeline integriert und die Hyperparameter (der wichtigste: Anzahl der Decision Trees) optimiert um das beste Modell für den PCB Panel Counter Anwendungsfall auszuwählen.

3.3.3 Teilaufgabe 3.5: Implementierung Meta-Algorithmen

Teilbeitrag 3.5.7: Implementation E2E ML Pipeline + Modell-Training und Optimierung (07-LUMI)

Ziele

Implementierung einer End-to-End Machine-Learning Pipeline für das automatisierte Training und Evaluieren von den implementierten Extraktions-Modellen. Training von Machine Learning Modellen für die automatisierte Extraktion von Bild-, Text- und Design-for-Manufacturing-Informationen aus Gerber-Dateien. Training von ML-Modellen basierend auf dem Trainingsset der erstellten Zieldaten.

Problemstellung

Die Integration verschiedener Komponenten, darunter Datenvorverarbeitung, Datenaufteilung und Modelltraining, in eine zusammenhängende End-to-End-Pipeline. Besonders wichtig ist dabei die Schaffung einer flexiblen und automatisierten Struktur, die es ermöglicht, neue Daten effizient zu verarbeiten, Modelle neu zu trainieren und die besten Algorithmen für unterschiedliche Anwendungsfälle wie Gerber2Layer und PCB Panel Counter auszuwählen.

Lösungsweg und Ergebnisse

Eine End-to-End-Pipeline, die die Datenvorverarbeitung aus 2.2.7 mit der Datenaufteilung aus 2.5.7 und dem implementierten Modell aus 3.1.7. verbindet, wurde implementiert und auf Fehler überprüft.

Insbesondere wurden alle Bestandteile (Datenaufbereitung für Gerber-Dateien, Datenaufteilung, Training und Hyperparameterauswahl der ResNet-Modelle, Evaluierungsmetriken der unterschiedlichen Anwendungsfälle) in eine leicht, mit einem Skript ausführbare, Pipeline zusammengestückelt, so dass ein Neutrainieren und Neuauswahl des besten Modelles für den Gerber2Layer-Anwendungsfall und den PCB Panel Counter-Anwendungsfall beim Vorhandensein neuer Daten leicht möglich ist. Mit der fertigen Pipeline wurden weitere Experimente (e.g. für die Bildkompression, aber auch Standard Hyperparameter-Tuning) durchgeführt (mit den zuvor vorbereiteten Datensätzen) um das beste Modell und den besten Algorithmus zu finden.

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

Teilbeitrag 3.6.7: Modell-Evaluation und Test der trainierten Modelle (07-LUMI)

Ziele

Iterative Evaluierung und Dokumentation der trainierten Modelle für die automatisierte Extraktion von Bild-, Text- und Design-for-Manufacturing-Informationen aus Gerber-Dateien. Evaluierung und Validierung des Modells auf dem Test-Datensatz, um die Leistungsbestimmung und Funktionstüchtigkeit nachzuweisen.

Problemstellung

Die Evaluierung von KI-Modellen für Anwendungsfälle wie Gerber2Layer und PCB Panel Counter erfordert die Auswahl und Implementierung geeigneter Metriken und Ansätze, um sowohl qualitative als auch quantitative Aussagen über die Modellleistung treffen zu können, insbesondere im Vergleich gegenüber sogenannter “Baselines” (Modelle ohne KI).

Lösungsweg und Ergebnisse

Das Gerber2Layer-KI-Modell, wurde sowohl qualitativ als auch quantitativ evaluiert und getestet. Auf dem Test-Datensatz wurde eine “Balanced Accuracy” von 52.95% erzielt. Dies entspricht einer Verbesserung von 42.85% gegenüber der Baseline von 9.10% wenn immer dieselbe Klasse (in diesem Fall SoldermaskTop mit 38 Beispielen) vorhergesagt würde.

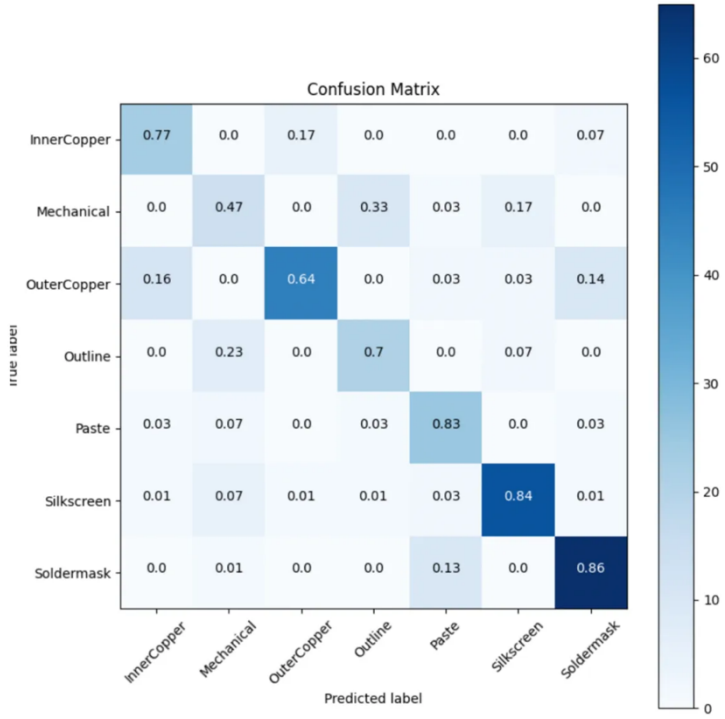

Abbildung 3: Konfusionsmatrix für die Evaluation des Gerber2Layer-KI-Modelles auf dem Test-Datensatz.

Für den PCB Panel Counter wurden unterschiedliche Evaluierungsmetriken (qualitativ wie quantitativ) implementiert. Dies beinhaltet einen “Confusion Scatter Plot” für eine binäre Klassifikation, sowie Metriken wie Regression Accuracy, ROC AUC Average, F1-Score, Average Precision und R^2.

Nach Auswertung wurde das beste Modell als ein RandomForest-Classifier festgestellt (mit einer Accuracy von 98.8%). Die beiden Abbildungen zeigen die Ergebnisse der finalen Auswertung.

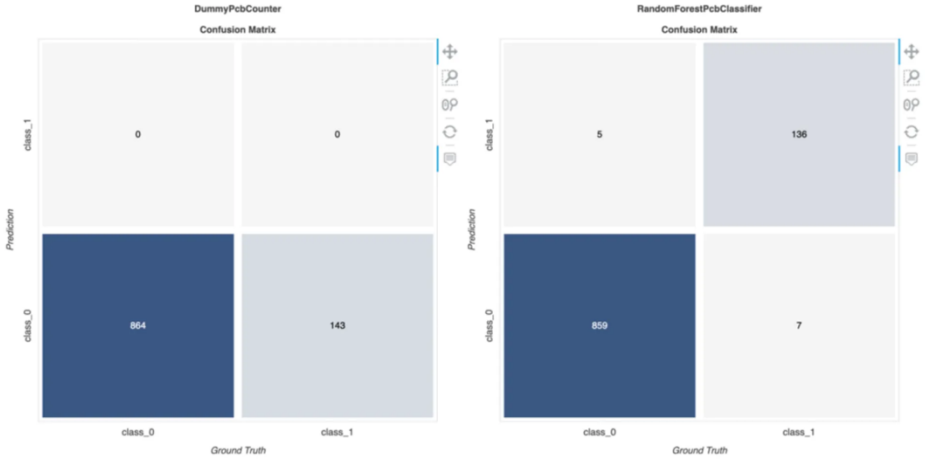

Abbildung 3: Confusion Matrix für das beste trainierte Modell vs eine Dummy Baseline

Scores (higher is better)

Quantity	DummyPcbCounter	RandomForestPcbClassifier
Regr. Accuracy	0.858	0.866
R^2	-0.039	-0.010
Explained Variance	0.000	0.024
Accuracy	0.858	0.988
ROC AUC Macro Average	0.500	0.994
ROC AUC Micro Average	0.858	0.998
F1-Score Macro Average	0.462	0.975
F1-Score Micro Average	0.858	0.988
ROC AUC class_0 vs Rest	0.500	0.994
ROC AUC class_1 vs Rest	0.500	0.994
Average Precision class_0 vs Rest	0.858	0.998
Average Precision class_1 vs Rest	0.142	0.983
F1-Score class_0 vs Rest	0.924	0.993
F1-Score class_1 vs Rest	0.000	0.958

Abbildung 4: Auswertung der implementierten Metriken des besten Modells vs eine Dummy Baseline

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

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

Teilbeitrag 4.1.7: Integration der entwickelten KI-Module für die automatisierte Extraktion von Bild-, Text- und Tabellen-Informationen aus Datenblättern in Plattform Anwendungsebene #1 (07-LUMI)

Ziele

Integration der entwickelten KI-Module für die automatisierte Extraktion von Bild-, Text- und Design-for-Manufacturing-Informationen aus Gerber-Dateien in die Anwendungsebene. Implementierung geeigneter Schnittstellen zur Übermittlung der Eingangs- und Ausgangsdaten.

Problemstellung

Zur Demonstration der Anwendungsfälle und Einbindung in andere Software-Applikationen muss ein Demonstrator mit Front- und Backend implementiert werden.

Lösungsweg und Ergebnisse

Erste mögliche Anwendung und Integration eines Gerber-Layer-Klassifizerungsalgorithmus in ein Leiterplatten-Software-Produkt, wie Stackrate, wurde konzipiert und implementiert (Frontend wurde web-basiert entwickelt, mit React und Typescript, und das Backend zum Deployment des Algorithmus wurde mit dem Frontend verknüpft um einen präsentierfähigen Demonstrator auf die Beine zu stellen). Analog wurde ein Prototyp für den PCB Panel Counter Anweundungsfall konzipiert und implementiert (etwas simpler als der Gerber2Layer-Demonstrator, mit der Möglichkeit zur Demo im Jupyter Notebook).

3.5 Arbeitspaket 5: Projektmanagement & Dissemination

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

Teilbeitrag 5.2.7: Ergebnistest via assoziierten Partnern (07-LUMI)

Ziele

Mittels dreistufigem Ansatz zur Umsetzung der progressivKI F+E Nutzungsplanung und F+E Ergebnisverbreitung werden weitere assoziierte Partner adressiert. Zur Ermittelung der F+E Nutzungspotentiale werden individuelle Forschungsergebnisse auf einschlägigen Konferenzen veröffentlicht.

Problemstellung

Test und Feedback einsammeln mit internen und externen Partnern um die Sinnhaftigkeit und Verwertungschancen des Projektes besser abschätzen zu können.

Lösungsweg und Ergebnisse

Vor der Festlegung auf den ersten Andwendungsfall im UseCase #07 wurde gemeinsam mit Hotoprint und Binder Elektronik die Sinnhaftigkeit einer automatisierten Gerber-Layer-Klassifikation analysiert: “Würde so etwas im Alltag wirklich Arbeit abnehmen?”. Zudem wurde eine qualitative Status-Quo Analyse bzgl. der Häufigkeit des Anwendungsfalls, dass Gerber-Layer mit existierenden Heuristiken nicht zugeordnet werden können. Eine quantitativere Analyse ist geplant, sobald ein erstes Machine Learning Modell fertig und im Einsatz ist.

Nach der Festlegung auf den ersten Anwendungsfall im UseCase #07 wurde gemeinsam mit Hotoprint ein erstes gelabeltes Datenset aus echten Gerber-Dateien erstellt, dass zur Evaluation unser KI-Algorithmen genutzt werden kann. Die Durchführung der Analyse steht noch aus.

Im UseCase #07 wurde anhand der qualitativen Evalulation und Testen der existierenden KI-Modelle gemeinsam mit Binder (noch vor Ausscheiden) eine Erweiterung der existierenden Pipelines um den PCB Panel Counter als mögliche Verbesserung identifiziert.

Es wurde zudem ein erster Test der PCB-KI-Modelle mit externen Partnern sowie BetaLayout und SafePCB durchgeführt. Dies sind Leiterplattenhersteller aus Deutschland und Frankreich, die mit ihrer Expertise gutes Feedback auf die Funktion und wirtschaftliche Verwertbarkeit der KI-Modelle geben konnten.

Zu guter Letzt wurde ein weiter Test des Prototypen mit dem externen Partner SIIX durchgeführt. Dies ist ein Elektronikfertiger aus Japan, der mit seiner Expertise weiter gutes Feedback auf die Funktion und wirtschaftliche Verwertbarkeit der KI-Modelle geben konnte.

4 Verwertung und voraussichtlicher Nutzen

07-LUMI

Ausgangslage

Vor Beginn von progressivKI gab es aufgrund der Unsicherheit bzgl. der Erfolgschancen eines PCB Panel Counters und Gerber2Layer-Klassifizierungsalgorithmus keine ganz konkreten Pläne oder Absichten die Ergebnisse der Forschung in Luminovos Produkt zu verwerten. Die Hoffnung war es durch positive Forschungsergebnisse weiteres Investment rechtfertigen zu können und die im Rahmen von progressivKI erarbeiteten Forschungsergebnise in ein neues Produkt-Modul überführen zu können, dass in der Elektronikindustrie sowohl an PCB-Hersteller, als auch Elektronikfertiger (EMS) und OEMs vertrieben werden könnte.

Ergebnisse in progressivKI

Es wurden im Berichtszeitraum keine Erfindungen gemacht und Schutzrechte weder angemeldet noch erteilt. Trotzdem wurden Fortschritte mit zwei konkreten Anwendungsfällen (Gerber2Layer, PCB Panel Counter) erzielt und die Grundlage für eine technische und wirtschaftliche Verwertbarkeit gelegt. Im Zusammenklang legen die KI-Modelle des Gerber2Layer und des PCB Panel Counter Anwendungsfalls die Grundlage für eine automatisierte Verarbeitung von Gerber-Dateien. Konkret können die Lagenzuordnung und Erkennung der Anzahl Leiterplatten genutzt werden um zwei wichtige, sonst von Menschen manuell vollzogene Schritte, zu automatisieren.

Trotzdem wurden einige Fortschritte mit zwei konkreten Anwendungsfällen (Gerber2Layer, PCB Panel Counter) erzielt und die Grundlage für eine technische und wirtschaftliche Verwertbarkeit gelegt.

Nutzen und Verwertbarkeit

Die wissenschaftlichen und/oder technische Erfolgsaussichten nach Projektende werden auf der Grundlage der erzielten F+E-Ergebnisse mit gut bewertet. Ebenso weren die wissenschaftliche und wirtschaftliche Anschlussfähigkeit des Teilvorhabens mit gut bewertet. Eine Einbindung der wissenschaftlichen Ergebnisse nach Ablauf des Projektes in die Software von Luminovo wird als sinnvoll und wahrscheinlich bewertet. Bei Luminovo entwickeln und vertreiben wir Algorithmen zur automatischen Bepreisung von Leiterplatten. Hierzu müssen alle preisrelevanten Parameter automatisch aus Gerber-Dateien extrahiert werden und dies ist nur möglich wenn die Lagenzuordnung und Erkennung der Anzahl Leiterplatten korrekt ist. Der große Nutzen der Ergebnisses dieses Forschungsprojektes sind daher die Ausweitung der addressierbaren Anwendungsfälle unserer vertriebenen Algorithmen. Mit Gerber2Layer und dem PCB Panel Counter können theoretisch alle Gerber-Dateien automatisiert verarbeitet werden und nicht nur die wo wir schon vorab (aufgrund menschlichen Inputs) die Lagenzuordnung und Anzahl Leiterplatten kennen. So kann z.B der gesamte Service (Extrahierung der preis-relevanten Leiterplatten) als API-Schnittstelle an Leiterplattenhersteller zur Verfügung gestelllt und wirtschaftlich verwertet werden.

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“, xxxxxxxxxxxxxxx, xxxxxxxxxxxxxxxxxxxxxxx

(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“, xxxxxxxxxxxxxxxx, xxxxxxxxxxxxxxxxxxxxxxx

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

2023

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

2024

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

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

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

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

(65) Jad Maalouly, Dennis Hemker, Christian Hedayat, Marcel Olbrich, Sven Lange, and Harald Mathis: “Using Autoencoders to Classify EMC Problems in Electronic System

Development”, Adv. Radio Sci., 22, 53–59, https://doi.org/10.5194/ars-22-53-2024, 2024J. 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.

(68)

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: Automatische KI-basierte Analyse von Tabellen, Skizzen und Textelementen

4. Autor(en) [Name(n), Vorname(n)]	5. Abschlussdatum des Vorhabens
Ruban, Timon	30.09.2024
	6. Veröffentlichungsdatum
	7. Form der Publikation Schlussbericht
8. Durchführende Institution(en) (Name, Adresse) Luminovo GmbH 80799 München	9. Ber. Nr. Durchführende Institution
	10. Förderkennzeichen 19A21006G
	11. Seitenzahl 30
12. Fördernde Institution (Name, Adresse) Bundesministerium für Wirtschaft und Klimaschutz (BMWK) 53107 Bonn	13. Literaturangaben 67
	14. Tabellen 2
	15. Abbildungen 4

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: Automatic AI-based analysis of tables, sketches and text elements

4. author(s) (family name, first name(s))	5. end of project
Ruban, Timon	30.09.2024
	6. publication date
	7. form of publication Final Report
8. performing organization(s) (name, address) Luminovo GmbH 80799 München	9. originator's report no.
	10. reference no. 19A21006G
	11. no. of pages 30
12. sponsoring agency (name, address) Bundesministerium für Wirtschaft und Klimaschutz (BMWK) 53107 Bonn	13. no. of references 67
	14. no. of tables 2
	15. no. of figures 4

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