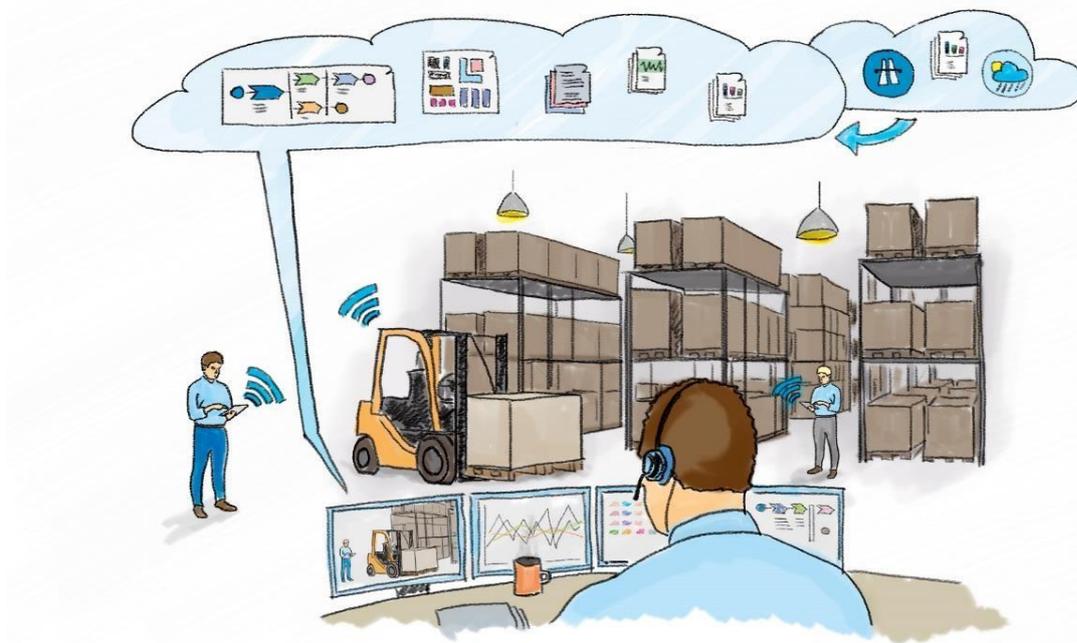


Forschungsprojekt für den Forschungsmaster Data Science

Projekttitle: 1 Entscheidungsunterstützung in Produktion und Logistik mittels Reinforcement Learning



Projektübersicht

Anzahl Studierende	1
Art (gefördertes Projekt, Projekt mit externen Partnern, Projekt, Studienprojekt)	Studienprojekt
Projektverantwortung	Prof. Dr.-Ing. Christian Schwede
Projektkontext	Projekt in Zusammenarbeit mit dem betreuenden Professor als Vorbereitung auf eine mögliche Konsortialforschung in dem Kontext.

Abstrakt

Zur Planung von komplexen Produktions- und Logistiksystemen werden immer häufiger Simulationsmodelle eingesetzt, um die Auswirkungen von Entscheidungen (z.B. Ressourcenpläne, Produktionsprogramme, Engpassmaßnahmen) detailliert evaluieren zu können. In dem hier beschriebenen Projekt soll mittels Reinforcement Learning die Erstellung der Entscheidungsszenarien, durch eine Künstliche Intelligenz automatisiert werden. Das Verfahren des maschinellen Lernens kann hierbei die Simulation als Trainingsumgebung verwenden.

Kurzbeschreibung

Zur Planung von komplexen Produktions- und Logistiksystemen werden immer häufiger Simulationsmodelle eingesetzt, um die Auswirkungen von Entscheidungen (z.B. Ressourcenpläne,

Produktionsprogramme, Engpassmaßnahmen) detailliert evaluieren zu können. Diese Modelle werden neuerdings mit digitalen Echtzeitabbildern der Produktions- und Logistiksysteme sogenannten „Digitalen Zwillingen“ verbunden. Dadurch können die Modelle auch in der kurzfristigen Planung und Echtzeitsteuerung eingesetzt werden. Kommt beispielsweise eine wichtige Lieferung zu spät zur Fabrik, so können die Auswirkungen mit der Simulation auf Basis der Echtzeitdaten des digitalen Zwilling adhoc bewertet und Gegenmaßnahmen überprüft werden.

Neben der aufwändigen Erstellung der Simulationsmodelle ist der Entscheidungsprozess bis heute im Wesentlichen manuell. Entscheidungsszenarien werden händisch im Entscheidungsunterstützungssystem erstellt, von der Simulation bewertet und dann erneut händisch angepasst.

In dem hier beschriebenen Projekt soll mittels Reinforcement Learning die Erstellung der Entscheidungsszenarien, durch eine Künstliche Intelligenz automatisiert werden. Das Verfahren des maschinellen Lernens kann hierbei die Simulation als Trainingsumgebung verwenden. Es erzeugt Eingabe und erhält durch die Simulation Feedback über deren Güte. Auf diese Weise können einerseits Entscheider durch intelligente Vorschläge unterstützt und andererseits perspektivisch weniger schwerwiegende Entscheidungen vollständig autonom getroffen werden.

Aufgabenstellung

Der/ die Studierende wird für ein vorgegebenes Produktions-/Logistiksystems ein Simulationsmodell mit der Simulationssoftware Siemens Plant Simulation erzeugen. Dieses Modell wird als Grundlage für die Entwicklung eines Verfahrens des Reinforcement Learning dienen, das Lernen soll für bestimmte Rahmenbedingungen optimale Entscheidungsszenarien zu generieren.

Bezug zum Thema Data Science

Verfahren des Reinforcement Learning sind ein Kernthema der Data Science und werden auch in den Veranstaltungen des Forschungsmasters behandelt.

Verfügbare Ressourcen

- Informationen, die zur Erstellung des Simulationsmodells benötigt werden (Systembeschreibung, Durchlaufzeiten, Kapazitäten, etc.) werden vom betreuenden Professor bereitgestellt
- Siemens Plant Simulation wird im Kontext des AI-Labs der FH Bielefeld bereitgestellt
- Hardware für das Reinforcement Learning ist über das Data Science Lab oder das CfADS der FH Bielefeld verfügbar

Projektplan

Erstes Semester: Formulierung des Forschungsexposees, Einarbeitung in Plant Simulation, Sammeln der notwendigen Information zur Erstellung des Simulationsmodells

Zweites Semester: Erstellung eines einfachen Simulationsmodells, Recherche zu relevanten Arbeiten in Themenfeld der Kopplung von Simulation und Maschinellen Lernen

Drittes Semester: Entwicklung von ersten Verfahren des Maschinellen Lernens, Entwicklung einer Schnittstelle zu Plant Simulation, Auswertung erster Ergebnisse

Viertes Semester: Erstellung eines komplexen Simulationsmodells, Implementierung und Vergleich von weiteren Verfahren, Fine-Tuning und Optimierung der Verfahren, Verbesserung der Ergebnisse, Finale Evaluierung

Eignungskriterien

Zwingend:

- Programmierkenntnisse

Optional:

- Simulationserfahrung
- Erfahrung mit Produktions- und Logistiksystemen

Erwerbbarere Kompetenzen

- Einsatz von Verfahren des Reinforcement Learnings
- Ereignisdiskrete Materialflusssimulation mit Plant Simulation
- Planung von Produktions- und Logistiksystemen

Forschungsprojekt für den Forschungsmaster Data Science

Projekttitle: 2 Digitale Zwillinge lernen



Projektübersicht

Anzahl Studierende	1-3
Art	Projekt mit externen Partnern
Projektverantwortung	Prof. Dr.-Ing. Christian Schwede
Projektkontext	Projekt in Zusammenarbeit mit dem Fraunhofer Institut für Software- und Systemtechnik (ISST) in Dortmund und im Kontext des Center for Applied Data Science (CfADS) sowie des Institute for Data Science Solutions (IDaS) ; Anstellung als Hiwi bei Fraunhofer ist möglich

Abstrakt

Ziel des Projektes ist es simulationsbasierte Digitale Zwillinge zur Planung und Steuerung von Produktions- und Logistikumgebungen aus IoT-Daten zu lernen. Hierbei wird auf dem vom der HSBI und dem Fraunhofer ISST erstellten Open-Source-Framework OFacT aufgebaut und dieses erweitert. Die Daten stammen aus Kundenprojekten von Fraunhofer und der IoT-Factory des CfADS. Zum Einsatz kommen neben Process Mining Methoden auch generative Modelle wie Large Language Models (LLMs).

Kurzbeschreibung

Digitale Zwillinge sind der Schlüssel zur optimalen Gestaltung, Planung und Steuerung von Produktions- und Logistikumgebungen. Diese Softwareframeworks erlauben den Zugriff auf ein stets aktuelles digitales Abbild des Systems, ermöglichen die Optimierung und Simulation von Szenarien in

dieser virtuellen Umgebung und vermitteln Änderungen mittels Arbeitsanweisungen direkt zurück an den Shop Floor. So können Entscheidungen in allen Lebensphasen des Systems evaluiert und optimiert werden, bevor sie getroffen werden. Sowohl langfristige Veränderungen am System als auch Reaktionen auf kurzfristige Störungen können optimal umgesetzt werden. Das Potential für

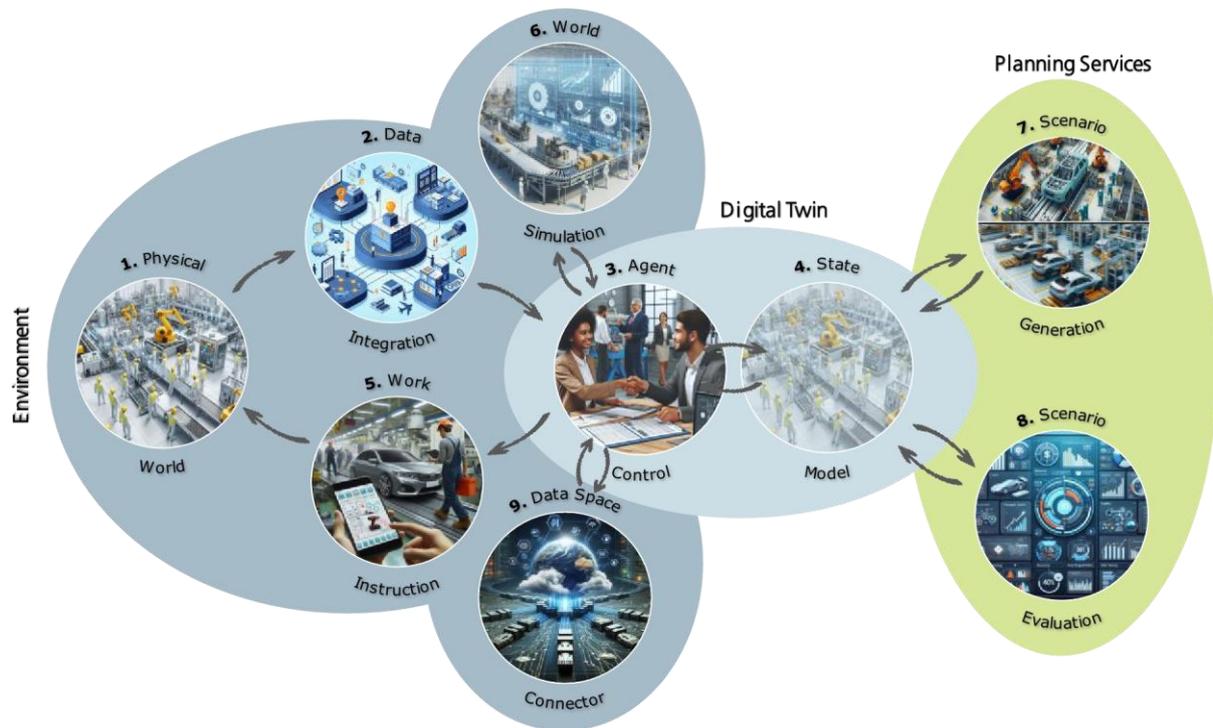
Unternehmen wird hierbei als sehr hoch eingeschätzt (prognostiziertes Marktvolumen von 10 Milliarden US \$ in 2028¹). Das Fraunhofer ISST und die HSBI haben das Open-Source-Framework OFact (Open Factory Twin) erstellt, das es insbesondere kleinen und mittelständische Unternehmen erlaubt ihre Produktionssysteme zu digitalisieren.



OFact basiert auf einem standardisierten Zustandsmodell, mit dem beliebige diskrete Materialflusssysteme abgebildet werden können. Über das Datenintegrationsmodul können beliebige

Datenschnittstellen angesprochen werden. Die Steuerung des Systems wird durch ein Multi-Agenten-System übernommen, so dass Steuerungsregeln hochflexible und getrennt von Zustandsmodell abgebildet und verändert werden können. Die Agenten übernehmen auch die Steuerung des Materialflusssysteme mittels Arbeitsanweisungen.

¹ Bain & Company: Global Machinery & Equipment Report 2024



Als Umgebung kann das Framework auf eine simulierte Realität zurückgreifen, um z.B. Szenarien zu evaluieren. Planungsservices erlauben die Erstellung und Optimierung von Handlungsalternativen und ein Dashboard die Auswertung anhand von Standard-Kennzahlen.

Eine wichtige Hürde bei der Implementierung von Digitalen Zwillingen in kleinen und mittelständischen Unternehmen sind die Kosten, die durch das manuelle Modellieren durch Experten entstehen. Diese Kosten fallen nicht nur bei der Erstellung, sondern auch bei der regelmäßigen Aktualisierung an. Das Ziel dieses Projektes ist es deshalb Digitalen Zwillinge aus Daten der Unternehmen zu lernen.

Aufgabenstellung

Der/die Studierende soll in dem Projekt Verfahren aus dem Bereich des Maschinellen Lernens nutzen, um Modelle von OFacT auf Basis von Daten von Produktionsumgebungen zu lernen. Die IoT-Daten oder auch Event-Logs vom Shop Floor der Unternehmen enthalten häufig schon viele der benötigten Informationen. Genutzt werden können Daten aus existierenden Industrieprojekten vom Fraunhofer ISST oder von der IoT-Factory am Campus Gütersloh. Neben Methoden des Process Mining, werden Regressions- und Klassifikationsverfahren z.B. auf Basis von tiefen Neuronalen Netzen eingesetzt. Zudem soll untersucht werden, inwieweit Teile der Modelle auch mit aktuellen Large Language

Models (LLM) erstellt werden können. Hierzu kann es sinnvoll sein, Retrieval-Augmented Generation (RAG) zu nutzen, um die LLM mit domainspezifischen Informationen zu versorgen.

Bezug zum Thema Data Science

Die verwendeten Methoden der Regression und Klassifikation, sowie LLM und RAG sind Bestandteil der Veranstaltung im Forschungsmaster und Kernbereiche der Data Science.

Verfügbare Ressourcen

- Daten werden über das Fraunhofer ISST und die IoT-Factory bereitgestellt

- Das Open-Source-Framework OFacT wird an der HSBI entwickelt und ist verfügbar
- Hardware für Maschine Learning ist über das Data Science Lab, das CfADS, sowie dem KI-Rechencluster yourAI der HSBI verfügbar

Projektplan

Erstes Semester: Erstellung eines Forschungsexposés als Prüfungsleistung. Einarbeitung in die Aufgabenstellung und das Framework OFacT.

Zweites Semester: Literaturrecherche zur Generierung von Modellen mithilfe von Verfahren des maschinellen Lernens, insbesondere LLMs und RAG. Sichtung der Datensätze und Anwendung erster einfacher Verfahren des Process Mining und existierender Sprachmodelle. Erstellung eines Papers, das einen Überblick über das Forschungsgebiet gibt, ist Prüfungsleistung.

Drittes Semester: Praktische Umsetzung der eigenen Lösung und Generierung eines OFacT-Modells für einen konkreten Anwendungsfall. Veröffentlichung eines Papers mit den ersten Ergebnissen ist Prüfungsleistung.

Viertes Semester: Masterarbeit und Kolloquium. Finale Evaluierung durch Vergleich verschiedener Verfahren.

Eignungskriterien

Zwingend:

- Programmierkenntnisse (vzw. Python)

Optional:

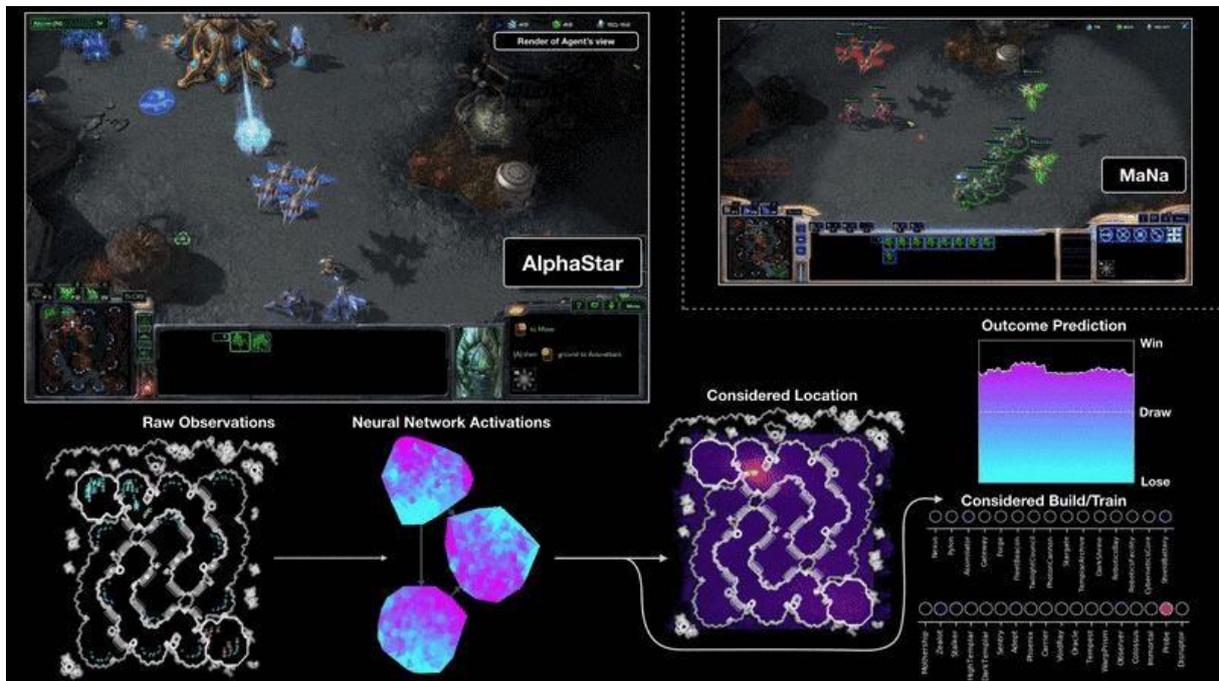
- Erfahrung mit Maschinellem Lernen
- Erfahrung mit LLMs

Erwerbbarer Kompetenzen

- Entwicklung und Verwendung von Digitalen Zwillingen
- Generierung von Modellen mittels LLMs und RAG
- Publikation von wissenschaftlichen Veröffentlichungen auf internationalen Konferenzen
- Kompetenzen in der Arbeit im Team - Open-Source Entwicklung

Forschungsprojekt für den Forschungsmaster Data Science

Projekttitle: 3 Interpretierbare und übertragbare KI für StarCraft2



Projektübersicht

Startsemester (von-bis)	WiSe2019/20-SoSe2021
Anzahl Studierende	1-3
Art (gefördertes Projekt, Projekt mit externen Partnern, Studienprojekt)	Studienprojekt
Projektverantwortung	Prof. Dr.-Ing. Christian Schwede
Projektkontext	Das Studienprojekt ist am Digital Labor des Campus Gütersloh angesiedelt. Das Team besteht aus einem Wissenschaftlichem Mitarbeiter und zwei weiteren Studierenden.

Abstrakt

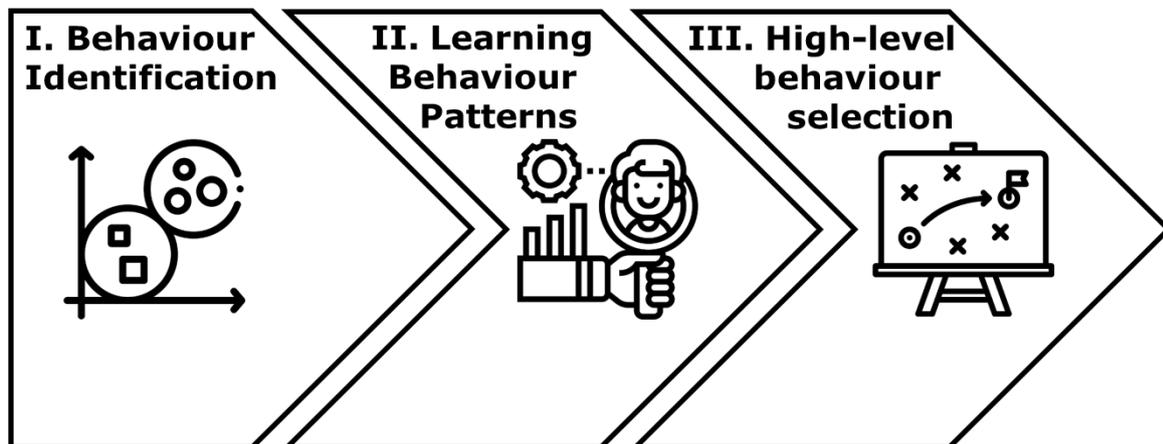
In diesem Projekt wird u.a. mittels cutting-edge Verfahren des Deep Reinforcement Learnings an einer Künstlichen Intelligenz für StarCraft2 gearbeitet, die Wissen bewertbar und übertragbar macht und zudem für Menschen nachvollziehbar ist (Explainability).

Kurzbeschreibung

Computerspiele stellen schon seit den Anfängen der Künstlichen Intelligenz eine spannende Herausforderung für die Entwicklung von Intelligenten Agenten dar. Große Durchbrüche der KI-Forschung zeigten sich häufig durch die Entwicklung von Programmen, die in der Lage waren, menschliche Gegenspieler zu besiegen. Deep Blue schlug 1996 den amtierenden Weltmeister Kasparow im Schach, IBMs Watson gewinnt 2011 in „Jeopardy!“ gegen zwei gegen zwei Profis und Googles AlphaGo schlägt 2016 Lee Sedol einen der weltbesten Go-Spieler. Seit 2019 spielt Deepminds AlphaStar in den diversen Ligen von Starcraft2 und besiegt mittlerweile 99,8% der Spieler. Auch wenn

diese KI hinsichtlich der Performanz unübertroffen ist, so erfüllt sie zwei andere wichtige Anforderungen an KI kaum: Übertragbarkeit/Lerneffizienz und Erklärbarkeit. Auf dem Weg zur Starken KI ist die Lerneffizienz bzw. die Übertragbarkeit und das nicht Vergessen von Wissen entscheidend, während für uns Menschen der Einblick in das Was und Warum des Handelns von KI von entscheidender Bedeutung ist.

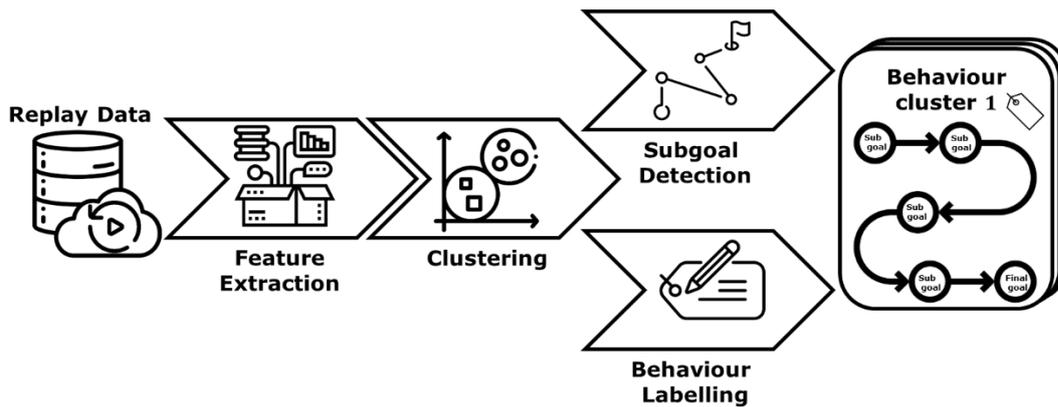
In diesem Projekt wird deshalb an einer Künstlichen Intelligenz für StarCraft2 gearbeitet die diese beiden Anforderungen erfüllt. Die Grundidee ist es eine KI zu entwickeln die lernt je nach Situation einen passenden Handlungsbaustein (Strategie) und nicht nur eine einzelne Aktion auszuwählen. So kann Wissen in den Bausteinen bewahrt werden und komplexe Handlungen durch die Kapselung in Strategien erklärbarer werden. Hierbei sollen die einzelnen Strategiebausteine auf Basis von Beispielpartien erst erkannt und dann gelernt werden. Durch die zusätzliche Konstruierung eines Subziel-Graphen, der die Zwischenziele einzelner Strategiebausteine in Reihenfolge bringt, werden diese dann für Menschen nochmal erklärbarer. Der gesamte Ansatz ist in drei Teilschritte unterteilt und in folgender Grafik dargestellt. Als erstes werden aus Beispieldaten Strategiecluster mittels Zeitreihenclusterings gelernt, dann wird auf Basis von diesen Clustern mittels Supervised oder Reinforcement Learning Strategiebausteine gelernt und schließlich findet mittels Hierarchical Reinforcement Learning die High-Level Strategie gelernt.



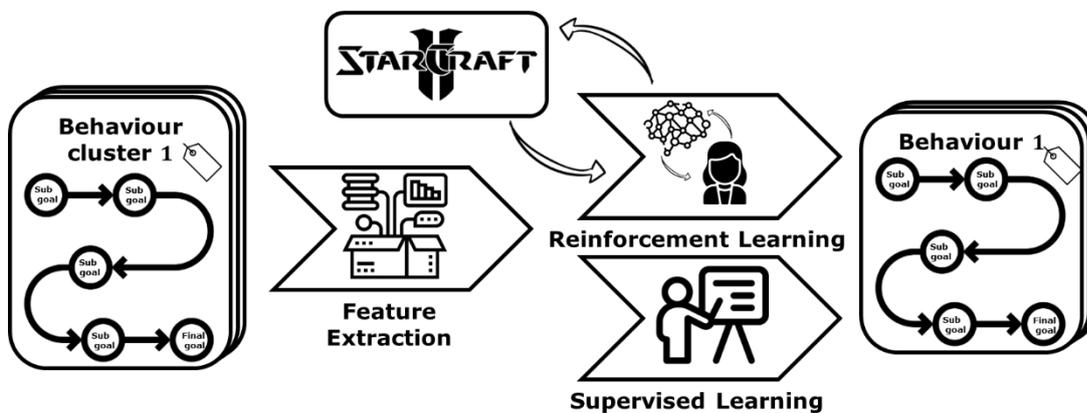
Aufgabenstellung

Die Studierenden können je nach Interesse in einem der oben beschriebenen Teilbereiche arbeiten. Der Schwerpunkt der Arbeit kann dabei einen der drei genannten Verfahrensgruppen betreffen.

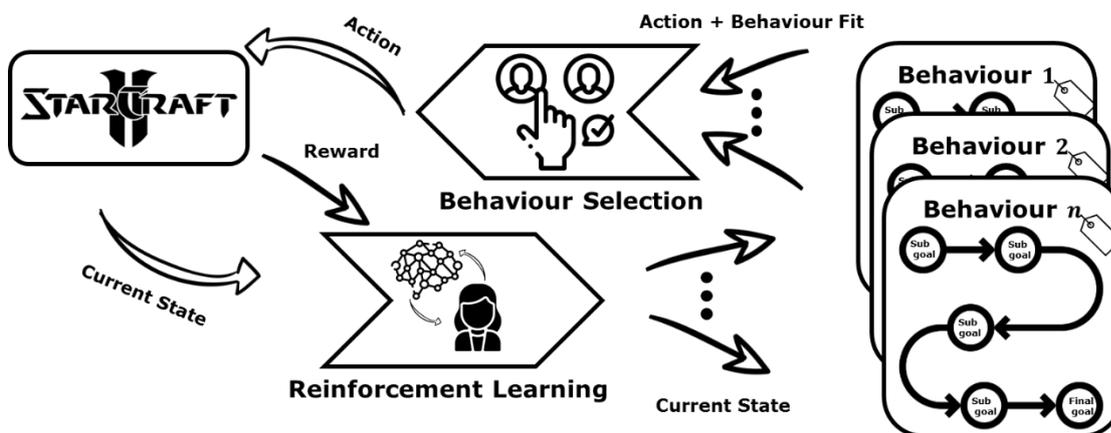
Der erste Bereich der Strategieerkennung wird hauptsächlich mit Clusterverfahren arbeiten. Aufgaben der Merkmalsextraktion im variablen und hochdimensionalen Eingaberaum von StarCraft2, der Auswahl von passenden Distanzmetriken, die Auswahl und Implementierung von Clusterverfahren für variable Zeitreihen, der Entwicklung von Verfahren für die Erkennung von Teilzielen und das automatische Labelling können bearbeitet werden.



Der zweite Bereich kann entweder Verfahren des Supervised oder des Deep Reinforcement Learnings umfassen. Überwachte Verfahren werden genutzt, um das Verhalten der geclusterten Strategien nachzuahmen, während Verstärkendes Lernen ein eigenes Verhalten anhand der Subgoals lernen soll.



Der Dritte Bereich umfasst Verfahren des Hierarchical Reinforcement Learnings. Hierbei muss erlernt werden den passenden Strategiebaustein für die jeweilige Situation auszuwählen. Außerdem muss das Auswahlverhalten derart beeinflusst werden, dass die Strategie nicht nach jeder Aktion neu gewählt wird.



Bezug zum Thema Data Science

Verfahren des Clustering, Supervised und Reinforcement Learning sind Kernthemen der Data Science und werden auch in den Veranstaltungen des Forschungsmasters behandelt.

Verfügbare Ressourcen

- Millionen von Replay-Daten und eine Python-API für StarCraft2 stehen zur Verfügung
- Hardware für das Maschine Learning ist über das Data Science Lab oder das CfADS der FH Bielefeld verfügbar

Projektplan

Erstes Semester: Formulierung des Forschungsexposees, Einarbeitung in das Spiel, den Source Code und die API.

Zweites Semester: Entwicklung eines einfachen Algorithmus in dem jeweiligen Feld für ein einfaches Spielszenario, Recherche zu relevanten Arbeiten im Themenfeld

Drittes Semester: Entwicklung von ersten komplexeren Verfahren für einfachere und komplexere Spielszenarien, Auswertung erster Ergebnisse

Viertes Semester: Erstellung eines komplexen Szenarios, Implementierung und Vergleich von weiteren

Verfahren, Fine-Tuning und Optimierung der Verfahren, Verbesserung der Ergebnisse, Finale Evaluierung

Eignungskriterien

Zwingend:

- Programmierkenntnisse
- Begeisterung für Spiele/ StarCraft2 und KI

Optional:

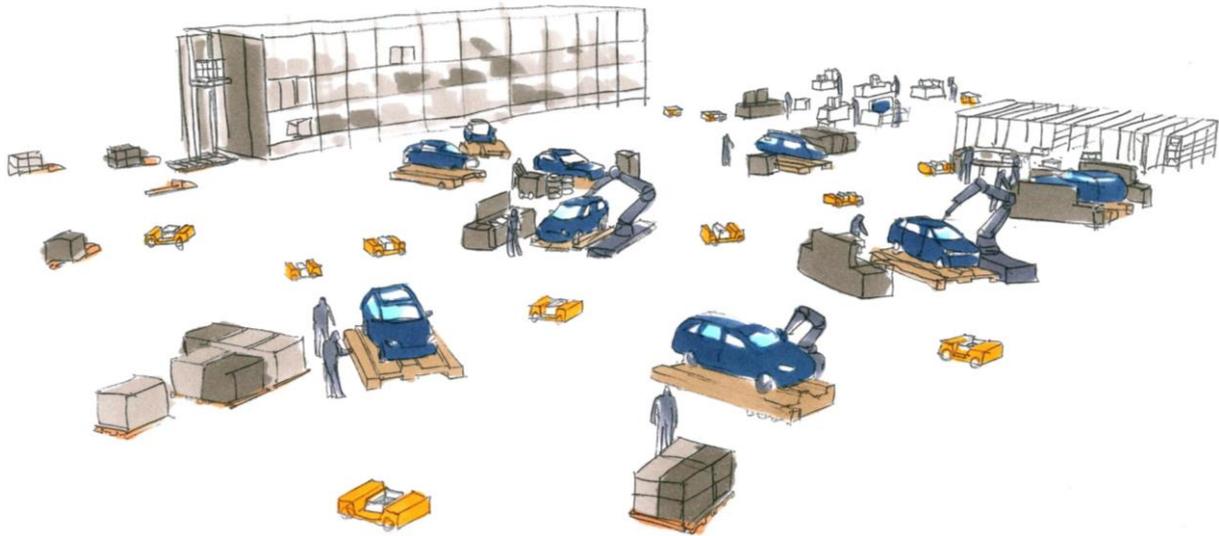
- Erfahrung in ML

Erwerbbarer Kompetenzen

- Einsatz und (Weiter-)Entwicklung von State-of-the-Art Verfahren des Maschinellen Lernens in hochkomplexen Umgebungen

Forschungsprojekt für den Forschungsmaster Data Science

Projekttitle: 4 KI für die hochflexible variantenreiche Massenproduktion



Projektübersicht

Anzahl Studierende	1
Art (gefördertes Projekt, Projekt mit externen Partnern, Projekt, Studienprojekt)	Projekt mit externen Partnern
Projektverantwortung	Prof. Dr.-Ing. Christian Schwede
Projektkontext	Projekt in Zusammenarbeit mit dem Fraunhofer-Institut für Software- und Systemtechnik (ISST) in Dortmund und im Kontext des Center for Applied Data Science (CfADS) sowie des Institute for Data Science Solutions (IDaS) ; Anstellung als Hiwi bei Fraunhofer ist möglich;

Abstrakt

Die stetige Individualisierung der Produkte stellt nicht nur die deutsche Automobilproduktion vor Herausforderungen, die ein vollständiges Umdenken in der Produktionsorganisation erzwingen. Weg von getakteter Fließfertigung hin zur dezentralen Matrixproduktionssystemen. Schwärme von autonomen Robotern koordinieren hier die Wertschöpfungsprozesse und passen sich flexible an die aktuelle Situation an. Während die Grundidee des Konzeptes klar umrissen ist, ergeben sich im Detail noch sehr viele offene Forschungsfragen, die insbesondere das Verhalten der einzelnen Roboter betrifft. Hier setzt das Projekt an und erforscht unterschiedliche Strategien der KI in einem virtuellen Testbed.

Kurzbeschreibung

In der sogenannten Matrixproduktion wird die Produktion dezentral von Software-Agenten in einem Multi-Agent-System (MAS) koordiniert. Die Ressourcen-Agenten verhandeln hierbei bspw. mit dem Auftragsagenten über die Erbringung von Wertschöpfungsprozesse, die für die Realisierung des Auftrages nötig sind. Die Freiheit der Reihenfolge der Fertigungsschritte wird hierbei nur durch

technische Eigenschaften des Produktes beschränkt. Auf diese Weise kann sich das gesamte System flexibel an nichtgeplante Vorfälle, wie bspw. einen Lieferengpass oder einen Maschinenausfall anpassen. Während dem Konzept in der Automobilindustrie zuerst mit Ablehnung und Skepsis begegnet wurde, gibt es seit ein paar Jahren intensive Bestrebungen, eine Operationalisierung zu erforschen und voranzutreiben. Grundsätzlich sind zu einem effizienten Einsatz noch zahlreiche Fragen offen die es zu erforschen gilt.

In der Forschungsgruppe der HSBI wird seit einigen Jahren in Kooperation mit dem Fraunhofer ISST in Dortmund das Open-Source Digital Twin Framework OFaCT (Open Factory Twin) entwickelt, das es unter anderem erlaubt mit agentenbasierter Simulation die hochflexiblen Matrixproduktionen zu modellieren und verschiedene Strategien und Designvarianten dynamisch zu bewerten. Das Tool ist außerdem als Digitaler Zwilling einsetzbar und kann über Sensordatenströme direkt mit der Produktion verbunden und zur Steuerung der operativen Prozesse genutzt werden.

Aufgabenstellung

Der/ die Studierende hat die Möglichkeit an einem der folgenden Themen zu arbeiten, um die Möglichkeiten und Limitationen der Matrixproduktion zu erforschen und neue Lösungskonzepte auf der Realisierung zum Stand der Technik beizusteuern.

Agentensteuerung für die dezentrale Produktion

Eine der entschiedensten offenen Fragen ist die der optimalen Steuerung der Agenten. Insbesondere die Synchronisation der Materialflüsse mit dem Hauptprodukt ist eine entscheidende, um Wartezeiten zu verhindern und gleichzeitig die Flexibilität zu erhalten. Die Entwicklung und Implementierung effizienter Steuerungsstrategien für das MAS ist hier die Kernaufgabe, die unter anderem die Frage beinhaltet ob und inwieweit in die Zukunft geplant und reserviert werden sollte. Methoden der Optimierung, Such und Planalgorithmen aus der KI oder Reinforcement Learning können hier eingesetzt werden.

Layoutdesign und -optimierung

Auch wenn der Begriff Matrixproduktion eine Gitternetzformige Anordnung der Produktionsstationen andeutet, so ist die Frage nach der optimalen Anordnung der verschiedenen Elemente der Matrixproduktion (Stationen, Lagerorte für Teile, Ladestationen der Transportfahrzeuge, Parkplätze zur Zwischenpufferung von Karosse usw.) noch nicht final entschieden. Optimierungsalgorithmen, die in Kombination mit der Simulation als Evaluierungsmethode eingesetzt werden müssen hier entwickelt werden, um für ein konkretes Produktionssetup das optimale Layout zu bestimmen. Auf die Frage wie stark das optimale Layout vom konkreten Auftragsmix abhängt ist relevant und könnte die Notwendigkeit einer regelmäßigen Überplanung des Layouts implizieren.

Routing und Stauanalyse

Die Entstehung von Staus vor den Produktionsstationen oder rauf den verschiedenen Wegen ist ein zentraler Aspekt der Effizienz des Gesamtsystems. Hierzu muss die Simulationsumgebung um ein Element der Routenplanung erweitert werden, das auch temporäre Routenkonflikte erkennt. KI-Suchalgorithmen aus dem Bereich der Wegfindung müssen implementiert und verschiedenen Strategien getestet werden. Schließlich müssen existierende Steuerungsstrategien und Layouts vor dem Hintergrund von Staus im System untersucht und bewertet werden.

Beschleunigung der Verhandlungen mittels Reinforcement Learning

Eine Schwachstelle von Multiagentensystemen ist das Kommunikationsaufkommen, dass durch die dezentralen Verhandlungen zwischen den Agenten entsteht. Hier gilt es Verhandlungsstrategien zu untersuchen, implementieren und zu vergleichen und insbesondere unnötige Kommunikation zu

vermeiden. Reinforcement Learning kann eingesetzt werden, um zu erkennen, wann Anfragen von Agenten nicht zielführend sind und so im Vorhinein vermieden werden können.

Agentenbasierte Wertschöpfungsnetzwerke

Die Einbindung der logistischen Prozesse aus dem Wertschöpfungsnetzwerk rund um die Produktion ist ein weiteres offenes Thema. Neben der Entwicklung geeigneter Ver- und Entsorgungsstrategien, die mit den Bedürfnissen der flexiblen Matrixproduktion übereinstimmen müssen, soll die visionäre Frage beantwortet werden, ob die dezentrale, autonome Wertschöpfung auch über die Fabrikgrenzen hinaus erweitert werden kann. Hierzu müssen die Agenten auf Basis von Geld als Zahlungsmittel Verträge mit Lieferanten und Dienstleistern verhandeln. Die entsprechenden Verhandlungsalgorithmen und Szenarien müssen umgesetzt und evaluiert werden.

Bezug zum Thema Data Science

Softwareagenten und Multiagentensysteme, Suchalgorithmen und Reinforcement Learning sind Kerngebiete der KI und werden in verschiedenen Veranstaltungen des Forschungsmasters thematisiert.

Verfügbare Ressourcen

- Das Framework OFaCT wird von dem HSBI und dem Fraunhofer ISST bereitgestellt
- Industriennahe Szenarien einer individuellen Fahrradproduktion existieren zur Validierung der Entwicklungen
- Szenarien von Industriekunden des ISST und der IoT-Factory in Gütersloh existieren ebenfalls zur Evaluierung einzelner Verfahren
- Hardware für das komplexere Machine Learning ist über das Data Science Lab oder das CfADS verfügbar

Projektplan

Erstes Semester: Formulierung des Forschungsexposees, Einarbeitung in das OFaCT-Framework, Auswahl des Themas.

Zweites Semester: Modellierung eines ersten Szenarios, Recherche zu relevanten Arbeiten in Themenfeld und Erstellung eines Reports zu Stand der Technik.

Drittes Semester: Implementierung und Evaluierung erster Verfahren, Auswertung erster Ergebnisse auf Basis des Szenarios, Verfassen eines Papers für eine (inter-)nationale Fachkonferenz.

Viertes Semester: Entwicklung weiterer Verfahren und Optimierung des Gesamtansatzes, Auswertung der Güte und Evaluierung der Ergebnisse in der Masterarbeit

Eignungskriterien

Zwingend:

- Programmierkenntnisse (optimal in Python)

Optional:

- Erfahrung mit Agentensystemen
- Erfahrung mit Simulation und Optimierung
- Hintergrundwissen zu Produktionslogistik und Produktionssystemen
- Erfahrung mit der Implementierung von Reinforcement Learning / ML-Verfahren

Erwerbbaare Kompetenzen

- Einsatz von Verfahren des Reinforcement Learnings
- Entwicklung und Bewertung von MAS
- Entwicklung von intelligenten Agenten
- Arbeiten mit Agentensimulationen
- Planung von Produktions- und Logistiksystemen insbesondere von
Martixproduktionssystemen und Industrie 4.0

Forschungsprojekt für den Forschungsmaster Data Science

Projekttitle: 5 Entwicklung eines Demonstrators für Active Learning am Beispiel des Spiels "Schiffe versenken"



Projektübersicht

Anzahl Studierende	1
Art	Studienprojekt
Projektverantwortung	Prof. Dr.-Ing. Martin Kohlhase; M.Sc. Bjarne Jaster
Projektkontext	Das Studienprojekt ist im Projekt SAIL (S ustainable AI L ifecycle) (sail.nrw) angesiedelt. SAIL ist eine Kooperation der Fachhochschulen und Universitäten aus OWL mit dem Ziel, KI nachhaltig zu gestalten.

Abstrakt

Das Thema Active Learning ist noch ein relativ unbekanntes Forschungsfeld, vor allem auf Anwenderseite. Daher zielt dieses Projekt darauf ab, einen Demonstrator zu entwickeln, der auch Laien die grundsätzliche Idee und wichtige Prinzipien von Active Learning näherbringt. Das Projekt SAIL bietet vielfältige Möglichkeiten zur Weiterbildung und ein großes Netzwerk innerhalb der Universitäten und Hochschulen in OWL. SAIL's Fokus liegt auf dem nachhaltigen Einsatz von KI vor allem über die Einführungsphase der KI hinaus. Dabei spielt das Thema Active Learning eine große Rolle.

Kurzbeschreibung

Active Learning kommt zum Einsatz, wenn eine KI entwickelt werden soll, aber noch kein brauchbarer Datensatz vorliegt. Dann geht es darum einen möglichst kleinen Datensatz zu erheben, der eine möglichst gute Datengrundlage für die KI darstellt. Dabei ergibt sich die Problemstellung, welche Datenpunkte besonders hilfreich zum Training eines KI-Modells sind. Active Learning Methoden lösen dieses Problem, indem sie ein Kriterium, das den Wert eines Datenpunkts beschreibt, definieren. Die Analogie zum Spiel „Schiffe versenken“ besteht darin, dass ein Spieler ein Feld angibt, das er für sinnvoll/wertvoll erachtet, und vom Gegenspieler das Label („Treffer“ oder „kein Treffer“) für dieses Feld erhält. Bei Active Learning basiert das Kriterium, das den Wert eines Datenpunkts beschreibt, häufig auf einem Explorations- und einem Exploitations-Faktor. Genau diese beiden Kriterien sind auch bei „Schiffe versenken“ wichtig. Erst wird das Spielfeld erkundet (Exploration), bis man einen Treffer erzielt, um anschließend die Umgebung, um den erzielten Treffer herum detaillierter abzusuchen (Exploitation). Ziel des Projekts ist es, das Explorations-Exploitations-Prinzip und damit die Grundlage von Active Learning anhand des Spiels „Schiffe versenken“ zu verdeutlichen.

Aufgabenstellung

Der / Die Studierende soll im Rahmen des Forschungsmasters das Spiel „Schiffe versenken“ implementieren und daran verschiedene Active Learning Prinzipien erproben und verdeutlichen. Dazu sollen verschiedene Active Learning Methoden identifiziert, verstanden, programmiert und in das Spiel integriert werden.

Bezug zum Thema Data Science

Es werden verschiedene Methoden der künstlichen Intelligenz (Machine Learning Methoden), die die Grundlage für einige Active Learning Methoden bilden, behandelt. Zusätzlich wird das Thema Active Learning allgemein behandelt, was besonders für industrielle Data Science Anwendungen von Bedeutung ist.

Verfügbare Ressourcen

Für die Bearbeitung des Projekts kann die Infrastruktur des CfADS Gütersloh genutzt werden, die aus folgenden Komponenten besteht:

- Data-Analytics-Cluster: rechenstarker Computercluster auf Basis des Hadoop-Frameworks
- Smart Service Lab: Labor zur Entwicklung von Smart Services und Assistenzsystemen auf Basis von Smart Devices.
- SAIL-Weiterbildungen in Form von Summer Schools und Vorlesungsreihen.

Projektplan

Erstes Semester: Einarbeitung in das Thema Active Learning. Dazu gehören Grundlagen über verschiedene Active Learning Ansätze sowie das Vorgehen bei der Evaluation von Active Learning. Erstellung eines Forschungsexposés ist Prüfungsleistung.

Zweites Semester: Entwicklung oder Anpassung einer existierenden Spielumgebung, um die Integration, Anwendung und Evaluierung der Active Learning Algorithmen zu ermöglichen. Zusätzlich soll prototypisch überlegt werden, wie der Demonstrator das Thema am besten veranschaulichen kann. Erstellung eines Papers, das einen Überblick über die Spielumgebung und die prototypischen Überlegungen gibt, ist Prüfungsleistung.

Drittes Semester: Integration verschiedener Active Learning Methoden in die Spielumgebung. Erstellung eines Papers, mit ersten qualitativen Ergebnissen ist Prüfungsleistung.

Viertes Semester: Entwicklung einer eigenen Active Learning Methode, die speziell für den Demonstrator und das Spiel angepasst wird. Die Masterarbeit inklusive Kolloquiums ist Prüfungsleistung.

Eignungskriterien

Zwingend:

- Grundkenntnisse Informatik & Künstliche Intelligenz / maschinelles Lernen
- Erfahrung in Python-Programmierung
- Teamfähigkeit und Interesse an wissenschaftlicher Arbeit
- Eigenständige Arbeitsweise Optional:
- Erfahrungen in den Bereichen der Mathematik, Statistik (Data-Science) und der Visualisierung von Daten und deren Zusammenhänge

Erwerbbarer Kompetenzen

Kompetenzen, die durch das Projekt erworben werden

- Maschinelle Lernverfahren, speziell im Bereich der Klassifikation und Regression
- Anwendung verschiedener Active Learning Methoden
- Aufbereitung und Präsentation von wissenschaftlichen Methoden und Ergebnissen -
Wissenschaftliches Arbeiten, Schreiben und Präsentieren

Forschungsprojekt für den Forschungsmaster Data Science

Projekttitle: 6 Maschinelle Intelligenz für die Erkennung von Anomalien, sowie die Prädiktion von Interaktionen, anhand von Bewegungsinformationen im Smart Home



Projektübersicht

Anzahl Studierende	1
Art	Projekt mit externen Partnern
Projektverantwortung	Prof. Dr.-Ing. Thorsten Jungeblut
Projektkontext	Projekt in Zusammenarbeit mit dem KogniHome - Technikunterstütztes Wohnen für Menschen e.V. in Bielefeld; Datensätze und Hardwareressourcen werden gestellt; Anstellung als wissenschaftliche Hilfskraft ist möglich; Über die Projektbearbeitung besteht die Möglichkeit der engen Zusammenarbeit mit Vereinsmitgliedern des KogniHome e.V., u.a. Bethel, Steinel, Hettich, HUM Systems, C&S GmbH uvm.

Abstrakt

Ziel des Projektes ist die Mitentwicklung eines Systems, das mittels KI-Verfahren das Nutzungsverhalten der Bewohner*innen eines Smart Homes erlernt, um anschließend, geeignete Handlungsempfehlungen bereitzustellen oder, bei der Erkennung von Anomalien, geeignete Maßnahmen einzuleiten. Wissenschaftliche Herausforderung des Projektes ist die Anwendung und Evaluation von maschinellen Lernverfahren zum Lernen von Interaktionsmustern basierend auf den gelieferten Daten der Minimal sensorik, sowie der Prädiktion zukünftiger Interaktion und der Anomalieerkennung.

Kurzbeschreibung

Die Digitalisierung dringt in immer weitere Lebensbereiche vor, und die damit verbundene Vernetzung von vielfältigen Komponenten des täglichen Umfelds führt zu einer Situation, in der ein stetig höherer Anspruch an die alltägliche Technik gestellt wird. Die Systeme sollen smarter werden, automatisiert und eigenständig handeln. Im Idealfall antizipiert die Technik die Bedürfnisse des Menschen und eine Korrektur durch diesen ist nicht mehr nötig. Bedarfsgerechte Mensch-Technik-Interaktion erfordert die Anpassung des Intelligenten Technischen Systems (ITS) an den Nutzungskontext und nicht umgekehrt. Voraussetzung für eine intuitive Interaktion ist daher zuallererst die sichere Erkennung des Nutzungskontextes, d.h. wo befindet sich der Nutzer und welche Handlung führt er gerade durch. Das Wissen über regelmäßig auftretende Interaktionsmuster ermöglicht es dem ITS zukünftige Interaktionen vorherzusagen und Assistenzfunktionen prädictiv zu steuern. Bildgebende Sensorik (z.B. Kameras, hochauflösende Time-Of-Flight-Sensoren) ermöglichen durch Personen-, Objekt-, Gesten- oder gar Gesichtserkennung eine leistungsfähige Erkennung des Handlungskontextes, bringen aber die Problematik der Erfassung personenbezogener Daten mit sich. Gerade im privaten häuslichen Umfeld, aber auch in Bürogebäuden oder der Produktion kann dies aus datenschutzrechtlichen Gründen unerwünscht sein.

Minimalsensorik, wie z.B. Bewegungs- oder Präsenzmelder erzeugen nicht unmittelbar personenbezogene Daten, sondern erfassen nur punktuelle Informationen über die Anwesenheit von Personen oder Objekten in einem räumlich eingeschränkten Bereich. Für eine umfassende Erfassung des Nutzungskontextes verspricht die Kombination einer Vielzahl von einfachen Sensoren eine ausreichende Erfassung des Nutzungskontextes bei gleichzeitiger Wahrung der Privatsphäre. Ist für eine Assistenzfunktion komplexere Sensorik notwendig (z.B. für eine Sprach- oder Gestenerkennung), dann braucht sie nur (und auch nur genau dann) aktiviert zu werden, wenn die Nutzung des Assistenzsystems zumindest absehbar ist. Die kontinuierliche Erfassung des Nutzungskontextes ermöglicht aber auch das Lernen von regelmäßigen Handlungsmustern. Aus diesen gelernten Handlungsmustern kann das ITS eine zukünftige zu erwartende Interaktion ableiten und Empfehlungen für die Aktivierung von Assistenzfunktionen geben bzw. diese vorbereiten (Prädiktive Steuerung). Darüber hinaus lassen sich aber auch Abweichungen vom potenziellen Regelzustand (Anomalien) erkennen und geeignet darauf reagieren.

Die Ableitung von Handlungsempfehlungen durch das ITS kann in einfachster Implementierung regelbasiert erfolgen (z.B. „Wenn der Bewegungsmelder im Flur aktiviert wird, dann soll das Licht angeschaltet werden“). In Systemen mit einer hohen Anzahl an Sensoren ist dieses aber sehr aufwendig, nicht flexibel anpassbar und schlecht auf wachsende Umgebungen skalierbar. Darüber hinaus liefern verschiedene Sensoren unterschiedlich abstrakte Informationen (z.B. lokale Bewegung (PIR, Ultraschall) oder Bewegung über mehrere Räume hinweg (HF/Mikrowellen), binär „an/aus“ oder Entfernungen) oder gar komplexere Informationen kamerabasierter Systeme (z.B. Anzahl erkannter Personen/Haustiere/Objekte (Staubsaugerroboter/Transportplattform)). Daher gilt es die unterschiedlichen Informationen zu abstrahieren, ggf. zu anonymisieren und in einem ganzheitlichen Ansatz zum Lernen des Nutzungskontextes, zum Abschätzen zukünftiger Interaktion und zum Erkennen von Anomalien zu nutzen. Wissenschaftliche Herausforderung des Projekts ist daher die Anwendung und Evaluation von maschinellen Lernverfahren zum Lernen von Interaktionsmustern basierend auf den gelieferten Daten der Minimalsensorik, sowie der Prädiktion zukünftiger Interaktion und der Anomalieerkennung.

Aufgabenstellung

Der/die Studierende soll in diesem Projekt ein ITS mitentwickeln, das mittels maschinellen Lernverfahren das Nutzungsverhalten der Bewohner*innen eines Smart Homes erlernt, um

anschließend, anhand der Echtzeitdaten, geeignete Handlungsempfehlungen bereitzustellen oder, bei der Erkennung von Anomalien, geeignete Maßnahmen einzuleiten. Die Ausarbeitung des konkreten Anwendungsszenarios, zusammen mit dem Team des KogniHome e.V., ist Teil des Projekts.

Zur Veranschaulichung soll folgendes Szenario beschrieben werden: „Sabine (74) steht jeden Morgen zwischen 7 und 8 Uhr auf, geht auf die Toilette und macht sich danach einen Kaffee“. In diesem Handlungsablauf sind drei Aktivitäten zu erkennen: Aufstehen, auf Toilette gehen, Kaffee kochen. In jeder dieser Aktivitäten kann es jetzt zu Handlungsempfehlungen bzw. Anomalien kommen. Beispielsweise könnte das ITS den Gang zur Toilette durch geeignete Beleuchtung vorbereiten, oder bereits die Kaffeemaschine anschalten. Gleichzeitig überwacht das ITS die Aktivitäten und erkennt Abweichungen vom gewohnten Verhalten. Stürzt Sabine z.B. auf dem Weg zur Toilette und steht nicht wieder eigenständig auf, so soll das ITS dies erkennen und z.B. den Notruf oder die Pflegestelle verständigen.

Bezug zum Thema Data Science

Die Evaluation und Anwendung von KI-/ML-Verfahren zur Zustandsüberwachung und Prädiktion sind ein Kernthema der Data Science und werden beispielsweise in den Modulen „Data Mining & Machine Learning“ sowie „Künstliche Intelligenz“ behandelt. Die Aufnahme hochaufgelöster Messdaten (z.B. Verbrauchsdaten) von einer Vielzahl an Sensoren in komplexen Wohnumgebungen stellt hohe Anforderungen an Organisation und Verarbeitung der Daten. Dieses ist Kern des Moduls „Big Data Architekturen“.

Verfügbare Ressourcen

- Informationen, die zur Erstellung des Szenarios benötigt werden (Systembeschreibung, logistische Abläufe, relevante Kennzahlen) werden vom KogniHome e.V. bereitgestellt - Es besteht Zugriff auf die Forschungswohnung des KogniHome e.V.
- Über die Forschungswohnung des KogniHome e.V. stehen umfangreiche Testdatensätze zur Verfügung.
- Der Ansprechpartner im KogniHome e.V. wird über die Projektlaufzeit zur Verfügung stehen - Benötigte Materialien werden vom KogniHome e.V. bereitgestellt.
- Hardware für das komplexere Maschine Learning ist über das Data Science Lab, das CfADS, sowie dem KI-Rechencluster yourAI der HSBI verfügbar.

Projektplan

Erstes Semester: Erstellung eines Forschungsexposés als Prüfungsleistung. Einarbeitung in die Konzepte und Strukturen (IoT-Software, Smart Home Protokolle, Schnittstellen etc.) der Forschungswohnung des KogniHome e.V.

Zweites Semester: Erstellung des Systemkonzepts zur Anomalieerkennung zur prädiktiven Steuerung von Assistenzsystemen. Recherche zu relevanten Arbeiten im Themenfeld des Einsatzes von KIVerfahren für das Lernen von Ereignissequenzen und für die Anomalieerkennung. Erstellung eines Papers, das einen Überblick über das jeweilige Forschungsgebiet gibt, als Prüfungsleistung.

Drittes Semester: Praktische Umsetzung verschiedenster maschinellen Lernverfahren im Bereich des unüberwachten und des (semi-)überwachten Lernens zur Optimierung einer automatisierten Interaktion von Mensch und Maschine, sowie deren Evaluation.

Viertes Semester: Masterarbeit und Kolloquium. Finale Evaluierung durch Vergleich der implementierten Strategien. Erstellung eines Papers mit ersten quantitativen Ergebnissen als Prüfungsleistung.

Eignungskriterien

Zwingend:

- Programmierkenntnisse (vzw. Python)
- Erfahrung mit dem Versions-Kontroll-System „git“ Optional:
- Erfahrung in der Elektronikentwicklung
- Erfahrung im Bereich Smart Home Technologien/IoT-Geräten
- Programmierung von Mikrocontrollern

Erwerbbarere Kompetenzen

- Verfahren der künstlichen Intelligenz zur Problemlösung
- Sensor-nahe Informationsverarbeitung
- Prädiktive Assistenz und Anomalieerkennung (Übertragbarkeit auf industrielle Prozesse)
- Kompetenzen in der Arbeit im Team

Forschungsprojekt für den Forschungsmaster Data Science

Projekttitle: 7 Effiziente Ausführung eines Algorithmus zur Objekterkennung auf Edge-Geräten

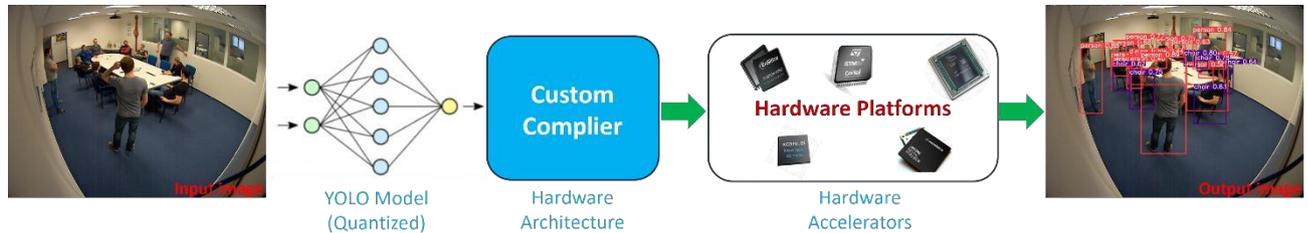


Bild 1: Effiziente Abbildung des YOLO-Vx-Modells auf Randgeräte

Projektübersicht

Anzahl Studierende	1
Art	Projekt mit externen Partnern
Projektverantwortung	Prof. Dr.-Ing. habil. Thorsten Jungeblut Dr.-Ing. Qazi Arbab Ahmed
Projektkontext	Transferprojekt CareTech OWL in Zusammenarbeit mit einem externen Partner, der Steinel GmbH , im Rahmen des Forschungsprojekts CareTech OWL. Eine parallele Beschäftigung als studentische Hilfskraft (WHK) ist möglich.

Abstrakt

Das Paradigma der künstlichen Intelligenz (KI) hat eine Handvoll traditioneller Computer-Vision-Techniken ersetzt, um die korrekte Ausgabe eines komplexen Systems unter engen Einschränkungen und unterschiedlichen Bedingungen intelligent vorherzusagen. Viele KI-Algorithmen benötigen jedoch aufgrund ihrer massiven Rechenanforderungen enorme Mengen an Hardwareressourcen. Die Hauptaufgabe dieses Projekts ist die Entwicklung eines Frameworks für die effiziente Implementierung von Objekterkennungsalgorithmen auf stark ressourcenbeschränkten Hardwarearchitekturen (LowEnd-FPGAs, eingebettete Mikrocontroller). Basierend auf dem Framework werden automatisierte Methoden zur Erkundung des Entwurfsraums geeigneter Kombinationen von Objekterkennungsalgorithmen und Hardware im Sinne eines HW/KI-Co-Designs untersucht. Insbesondere industrielle Anwendungen mit hohen Latenzanforderungen werden angesprochen, wie z. B. die Echtzeit-Anwesenheitserkennung von Menschen.

Kurzbeschreibung

Für die effiziente Ausführung von KI-Algorithmen haben Techniken wie Föderales Lernen (FL) und Cognitive Edge Computing (CEC) bereits die Last des Trainings und der Inferenz neuronaler

Netze von der Cloud an den Ort der Datenentstehung verlagert. Die Partitionierung der Ausführung der Anwendung hat einen erheblichen Einfluss auf die Performanz und Ressourceneffizienz des Gesamtsystems. So kann hier zwischen grundlegend unterschiedlichen Ansätzen der dezentralen Merkmalsextraktion möglichst nah am Sensor mit anschließender Fusion gegenüber der zentralen Verarbeitung in der Cloud unterschieden werden. Der erste Ansatz erfordert leistungsstarke EdgeHardware für die Vorverarbeitung und bietet potenziell Vorteile für hohe Echtzeitanforderungen. Der zweite Ansatz stellt höhere Anforderungen an die Kommunikationsinfrastruktur, ermöglicht aber möglicherweise die Ausführung komplexerer Netzwerke. Das Hauptziel dieses Projekts ist es daher, automatisierte Methoden zur Erforschung des Entwurfsraums geeigneter Kombinationen von KI-basierten Objekterkennungsmethoden und ressourcenbeschränkter Hardware im Hinblick auf HW/KICodesign zu erforschen.

Im Bereich der effizienten Ausführung von KI-Verfahren auf eingebetteten Systemen (Cognitive Edge Computing) wurden in der Vergangenheit große Fortschritte erzielt. Auf allen Ebenen der unterschiedlichen Verarbeitungskonzepte (Cloud, Fog, Edge, Very Edge) in der Produktionskette findet sich eine Vielzahl potenzieller Hardwarearchitekturen und KI-Beschleuniger, die sich in den verfügbaren Systemressourcen (z.B. Leistung oder Stromverbrauch) unterscheiden. Beispiele für relevante Hardwarearchitekturen sind eingebettete Mikrocontroller mit integrierter KI-Beschleunigung, eingebettete GPUs/FPGAs, dedizierte KI-Hardwarebeschleuniger oder High-EndGPUs/FPGAs aus dem HPC-Bereich.

Wir betrachten die gesamte Verarbeitungskette, beginnend mit der sensornahen Vorverarbeitung (very edge), über die Verbindung der Sensorgruppen und ihrer Informationen in der Edge, über lokale dezentrale Cloud-Instanzen (Fog), bis hin zur zentralen Station aller relevanten Informationen (Cloud). Auf jeder Ebene der Verarbeitungskette existieren individuelle Ansätze, um die Ressourceneffizienz von KI-Methoden lokal zu optimieren, z. B. durch Reduzierung der numerischen Präzision (z. B. von 32 auf 16 oder 8 Bit), um eine effizientere Ausführung auf spezialisierter Hardware zu ermöglichen oder den lokalen Speicherplatz zu minimieren. Ziel dieses Projekts ist es, eine optimale Kombination von Hardware und Objekterkennungsalgorithmen (z.B. YOLO) im Rahmen einer ganzheitlichen Entwurfsraumexploration in der Nähe des Sensors zu ermitteln.

Aufgabenstellung

In diesem Projekt entwickeln die Studierenden ein Framework für die effiziente Ausführung von KI-basierten Objekterkennungsalgorithmen auf ressourcenbeschränkten Edge-Geräten. Um die nachhaltige Nutzung der entwickelten Methoden und Frameworks durch den Industriepartner zu unterstützen, sollen in diesem Projekt universell einsetzbare Modelle und automatisierte Entwurfswerkzeuge in Form eines Standard-Entwicklungsbaukastens zur Verfügung gestellt werden. Die erste große Herausforderung ist die Komprimierung des neuesten Algorithmus zur Erkennung von Objekten (z. B. YOLO), um die Modellgröße mit Hilfe von KI-Approximationstechniken mit akzeptabler Genauigkeit zu reduzieren. Die nächste Herausforderung besteht darin, ressourceneffiziente Techniken (Inferenz-Compiler) zu entwickeln, um das komprimierte Modell auf eine geeignete Hardwareplattform abzubilden, z. B. Low-End-FPGAs oder eingebettete (KI-) Mikrocontroller, unter Berücksichtigung der Ressourcennutzung in Bezug auf Fläche, Leistung/Energie und Latenz/Durchsatz, wie in Abbildung 1 dargestellt.

Bezug zum Thema Data Science

Die Bewertung und Anwendung von KI/ML-Methoden im Bereich "Machine Vision", z.B. der Einsatz von CNNs in der Objektklassifizierung, sind ein Kernthema der Data Science und werden beispielsweise in den Modulen "Data Mining & Machine Learning" und "Artificial Intelligence" behandelt. KI-gestützte Bildverarbeitung stellt hohe Anforderungen an die Organisation und Verarbeitung von Daten auf allen Ebenen von IoT-Verarbeitungskonzepten (Edge/Fog/Cloud). Dies ist der Kern des Moduls "Big Data Architekturen". Die Betrachtung des gesamten Systemprozesses vom bildgebenden Sensor bis in die Cloud erfordert eine ganzheitliche Betrachtung des gesamten Data-Science-Prozesses, die im Modul "Data Science" behandelt wird.

Verfügbare Ressourcen

Sicherstellung der Verfügbarkeit von Daten, Rechenressourcen, Hardware, Anwendungsexperten

1. Die für die Erstellung des Szenarios erforderlichen Informationen (Systembeschreibung, Schnittstellen, Dokumentation, relevante Kennzahlen etc.) werden bereitgestellt
2. Steinel GmbH stellt umfangreiche Testdatensätze aus realen Produktionsumgebungen zur Verfügung
3. Der Ansprechpartner der Steinel GmbH steht Ihnen für die Dauer des Projekts zur Verfügung
4. Die für die Prototypenentwicklung benötigten Komponenten sowie weitere benötigte Materialien werden von der Steinel GmbH zur Verfügung gestellt
5. Hardware für das komplexere maschinelle Lernen steht über das Data Science Lab, das CfADS und den KI-Rechencluster yourAI an der Hochschule Bielefeld zur Verfügung

Projektplan

Erstes Semester: Erstellung eines Forschungsexposés als Prüfung. Vertrautheit mit dem Konzept KI-basierter Objekterkennungsalgorithmen, insbesondere YOLO, R-CNN, Bilderkennung, Approximationstechniken für neuronale Netze, Hardwareplattformen und Design-Flow-Tools.

Zweites Semester: Erstellung des Systemkonzepts zur Entwurfsraumexploration von kognitiven EdgeComputing-Architekturen. Recherche zu relevanten Arbeiten auf dem Gebiet der KI-basierten Objekterkennungsalgorithmen und der Modellkomprimierung im oben genannten Kontext. Erstellung einer Arbeit, die einen Überblick über das jeweilige Forschungsgebiet gibt, als Prüfungsleistung.

Drittes Semester: Entwicklung eines ersten Demonstrators und Proof-of-Concept zur Hardwarebeschleunigung für Human Presence Detector (HPD) mit z.B. YOLO-V7. Vergleich des entwickelten Frameworks mit einer klassischen Implementierung.

Viertes Semester: Masterarbeit und Kolloquium. Implementierung und Vergleich verschiedener Kombinationen von KI-basierten Objekterkennungsalgorithmen und Hardwarebeschleunigern. Systematische Bewertung und Untersuchung der Effizienz des entwickelten Rahmens. Abschließende Bewertung durch Vergleich der implementierten

Strategien mit den modernsten Methoden. Erstellung einer Arbeit mit den ersten quantitativen Ergebnissen als Prüfung.

Eignungskriterien

Zwingend:

- Gute Kenntnisse in Python, Pytorch
- Gute Kenntnisse von C++

Optional:

- Erfahrung mit Hardware-Design-Flow-Tools
- Programmierung von Mikrocontrollern/FPGAs
- Grundkenntnisse in HDL (Verilog, VHDL)
- Erfahrung mit IoT-Geräten
- Erfahrung mit dem Versionskontrollsystem "git".

Erwerbbar Kompetenzen

- Ressourceneffiziente Informationsverarbeitung am Edge (eingebettete Mikrocontroller, FPGAs) im Einklang mit dem IoT-Verarbeitungskonzept
- Sensorbezogene Informationsverarbeitung
- AI/ML-basierte Objekterkennungsmethoden
- Nutzung von eingebetteter Hardware zur Beschleunigung von AI/ML-Prozessen

Forschungsprojekt für den Forschungsmaster Data Science

Projekttitle: 8 Hardware-KI-Codesign für die effiziente Ausführung neuronaler Netze

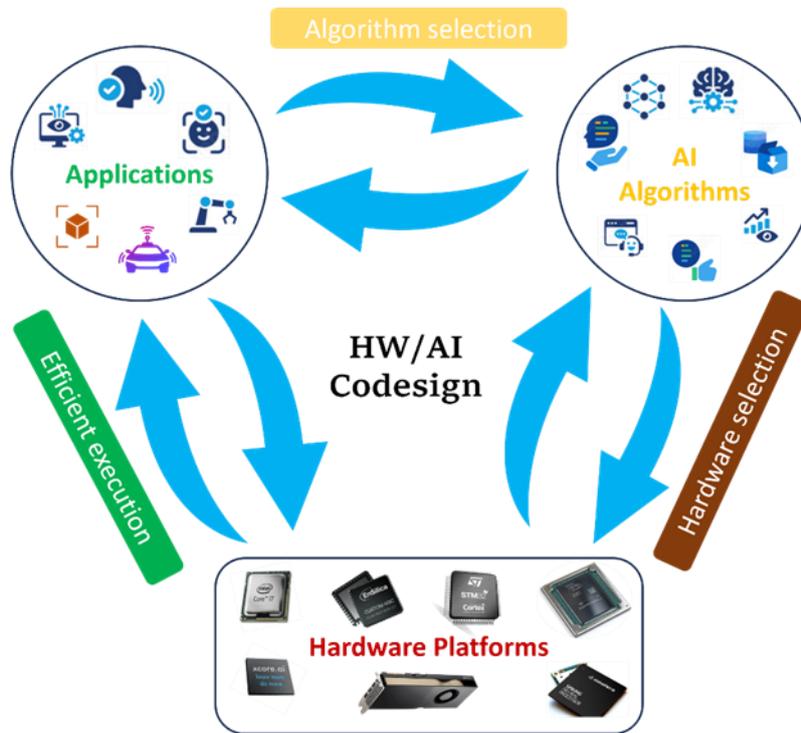


Bild 1: Design-Space-Exploration für Hardware-KI-Codesign

Projektübersicht

Anzahl Studierende	1
Art	Projekt mit externen Partnern
Projektverantwortung	Prof. Dr.-Ing. habil. Thorsten Jungeblut, Dr.-Ing. Qazi Arbab Ahmed
Projektkontext	CareTech OWL Transferprojekt in Zusammenarbeit mit dem externen Partner, der Steinel GmbH , im Rahmen des Forschungsprojekts CareTech OWL. Eine parallele Beschäftigung als studentische Hilfskraft (WHK) ist möglich.

Abstrakt

Das Paradigma der künstlichen Intelligenz (KI) hat eine Handvoll traditioneller Computer-Vision-Techniken ersetzt, um die korrekte Ausgabe eines komplexen Systems unter engen Einschränkungen und unterschiedlichen Bedingungen intelligent vorherzusagen. Viele KI-Algorithmen benötigen jedoch aufgrund ihrer massiven Rechenanforderungen enorme Mengen an Hardwareressourcen. Ziel dieses Projekts ist die Entwicklung eines Frameworks für die effiziente Implementierung von KI- und ML-

Algorithmen auf stark ressourcenbeschränkten Hardwarearchitekturen. Basierend auf dem Framework werden automatisierte Methoden zur Exploration des Entwurfsraums geeigneter Kombinationen von KI-Algorithmen und Hardware im Sinne von HW/KI-Co-Design erforscht.

Insbesondere industrielle Anwendungen mit hohen Latenzanforderungen werden angesprochen. Dabei wird nicht nur die gesamte Kette als linearer Prozess vom Modelltraining bis zur Inferenz berücksichtigt, sondern auch der Einfluss der Wahl möglicher Hardwarekonfigurationen auf die ursprüngliche Modellentwicklung.

Kurzbeschreibung

Für die effiziente Ausführung von KI-Algorithmen haben Techniken wie Föderales Lernen (FL) und Cognitive Edge Computing (CEC) bereits die Last des Trainings und der Inferenz neuronaler Netze von der Cloud an den Rand der Datenentstehung verlagert. Die Partitionierung der Ausführung der Anwendung hat einen erheblichen Einfluss auf die Performance und Ressourceneffizienz des Gesamtsystems. So kann hier zwischen grundlegend unterschiedlichen Ansätzen der dezentralen Merkmalsextraktion möglichst nah am Sensor mit anschließender Fusion versus zentraler Verarbeitung in der Cloud unterschieden werden. Der erste Ansatz erfordert leistungsstarke Edge-Hardware für die Vorverarbeitung und bietet potenziell Vorteile für hohe Echtzeitanforderungen. Der zweite Ansatz stellt höhere Anforderungen an die Kommunikationsinfrastruktur, ermöglicht aber möglicherweise die Ausführung komplexerer Netzwerke. Das Hauptziel dieses Projekts ist es daher, automatisierte Methoden zur Exploration des Entwurfsraums geeigneter Kombinationen von KI-Methoden und ressourcenbeschränkter Hardware im Sinne von HW/KI-Codesign zu erforschen.

Im Bereich der effizienten Ausführung von KI-Verfahren auf eingebetteten Systemen (Cognitive Edge Computing) wurden in der Vergangenheit große Fortschritte erzielt. Auf allen Ebenen der unterschiedlichen Verarbeitungskonzepte (Cloud, Fog, Edge, Very Edge) in der Produktionskette findet sich eine Vielzahl potenzieller Hardwarearchitekturen und KI-Beschleuniger, die sich in den verfügbaren Systemressourcen (z.B. Leistung oder Stromverbrauch) unterscheiden. Beispiele für relevante Hardwarearchitekturen sind eingebettete Mikrocontroller mit integrierter KI-Beschleunigung, eingebettete GPUs/FPGAs, dedizierte KI-Hardwarebeschleuniger oder High-EndGPUs/FPGAs aus dem HPC-Bereich.

Wir betrachten die gesamte Verarbeitungskette, beginnend mit der sensornahen Vorverarbeitung (very edge), über die Verbindung der Sensorgruppen und ihrer Informationen in der Edge, über lokale dezentrale Cloud-Instanzen (Fog), bis hin zur zentralen Station aller relevanten Informationen (Cloud). Auf jeder Ebene der Verarbeitungskette existieren individuelle Ansätze, um die Ressourceneffizienz von KI-Prozessen lokal zu optimieren, z. B. durch Reduzierung der numerischen Präzision (z. B. von 32 auf 16 oder 8 Bit), um eine effizientere Ausführung auf spezialisierter Hardware zu ermöglichen oder den lokalen Speicherplatz zu minimieren. Ziel ist es, eine optimale Kombination von Hard- und Software (d.h. KI-Algorithmus) im Rahmen einer ganzheitlichen Entwurfsraumexploration auf allen Verarbeitungsebenen zu ermitteln.

Aufgabenstellung

In diesem Projekt werden die Studierenden ein automatisiertes Toolkit für die Entwurfsraumexploration entwickeln, das den Benutzer beim HW/KI-Codesign unterstützen kann. Um den nachhaltigen Einsatz der entwickelten Methoden und Frameworks durch den Industriepartner zu unterstützen, sollen in diesem Projekt universell einsetzbare Modelle und automatisierte Entwurfswerkzeuge in Form eines Entwicklungsbaukastens zur Verfügung gestellt werden, der von den konkreten Anwendungsfällen abstrahiert und es ermöglicht, anhand eines zukünftigen

Anwendungsszenarios Empfehlungen für eine optimale Kombination von KI-Methoden und geeigneter (Edge-)Hardwarearchitektur zu erhalten. Ziel ist es, dem Anwender vorläufige Modelle und automatisierte Entwurfswerkzeuge zur Verfügung zu stellen, die Empfehlungen für eine Kombination aus KI-Methoden und geeigneter (Edge-) Hardwarearchitektur auf Basis eines gegebenen Anwendungsszenarios und Bewertungsmaßnahmen ermöglichen.

Bild 1 veranschaulicht das allgemeine Konzept der Exploration des Entwurfsraums für das Hardware-AI-Codesign. Die erste Hauptherausforderung ist die Komprimierung/Optimierung des neuronalen Netzes, um die Größe zu reduzieren und dennoch eine akzeptable Genauigkeit zu erreichen, indem KI-Approximationstechniken verwendet werden. Die nächste Herausforderung besteht in der Entwicklung ressourceneffizienter Techniken zur Abbildung des komprimierten (KI-)Modells auf eine geeignete Hardwareplattform wie GPUs, CPUs, ASICs und FPGAs unter Berücksichtigung der Ressourcennutzung in Bezug auf Fläche, Leistung/Energie und Latenz/Durchsatz.

Bezug zum Thema Data Science

Die Evaluierung und Anwendung von KI/ML-Methoden im Bereich "Maschinelle Sehens", z.B. der Einsatz von CNNs in der Objektklassifikation, sind ein Kernthema der Data Science und werden z.B. in den Modulen "Data Mining & Machine Learning" und "Künstliche Intelligenz" behandelt. KI-gestützte Bildverarbeitung stellt hohe Anforderungen an die Organisation und Verarbeitung von Daten auf allen Ebenen von IoT-Verarbeitungskonzepten (Edge/Fog/Cloud). Dies ist der Kern des Moduls "Big Data Architekturen". Die Betrachtung des gesamten Systemprozesses vom bildgebenden Sensor bis zur Cloud erfordert eine ganzheitliche Betrachtung des gesamten Data Science Prozesses, die im Modul "Data Science" behandelt wird.

Verfügbare Ressourcen

Sicherstellung der Verfügbarkeit von Daten, Rechenressourcen, Hardware, Anwendungsexperten

- Sicherstellung der Verfügbarkeit von Daten, Rechenressourcen, Hardware, Anwendungsexperten
- Bereitstellung der für die Erstellung des Szenarios erforderlichen Informationen (Systembeschreibung, Schnittstellen, Dokumentation, relevante Kennzahlen etc.)
- Steinel GmbH stellt umfangreiche Testdatensätze aus realen Produktionsumgebungen zur Verfügung
- Der Ansprechpartner der Steinel GmbH steht während der gesamten Projektlaufzeit zur Verfügung
- Die Steinel GmbH stellt die für die Prototyp-Entwicklung benötigten Komponenten sowie weitere benötigte Materialien zur Verfügung
- Hardware für das komplexere maschinelle Lernen ist über das Data Science Lab, den CfADS und den KI-Computing-Cluster yourAI an der Hochschule Bielefeld verfügbar

Projektplan

Erstes Semester: Erstellung eines Forschungsexposés als Prüfungsleistung. Einarbeitung in das Konzept der KI-Algorithmen (CNN, DNN), insbesondere der Objekterkennung und Bilderkennung, der verwendeten Hardware-Plattformen und Design-Flow-Tools.

Zweites Semester: Erstellung des Systemkonzepts für die Design Space Exploration von Cognitive Edge

Computing Architekturen. Recherche zu relevanten Arbeiten im Bereich der Nutzung von KI/ML-Methoden zur Datenverarbeitung und Modellkompression im oben genannten Kontext. Erstellung eines Papers, das einen Überblick über das jeweilige Forschungsgebiet gibt, als Prüfungsleistung.

Drittes Semester: Entwicklung eines ersten Demonstrators und Proof-of-Concept für die Hardware-Beschleunigung einer relevanten Anwendung. Vergleich eines KI-Prozesses mit einer klassischen Implementierung.

Viertes Semester: Masterarbeit und Kolloquium. Implementierung und Vergleich verschiedener Kombinationen von KI/ML-Verfahren und Hardwarebeschleunigern. Systematische Evaluierung und Erforschung der Effizienz der Kombinationen. Vergleich verschiedener Verarbeitungskonzepte (Embedded AI, Edge, Cloud). Abschließende Bewertung durch Vergleich der implementierten Strategien. Erstellung eines Papers mit den ersten quantitativen Ergebnissen als Prüfung.

Eignungskriterien

Mandatory:

- Gute Kenntnisse in Python, Pytorch
- Gute Kenntnisse von C++ Optional:
- Erfahrung mit Hardware-Design-Flow-Tools
- Programmierung von Mikrocontrollern/FPGAs
- Grundkenntnisse in HDL (Verilog, VHDL)
- Erfahrung mit IoT-Geräten
- Erfahrung mit dem Versionskontrollsystem "git".

Erwerbbarer Kompetenzen

- Ressourceneffiziente Informationsverarbeitung am Edge (eingebettete Mikrocontroller, FPGAs) im Einklang mit dem IoT-Verarbeitungskonzept
- Sensorbezogene Informationsverarbeitung
- AI/ML-Methoden
- Nutzung von eingebetteter Hardware zur Beschleunigung von AI/ML-Prozessen

Forschungsprojekt für den Forschungsmaster Data Science

Projekttitle: 9 Cognitive Edge Computing für KI-/ML-basierte Oberflächeninspektion

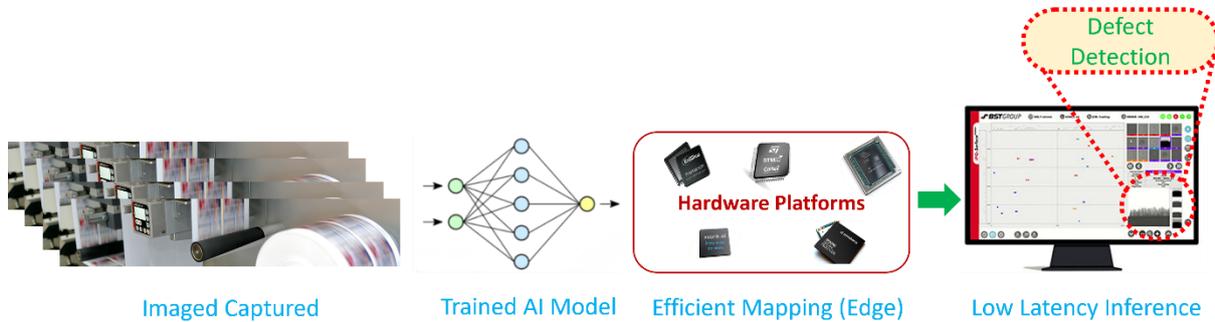


Bild 1: Effiziente Oberflächeninspektion mit AI on edge

Projektübersicht

Anzahl Studierende	1
Art	Projekt mit externem Partner
Projektverantwortung	Prof. Dr.-Ing. Thorsten Jungeblut Dr. Ing. Qazi Arbab Ahmed
Projektkontext	CareTech OWL Transferprojekt in Zusammenarbeit mit einem externen Partner, der BST Group , als Teil des CareTech OWL Forschungsprojekts. Das Partnerunternehmen BST Group stellt umfangreiche Testdatensätze sowie einen prototypischen Hardwareaufbau zur Verfügung. Eine parallele Beschäftigung als wissenschaftliche Hilfskraft (WHK) ist möglich. Die BST Group ist sehr an der Rekrutierung und langfristigen Beschäftigung von Nachwuchskräften interessiert.

Abstrakt

Das Paradigma der künstlichen Intelligenz (KI) hat eine Handvoll traditioneller Computer-Vision-Techniken ersetzt, um auf intelligente Weise die korrekte Ausgabe eines komplexen Systems unter engen Beschränkungen und wechselnden Bedingungen vorherzusagen. Ziel des Projektes ist die Entwurfsraumexploration von KI-/ML-Hardwarebeschleunigern in der Oberflächeninspektion. Im Zentrum steht nicht nur das Lernen der Modelle auf HPC-Systemen, sondern auch die effiziente Ausführung (Inferenz) auf eingebetteter Hardware. Ergebnis der Entwurfsraumexploration ist die Partitionierung der Anwendung, d.h. welche KI-Verfahren können auf dem Sensor ausgewertet werden, welche Verfahren können über Edge-Hardware (z.B. eingebettete GPU/FPGA) beschleunigt werden und welche erfordern leistungsfähige HPC-Hardware in der Cloud.

Kurzbeschreibung

Die Entwicklungen im Bereich der intelligenten technischen Systeme (ITS) führen derzeit zu einem Umbruch in der gesamten Wertschöpfungskette der industriellen Produktion. Die zunehmende Leistungsfähigkeit der Informationsverarbeitung bietet für das Anwendungsgebiet der industriellen Bildverarbeitung viele neue Möglichkeiten, an denen Mensch und Maschinen bisher an ihre Grenzen stoßen. Insbesondere die Nutzung Maschinellem Lernverfahren und Methoden der künstlichen Intelligenz versprechen bisher nicht gekannte Möglichkeiten beispielsweise in der Objektklassifikation oder der visuellen Qualitätskontrolle. Etwa seit dem Jahr 2010 werden mit Deep Neuronal Networks (DNN) bzw. Convolutional Neuronal Networks (CNN) bedeutende Fortschritte erzielt. Die Leistungsfähigkeit etablierter KI-/ML-Verfahren basiert aber bisher meist auf der Nutzung leistungsfähiger dezentraler Rechenressourcen (High-Performance Computing) in der Cloud. Nicht nur für das Lernen der Modelle, sondern auch für deren Ausführung (Inferenz) ist der Anwender auf diese leistungsfähigen Ressourcen angewiesen. Die im Bereich in der industriellen Bildverarbeitung auftretenden Anforderungen weichen jedoch aufgrund hoher Ansprüche an niedrige Latenz, Echtzeitfähigkeit oder Datenlokalität von den durch große Anbieter von KI-Know-How adressierten Fragestellungen ab. Auch Fragestellungen wie Wartbarkeit, Zertifizierbarkeit oder Privacy erschweren die Nutzung populärer Modelle wie DNNs oder CNNs in der Cloud.

Aber auch im Bereich der effizienten Ausführung von KI-/ML-Verfahren auf eingebetteten Systemen (**Cognitive Edge Computing**) wurden in der Vergangenheit große Fortschritte gemacht. Auf allen

Ebenen der unterschiedlichen Verarbeitungskonzepte in der vernetzten Produktion (Edge/Fog/Cloud-Computing) finden sich geeignete Hardwarebeschleuniger, die auf einen geeigneten Kompromiss zwischen den Systemressourcen wie benötigter Leistungsfähigkeit (z.B. Klassifikationsgenauigkeit), Leistungsaufnahme/Energiebedarf oder Datendurchsatz/Latenz abzielen. Beispiele für relevante Hardwarearchitekturen sind eingebettete Mikrocontroller, Embedded GPUs, eingebettete FPGAs oder dedizierte KI-Hardwarebeschleuniger.

Die BST Group entwickelt Systeme für die Oberflächeninspektion (z.B. für die Batteriezellproduktion), die unter anderem typische Fehler Fertigungsprozess (z. B. Beschichtungsaussetzer) verlässlich und umgehend erkennen können. Durch ihren modularen Aufbau können BST Systeme an unterschiedlichste Anwendungen perfekt angepasst werden. Bilderfassung und Fehlererkennung erfolgen in Echtzeit. Die Systeme sind anwendbar auf uniforme, texturierte sowie bedruckte Oberflächen. Die umgehende und automatische Erkennung und Anzeige auch kleinster Fehler und Abweichungen ermöglichen eine schnelle und sichere Anpassung des Prozesses zur Ausschussvermeidung. Das System besteht aus mehreren optischen Sensoren, deren Sensordaten geeignet fusioniert werden. Die Anwendung maschineller Lernverfahren verspricht hier eine höhere Leistungsfähigkeit in der Fehlererkennung und Optimierung des gesamten Prozesses. Mit Bahnlaufgeschwindigkeiten von mehreren hundert Metern pro Sekunde stellen sich allerdings sehr hohe Anforderungen an die Geschwindigkeit bzw. Latenz der eingesetzten KI-/ML-Verfahren. Bild 1 zeigt einen Überblick über die vorgeschlagene Methodik.

Aufgabenstellung

Ziel des Projektes ist die Entwurfsraumexploration von KI-/ML-Hardwarebeschleunigern für den

Einsatz in der Oberflächeninspektion. Im Zentrum steht nicht nur das Lernen der Modelle auf HPC-Systemen, sondern auch die effiziente Ausführung (Inferenz). Die Betrachtung der gesamten Systemarchitektur vom intelligenten Sensor über Edge-Gateways zur lokalen Datenvorverarbeitung bis hin zur Cloud-Infrastruktur stellt hohe Anforderungen an die Abbildung der KI-Verfahren auf die

Hardware. Die Wahl der Zielarchitektur hat wiederum Einfluss auf die Wahl und das Training der Modelle. Hieraus ergibt sich ein iterativer Zyklus (Model-to-Inference-to-Model), der sowohl die Auswahl geeigneter KI-Verfahren als auch die Bestimmung der (Hyper-)Parameter des Modells beinhaltet. Diesen Ansatz einer ganzheitlichen Entwurfsraumexploration kann man auch in Anlehnung an den etablierten Begriff HW/SW-Co-Design als HW-/KI-Co-Design bezeichnen. Die

Entwurfsraumexploration soll dabei unterschiedlichen Entwurfsziele, wie beispielsweise Klassifikationsgenauigkeit, Latenz oder Ressourcenbedarf der Hardware berücksichtigen. Ergebnis der Entwurfsraumexploration ist die Partitionierung der Anwendung, d.h. welche KI-Verfahren können direkt auf dem Sensor ausgewertet werden (z.B. durch Dimensionsreduktion oder Feature-Extraktion), welche Verfahren können über Edge-Hardware (beispielsweise eingebettete GPU/FPGA oder dedizierte TPU-Beschleuniger) beschleunigt werden und welche erfordern leistungsfähige HPC-Hardware in der Cloud.

Bezug zum Thema Data Science

Die Evaluation und Anwendung von KI-/ML-Verfahren im Bereich des „maschinellen Sehens“ z.B. den Einsatz von CNNs in der Objektklassifikation sind ein Kernthema der Data Science und werden beispielsweise in den Modulen „Data Mining & Machine Learning“ sowie „Künstliche Intelligenz“ behandelt. Die KI-gestützte Bildverarbeitung stellt hohe Anforderungen an Organisation und Verarbeitung der Daten auf allen Ebenen der IoT-Verarbeitungskonzepte (Edge/Fog/Cloud). Dieses ist Kern des Moduls „Big Data Architekturen“. Die Betrachtung des gesamten Systemprozesses vom bildgebenden Sensor bis zur Cloud erfordert eine ganzheitliche Betrachtung des vollständigen Data Science Prozesses, welches im Modul „Data Science“ behandelt wird.

Verfügbare Ressourcen

- Informationen, die zur Erstellung des Szenarios benötigt werden (Systembeschreibung, Schnittstellen, Dokumentationen, relevante Kennzahlen etc.) werden von der BST Group bereitgestellt
- Die BST Group stellt umfangreiche Testdatensätze aus realen Produktionsumgebungen zur Verfügung
- Der Ansprechpartner der BST Group wird über die Projektlaufzeit zur Verfügung stehen
- Die für den prototypischen Aufbau benötigten Komponenten sowie sonstiges benötigtes Material wird von der BST Group bereitgestellt
- Hardware für das komplexere Maschine Learning ist über das Data Science, das CfADS sowie dem KI-Rechencluster yourAI der FH Bielefeld verfügbar

Projektplan

Erstes Semester: Erstellung eines Forschungsexposés als Prüfungsleistung. Einarbeitung in die das Konzept der Oberflächeninspektionssysteme von BST, die Schnittstellen der zur Verfügung gestellten intelligenten Sensoren.

Zweites Semester: Erstellung des Systemkonzepts zur Entwurfsraumexploration von Cognitive-Edge-Computing-Architekturen. Recherche zu relevanten Arbeiten im Themenfeld des Einsatzes von KI-/ML-Verfahren für die Sensordatenverarbeitung im o.g. Kontext. Erstellung eines Papers, das einen Überblick über das jeweilige Forschungsgebiet gibt, als Prüfungsleistung.

Drittes Semester: Entwicklung eines ersten Demonstrators und Proof-of-Concept zur Hardwarebeschleunigung einer Anwendung zur Oberflächeninspektion von BST. Vergleich eines KI-Verfahrens mit einer klassischen Realisierung.

Viertes Semester: Masterarbeit und Kolloquium. Implementierung und Vergleich unterschiedlicher Kombinationen aus KI-/ML-Verfahren und Hardwarebeschleunigern. Systematische Evaluation und Exploration der Effizienz der Kombinationen. Vergleich verschiedener Verarbeitungskonzepte (Embedded AI, Edge, Cloud). Finale Evaluierung durch Vergleich der implementierten Strategien. Erstellung eines Papers mit ersten quantitativen Ergebnissen als Prüfungsleistung.

Eignungskriterien

Zwingend:

- Gute Erfahrung mit Python, Pytorch
- Gute Kenntnisse in C++

Optional:

- Erfahrung mit IoT-Geräten
- Grundkenntnisse in HDL (Verilog, VHDL)
- Erfahrung mit Hardware-Design-Flow-Tools
- Programmierung von Mikrocontrollern/FPGAs

Erfahrung mit IoT-Geräten Erwerbbarer Kompetenzen

- Ressourceneffiziente Informationsverarbeitung auf den verschiedenen Ebenen (Edge, Fog, Cloud) im Sinne des IoT-Verarbeitungskonzepts
- Sensornaher Informationsverarbeitung
- KI-/ML-Verfahren
- Einsatz eingebetteter Hardware zur Beschleunigung von KI-/ML-Verfahren

Forschungsprojekt für den Forschungsmaster Data Science

Projekttitle: 10 Optische Qualitätskontrolle von beschichteten Holzzuschnitten



Projektübersicht

Anzahl Studierende	1
Art	Projekt mit externen Partnern
Projektverantwortung	Prof. Dr.-Ing. Christian Schwede
Projektkontext	Projekt in Zusammenarbeit mit dem Unternehmen Febrü Büromöbel GmbH und dem Institute for Data Science Solutions (IDaS) ; Anstellung als Hiwi durch die Hochschule ist vorgesehen.

Abstrakt

Ziel des Projektes ist beschichtete Holzurniere, die in einer variantenreichen Büromöbelproduktion zugeschnitten und gekantet werden optisch auf ihre Qualität zu überprüfen. Hierbei soll sowohl das Grundsetup (Kamerabeschaffung, und -aufhängung, Datenerhebung und Echtzeitdatenverarbeitung) eingerichtet, als auch das Verfahren auf Basis von Deep Convolutional Neural Networks entwickelt werden.

Kurzbeschreibung

Febrü ist ein mittelständisches Unternehmen mit Sitz in Herford, das sich auf die Produktion von Büromöbeln spezialisiert hat. Das Unternehmen beschäftigt rund 250 Mitarbeiter:innen und erzielen einen Jahresumsatz von etwa 45 Millionen Euro. Febrü produziert ausschließlich in

Deutschland und setzt auf eine nachhaltige Produktion mit hohem Qualitätsanspruch und individuellen Lösungen für die moderne Arbeitswelt. Nach dem Zuschneiden der Holzdekore findet derzeit eine manuelle Qualitätsprüfung durch einen Mitarbeiter statt. Dieser prüft die Maße (Länge, Höhe und Breite) auf Übereinstimmung mit den Vorgaben und die Oberfläche auf Beschädigung. Die Oberflächen haben hierbei eine hohe Variantenvielfalt und unterscheiden sich neben dem aufgedruckten Muster (Holzarten, Betonoptik usw.) auch durch unterschiedliche Reliefs. Die Aufgabe soll in Zukunft kamerabasiert durch Verfahren aus dem Bereich des Maschinellen Lernen unterstützt werden.

Aufgabenstellung

Die Student:in soll in dem Projekt erstens das Setup einrichten, dass zur Aufnahme der Daten und zur Durchführung der optischen Qualitätsprüfung notwendig ist. Hierzu gehört die Auswahl der Kamera, das Anbringen in der Produktion, das Einrichten der Aufnahme und die Abstimmung mit den Mitarbeitern der Qualitätsprüfung, so dass diese die Ergebnisse ihrer Prüfung digital und systematisch erfassen. Zweitens sollen Verfahren aus dem Bereich der Bildanalyse und des Maschinellen Lernens ausgewählt und implementiert werden die eine optische Erkennung der Maße und der Beschädigungen ermöglichen.

Bezug zum Thema Data Science

Die verwendeten Methoden des Maschinellen Lernens, Convolutional Neural Networks sind Bestandteil der Veranstaltung im Forschungsmaster und Kernbereiche der Data Science.

Verfügbare Ressourcen

- Fachexperten aus der Produktion und dem Qualitätsmanagement werden von Febrü bereitgestellt
- Benötigte Hard- und Software zur Datenerfassung und -verarbeitung in der Produktion wird von Febrü beschafft
- Das Labeln der Daten wird durch den Febrü QM-Experten durchgeführt
- Hardware für Maschine Learning ist über das Data Science Lab, das CfADS, sowie dem KI-Rechencluster yourAI der HSBI verfügbar

Projektplan

Erstes Semester: Erstellung eines Forschungsexposés als Prüfungsleistung. Einarbeitung in die Aufgabenstellung im Unternehmen, Recherche zu verfügbarer Kamerahardware und Software, Beschaffung der Hard- und Software, Einrichten des Setups in der Produktion, Erfassen der Bilder und starten des Labelns

Zweites Semester: Literaturrecherche zur Verfahren der optischen Bilderkennung und der Convolutional Neural Networks (CNN) in dem Kontext. Implementierung von Verfahren zur optischen Bestimmung der Abmessungen. Erstellung eines Papers, das einen Überblick über das Forschungsgebiet gibt, ist Prüfungsleistung.

Drittes Semester: Implementierung und Training von CNN mit den erfassten Daten. Auswerten der Ergebnisse. Veröffentlichung eines Papers mit den ersten Ergebnissen ist Prüfungsleistung.

Viertes Semester: Masterarbeit und Kolloquium. Verbesserung der Ergebnisse und Integration des Algorithmus in die Produktionsumgebung.

Eignungskriterien

Zwingend:

- Programmierkenntnisse (vzw. Python)
- Kenntnisse in Echtzeitprogrammierung und Sensordatenverarbeitung (Automatisierung/ Mechatronik)

Optional:

- Erfahrung mit Algorithmen zur Bildverarbeitung
- Erfahrung mit Maschinellem Lernen
- Erfahrung in Produktion und Qualitätsmanagement

Erwerbbarer Kompetenzen

- Bildverarbeitung
- Optische Qualitätskontrolle
- Convolutional Neural Networks
- Echtzeitdatenverarbeitung
- Publikation von wissenschaftlichen Veröffentlichungen auf internationalen Konferenzen
- Kompetenzen in der Arbeit im Team

Forschungsprojekt für den Forschungsmaster Data Science

Projekttitel: 11 Datenbasierte Identifikation mathematischer Modelle von physikalischen Systemen



Projektübersicht

Anzahl Studierende	1
Art	Gefördertes Projekt mit externen Partnern (bis Ende 2025), dann ggfs. Anbindung an Folgeprojekt
Projektverantwortung	Prof. Dr.-Ing. Martin Kohlhase, M.Sc. M. Dockhorn
Projektkontext	Projektpartner (bis Ende 2025): <ul style="list-style-type: none">Center for Applied Data Science (Institut der HSBI)Fraunhofer-Institut für Entwurfstechnik Mechatronik (Universität-Paderborn) Der Studierende wird Teil des Projektteams und steht in regelmäßigem Austausch mit wissenschaftlichen Mitarbeitern der HSBI

Abstrakt

Zentrales Thema des Forschungsprojekts ist die Systemidentifikation, welche sich mit der datenbasierten Schätzung mathematischer Modelle beschäftigt. Im Rahmen des Projekts werden verschiedene Methoden aus diesem Bereich verwendet, um Modelle zur Beschreibung realer Systeme zu generieren. Die Qualität dieser Modelle wird bewertet und mit KI-basierten Modellen verglichen. Anhand der so gewonnenen Erkenntnisse werden Forschungsfragen definiert, die vom Studierenden in seiner Masterarbeit zu untersuchen sind. Während der gesamten Projektlaufzeit wird der Studierende von den Betreuenden kontinuierlich begleitet und individuell unterstützt.

Kurzbeschreibung

Kernthema der Forschung ist die Systemidentifikation. Diese konzentriert sich auf Schätzung mathematischer Modelle anhand von (Mess-)Daten und Systemwissen. Mathematische Modelle sind in diesem Kontext differenzial-algebraische Gleichungssysteme, die das Verhalten eines Systems beschreiben und beispielweise zur Formulierung von Gesundheitszuständen oder für den Entwurf von Regelungen verwendet werden können. Die Form und Koeffizienten der differenzial-algebraischen Gleichungssysteme werden bei der Systemidentifikation mit Hilfe unterschiedlicher Algorithmen bestimmt, welche im Rahmen der Forschungsarbeit untersucht, miteinander verglichen und an diversen realen Systemen angewendet werden sollen. Des Weiteren soll ein direkter Vergleich zwischen Systemidentifikationsalgorithmen und entsprechenden Methoden des maschinellen Lernens durchgeführt werden. Anhand der hierbei gewonnenen Erkenntnisse werden geeignete Forschungsfragen im Kontext der Systemidentifikation definiert, welche der Studierende im Rahmen seiner Masterarbeit untersucht. Bei Interesse wird der Studierende dabei unterstützt, geeignete Forschungsergebnisse auf entsprechenden Konferenzen zu publizieren. Während der gesamten Projektlaufzeit wird der Studierende von den Betreuenden kontinuierlich begleitet und individuell unterstützt.

Die Forschungsarbeiten werden zunächst im Rahmen des kooperativen Validierungsforschungsprojektes VIP4PAPS durchgeführt. Projektpartner sind das Fraunhofer Institut für Entwurfstechnik Mechatronik (Universität Paderborn, 4 Mitarbeiter) und das Center for Applied Data Science (HSBI, 2 Mitarbeiter). Ziel des Projekts ist die Validierung einer Prescriptive-Analytics-Plattform für Produktionsanlagen. Zusammengefasst meint dies die Entwicklung eines Tools für Anlagennutzer, welches anhand von Produktionsdaten Voraussagen über zukünftig auftretende Fehler trifft und entsprechende Handlungsempfehlungen zur Vermeidung eines tatsächlichen Fehlerfalls generiert. Der Studierende erhält somit während seiner Forschung einen Einblick in die Arbeitsweise eines interdisziplinären Projektteams und kann erste Erfahrungen im Kontext drittmittelgeförderter Forschungsprojekte sammeln. Nach Abschluss des Projekts (09.2025) wird es angestrebt, den Studierenden in ein entsprechendes Folgeprojekt mit einzubinden.

Aufgabenstellung

Zu Beginn ist es die Aufgabe des Studierenden, sich im Rahmen einer Literaturrecherche einen Überblick über theoretische Grundlagen und den aktuellen Stand der Technik zu verschaffen. Hierbei ist es das Ziel, dass sich der Studierende neben den fachlichen Inhalten auch Methoden zum effektiven und zielgerichteten Umgang mit wissenschaftlicher Literatur aneignet. Zusätzlich sammelt der Studierende in dieser Einarbeitungsphase praktische Erfahrung im Umgang mit einzelnen Systemidentifikationsalgorithmen, indem er diese auf geeignete Lernbeispiele anwendet.

Nach erfolgreicher Einarbeitung nutzt der Studierende die zuvor erlernten Techniken, um mathematische Modelle für reale Systeme, wie beispielsweise Sortierroboter, zu identifizieren und zu

validieren. Dies beinhaltet sowohl die Planung und Durchführung von Experimenten zur Datengenerierung als auch das Preprocessing der Daten. Des Weiteren nutzt der Studierende numerische Methoden, um für die Systemidentifikation benötigte Größen, wie z.B. Ableitungen gemessener Signale, anhand vorhandener Daten zu generieren.

In der anschließenden Projektphase vergleicht der Studierende die Qualität der ermittelten mathematischen Modelle mit der KI-basierter Modelle, welche auf den zur Systemidentifikation verwendeten Daten trainiert, worden sind. Anhand der so gewonnenen Erkenntnisse definiert der Studierende zusammen mit den Betreuenden geeignete Forschungsfragen, die er im Rahmen seiner Masterarbeit untersucht.

Bezug zum Thema Data Science

Die nachfolgend aufgeführten Aufgaben des Studierenden sind zentrale Elemente der Data Science

- Zielgerichtete und effiziente Generierung von Daten
- Preprocessing von Daten
- Ableitung von Features aus vorhandenen Datensätzen
- Datenbasierte Generierung von Systemmodellen
- Implementierung von Algorithmen des maschinellen Lernens

Verfügbare Ressourcen

Im Rahmen des Projektes hat der Studierende die Möglichkeit

- zum regelmäßigen Austausch mit erfahrenen Mitarbeitern des CfADS
- zur Nutzung der IoT-Factory und HSBI-interner Labore für die Datengenerierung und Validierung der eigenen Arbeit
- zur Nutzung der von der HSBI bereitgestellten Softwaretools und des Data-Analytics-Cluster

Projektplan

Erstes Semester:

- Durchführung einer strukturierten Literaturrecherche
- Anwendung einzelner Systemidentifikationsalgorithmen auf geeignete Lernbeispiele
- Erstellung eines Forschungsexposés ist Prüfungsleistung.

Zweites Semester:

- Planung und Durchführung von Experimenten zur Datengenerierung
- Preprocessing der generierten Daten.
- Nutzung numerischer Methoden, um für die Systemidentifikation benötigte Größen aus vorhandenen Daten zu generieren.
- Identifikation und Validierung mathematischer Modelle anhand der generierten Daten
- Erstellung eines Papers, das einen Überblick über das jeweilige Forschungsgebiet gibt, ist Prüfungsleistung.

Drittes Semester:

- Generierung KI-basierter Modelle für die im zweiten Semester betrachteten Systeme.
- Vergleich der Qualität mathematischer Modelle und KI-basierter Modelle

- Analyse der Ergebnisse
- Definition von konkreten Forschungsfragen, die in der Masterarbeit untersucht werden sollen
- Erstellung eines Papers mit ersten quantitativen Ergebnissen ist Prüfungsleistung.

Viertes Semester:

- Masterarbeit und Kolloquium

Eignungskriterien

Zwingend:

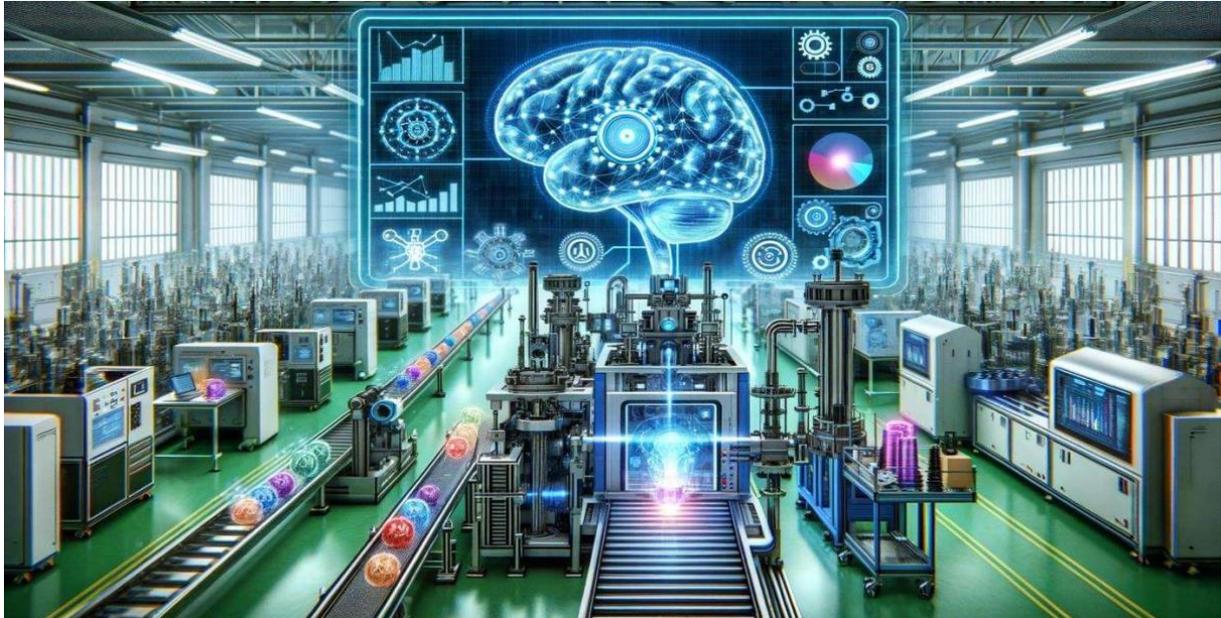
- Bachelorabschluss in ingenieurwissenschaftlicher Fachrichtung
- Programmiererfahrung in Matlab oder Python
- Gute Grundkenntnisse der Regelungstechnik
- Freude sich tief und intensiv in technische Fragestellungen einzuarbeiten

Erwerbbarere Kompetenzen

- Durchführung einer strukturierten Literaturrecherche
- Expertenwissen im Bereich der datenbasierten Systemidentifikation
- Grundkenntnisse zu Methoden des maschinellen Lernens
- Zielgerichtete und effiziente Planung von Experimenten zur Datengenerierung
- Effiziente Validierung eigener Lösungsansätze
- Dokumentation und Präsentation der eigenen Arbeit in wissenschaftlicher Form
- Anfertigung von wissenschaftlichen Arbeiten mit Fokus auf eine potenzielle Veröffentlichung
- Softskills bezüglich der Arbeitsweise von Forschenden in Projektteams

Forschungsprojekt für den Forschungsmaster Data Science

Projekttitel: 12 KI-gestützte Produktionsplanung für Mass Customization (KiMaC)



Projektübersicht

Anzahl Studierende	1-2
Art	Gefördertes Projekt mit Partnerunternehmen
Projektverantwortung	Prof. Dr. Pascal Reusch
Projektkontext	Eine interdisziplinäre Forschungsinitiative in Zusammenarbeit mit führenden Industriepartnern, die sich auf die Implementierung von Mass Customization unter Nutzung von KI-Technologien konzentriert. Partner sind renommierte Unternehmen der Fertigungsindustrie. Es besteht die Möglichkeit einer Beschäftigung als wissenschaftliche Hilfskraft.

Abstrakt

Dieses Projekt zielt darauf ab, die Produktion durch Mass Customization zu revolutionieren, indem es die **Personalisierung** maßgeschneiderter Produkte mit der **Effizienz und Kostenersparnis der Massenproduktion** kombiniert. KI-Technologien werden genutzt, um **reale Herausforderungen anzugehen** und Produktionsprozesse so anzupassen, dass personalisierte Produktangebote effizienter und kostengünstiger werden. Das Projekt umfasst **KI-gestützte Systeme** zur Optimierung der Konfiguration, der Produktionslogistik und der Steuerungsprozesse, was die Durchlaufzeiten verkürzt, Fehler reduziert, die Präzision erhöht und Kosten senkt.

Kurzbeschreibung

Das KiMaC-Projekt ist eine bahnbrechende Initiative im Bereich der Mass Customization und vereint die Stärken der **GRAUTHOFF Türengruppe GmbH** und der **Solarlux GmbH** mit künstlicher Intelligenz, um die Produktion von Türen und Glas-Faltwänden zu revolutionieren. Dabei steht nicht nur die technologische Innovation im Vordergrund, sondern auch die **Nachhaltigkeit und die Fähigkeit zur Individualisierung**, die KI in die Fertigungsprozesse einbringt. GRAUTHOFF Türengruppe GmbH ist ein bedeutender Akteur in der Gebäudeindustrie und spezialisiert auf die Herstellung von Türen. Mit über 60 Jahren Erfahrung, die in einer kleinen Werkstatt begann, ist das Unternehmen zu einem der führenden Türenhersteller Deutschlands gewachsen. Solarlux GmbH ist seit über 35 Jahren führend in der Herstellung von Glas-Faltwänden, Wintergärten und Fassadenlösungen. Solarlux zeichnet sich durch außergewöhnliche Qualität, nachhaltiges Handeln und innovative Designs aus.

Das KiMaC-Projekt zielt darauf ab, mithilfe von KI den Individualisierungsprozess zu optimieren und eine effiziente Produktion maßgeschneiderter Produkte zu ermöglichen, die den **individuellen Kundenpräferenzen entsprechen, ohne dabei die Effizienz der Massenproduktion zu beeinträchtigen**. Durch die Integration von KI in die Produktkonfiguration und Produktionslogistik schafft das KiMaC-Projekt eine neue Dimension der Personalisierung bei der Herstellung von Türen und Glas-Faltwänden. Jedes Produkt wird nicht nur funktional überlegen, sondern auch individuell auf die Bedürfnisse und Geschmäcker der Kunden abgestimmt.

Einerseits wird die Produktkonfiguration mit einem Wissensgraphen (engl. Knowledge Graph) als neuer Datenbasis restrukturiert. Andererseits wird die Produktionsplanung so angepasst, dass individualisierte Produkte zu den Kosten der Massenproduktion hergestellt werden können. Dieser Teil des Projekts fokussiert sich auf **KI-gestützte Lösungen in der realen Produktionsplanung**. Das KiMaC-Projekt repräsentiert nicht nur einen Fortschritt in der Produktionseffizienz und Produktpersonalisierung, sondern unterstreicht auch das Engagement der teilnehmenden Unternehmen für Innovation, Nachhaltigkeit und Kundenzufriedenheit im modernen Zeitalter.

Aufgabenstellung

Studierende werden verschiedene Aspekte des Projekts erkunden und dazu beitragen, darunter:

- **Daten (Vor-)Verarbeitung & Datenanalyse:** Bearbeitung und Analyse von Unternehmensdaten aus der Praxis.
- **Erstellung KI-basierter Assistenzsysteme:** Unterstützung der Produktionslogistik und Konfigurationsprozesse durch intelligente Entscheidungshilfen und Produktionspläne.
- **Automatisierung von Fertigungsprozessen:** Einsatz von KI zur Planung von Produktionsaufträgen und Arbeitskräften in Echtzeit basierend auf Betriebsdaten und aktuellen Auftragsdaten.
- **Integration und Bewertung:** Einbindung und Evaluierung der entwickelten Assistenzsysteme in die Produktionssysteme der Partnerunternehmen, einschließlich der Analyse der wirtschaftlichen Tragfähigkeit und Akzeptanz.

Bezug zum Thema Data Science

Das Projekt integriert zentrale Methoden der Data Science, darunter Datenvorverarbeitung, Datenanalyse und maschinelles Lernen – insbesondere Reinforcement Learning – zur Optimierung von Produktionsprozessen in der Praxis. Es bietet eine einzigartige Gelegenheit, **theoretisches Wissen in einem industriellen Umfeld anzuwenden** und sich an der Schnittstelle von KI und Fertigung weiterzuentwickeln.

Verfügbare Ressourcen

Die **Zusammenarbeit mit Industriepartnern** bietet Zugang zu realen Produktionsumgebungen, Betriebsdaten und IT-Infrastrukturen für die Entwicklung und Implementierung von KI-Modellen und -Systemen. Zusätzlich stellt das **Center for Applied Data Science Gütersloh** eine **hochmoderne Test-IoT-Factory** für praktische Tests und Experimente bereit. Eine moderne Cloud-Umgebung wird für die Softwarebereitstellung genutzt, unterstützt durch umfangreiche Rechenressourcen des **Data Analytics Clusters** der Hochschule.

Projektplan

Erstes Semester: Forschungsexposé mit erster Konzeptualisierung von KI-Modellen zur Produktionsoptimierung.

Zweites Semester: Systematische Literaturrecherche zu bestehenden KI-Anwendungen im Bereich Mass Customization und Produktionsoptimierung.

Drittes Semester: Entwicklung und erste Tests der KI-Modelle und Assistenzsysteme in einer simulierten Produktionsumgebung.

Viertes Semester: Masterarbeit mit Fokus auf Integration, Evaluierung und Optimierung der KI-Systeme in realen Produktionsumgebungen, gefolgt von einem Kolloquium.

Eignungskriterien

Zwingend:

- Bachelorabschluss in Data Science, Produktionslogistik, Informatik oder einem verwandten Fachbereich.
- Programmierkenntnisse, bevorzugt in Python.
- Grundlegendes Verständnis von maschinellem Lernen, Statistik und Optimierung.
- Interesse an der Anwendung von Data Science in realen industriellen Herausforderungen.

Optional:

- Erfahrung mit Operations-Research, Reinforcement Learning oder Prozesssimulation.
- Kenntnisse in Produktionsplanung, ERP-Systemen oder verwandten Bereichen.

Erwerbbar Kompetenzen

Kompetenzen, die durch das Projekt erworben werden

- **Praktische Anwendung** fortgeschrittener Methoden des maschinellen Lernens und Künstlicher Intelligenz in komplexen, realen Produktionsumgebungen.
- Tiefgehendes Verständnis von **Herausforderungen und Lösungen im Bereich Mass Customization** aus der Perspektive der Data Science.
- **Erweiterte Forschungskompetenzen** durch die Entwicklung, Implementierung und Evaluierung modernster KI-Systeme in einem interdisziplinären Umfeld.

Forschungsprojekt für den Forschungsmaster Data Science

Projekttitle: 13 Digitaler Zwilling für Losgrößenoptimierung einer Pulverbeschichtungsanlage



Projektübersicht

Anzahl Studierende	1
Art	Projekt mit externen Partnern
Projektverantwortung	Prof. Dr.-Ing. Christian Schwede
Projektkontext	Projekt in Zusammenarbeit mit dem Unternehmen Febrü Büromöbel GmbH und dem Institute for Data Science Solutions (IDaS) ; Anstellung als Hiwi durch die Hochschule ist vorgesehen.

Abstrakt

Ziel des Projektes ist die Losgrößenbildung einer Pulverbeschichtungsanlage für Metallteile einer variantenreichen Büromöbelproduktion zu optimieren. Hierzu müssen die Produktions- und Lagerprozesse rund um die Anlage als auch aus den Daten des Unternehmens als Digitaler Zwilling automatisch gelernt und auf dieser Basis ein KI-Assistent zu Losgrößenplanung entwickelt werden.

Kurzbeschreibung

Febrü ist ein mittelständisches Unternehmen mit Sitz in Herford, das sich auf die Produktion von Büromöbeln spezialisiert hat. Das Unternehmen beschäftigt rund 250 Mitarbeiter:innen und erzielt einen Jahresumsatz von etwa 45 Millionen Euro. Febrü produziert ausschließlich in Deutschland und setzt auf eine nachhaltige Produktion mit hohem Qualitätsanspruch und individuellen Lösungen für

die moderne Arbeitswelt. Ein teurer Produktionsschritt in der Metallteilefertigung ist die Pulverbeschichtung der Metallteile, um diesen unterschiedlichen Farben zu geben. Die Metallteile sind hochvariantenreich und entstehen durch Laserschneiden, Stanzen, Schweißen und Schleifen aus Platten oder Rohren. In der Pulverbeschichtungsanlage müssen sie zu Farblosen zusammengefasst werden, so dass möglichst wenige Farbwechsel (Rüstzeitenreduzierung) durchgeführt werden müssen und gleichzeitig die Liefertreue eingehalten wird. Ein weiteres Kriterium ist es, dass die Farben von hell nach dunkel aufgelegt werden. Eine Schwierigkeit besteht hierbei darin, dass die Metallteile häufig nicht wie geplant aus dem vorherigen Produktionsschritten bereitgestellt werden und so die Planung flexibel angepasst werden muss. Das Wissen um die Planung liegt momentan bei einigen wenigen erfahrenen Mitarbeitern.

Aufgabenstellung

Die Student:in soll in dem Projekt erstes aus den Daten der Produktion und der Logistik einen Digitalen Zwilling unter Verwendung des Open Source Frameworks OFacT erstellen. Hierbei sollen Verfahren des Maschinellen Lernens und des Process Minings verwendet werden, um den simulationsbasierten Digitalen Zwilling möglichst automatisch zu erstellen. Zweitens soll auf Basis des Digitalen Zwillings dann ein KI-Assistent zu Losgrößenplanung erstellt werden. Hier können einerseits Verfahren der mathematischen Optimierung und des Reinforcement Learnings eingesetzt werden. Das Wissen der menschlichen Planer soll durch einen zu entwickelnden Interaktions- und Feedbackmechanismus (u.U. auf Basis von Large Language Models) integriert werden

Bezug zum Thema Data Science

Die verwendeten Methoden des Maschinellen Lernens, des Reinforcement Learnings und der Large Language Models sind Bestandteil der Veranstaltung im Forschungsmaster und Kernbereiche der Data Science.

Verfügbare Ressourcen

- Daten und Fachexperten aus der Produktion werden von Febrü bereitgestellt
- Das OFacT Framework wird vom IDaS bereitgestellt
- Hardware für Maschine Learning ist über das Data Science Lab, das CfADS, sowie dem KI-Rechencluster yourAI der HSBI verfügbar

Projektplan

Erstes Semester: Erstellung eines Forschungsexposés als Prüfungsleistung. Einarbeitung in die Aufgabenstellung im Unternehmen, Sichtung der Daten, Einarbeitung in das OFacT Framework. Erste manuelle Modellierung des Digitalen Zwillings

Zweites Semester: Literaturrecherche zu Verfahren der Optimierung und des Reinforcement Learnings zur Produktionsplanung. Automatische Erstellung des Digitalen Zwillings aus den Daten mittels Maschinellen Lernen und Process Mining. Erstellung eines Papers, das einen Überblick über das Forschungsgebiet gibt, ist Prüfungsleistung.

Drittes Semester: Implementierung des AI-Assistenten und Auswertung der Ergebnisse. Veröffentlichung eines Papers mit den ersten Ergebnissen ist Prüfungsleistung.

Viertes Semester: Masterarbeit und Kolloquium. Implementierung des Verfahrens zu Integration des menschlichen Feedbacks.

Eignungskriterien

Zwingend:

- Programmierkenntnisse (vzw. Python)

Optional:

- Erfahrung mit Maschinellem Lernen
- Erfahrung mit Optimierungsverfahren
- Erfahrung in Produktion und Logistik
- Erfahrung mit Simulationsmodellen

Erwerbbarer Kompetenzen

- Digitale Zwillinge
- Reinforcement Learning
- Large Language Models
- Optimierungsverfahren zur Produktionsplanung
- Produktions- und Logistik Knowhow in der variantenreichen diskreten Fertigung
- Publikation von wissenschaftlichen Veröffentlichungen auf internationalen Konferenzen
- Kompetenzen in der Arbeit im Team

Forschungsprojekt für den Forschungsmaster Data Science

Projekttitel: 14 Optimierung des Plattenlagers eines mittelständischen Büromöbelherstellers



Projektübersicht

Anzahl Studierende	1
Art	Projekt mit externen Partnern
Projektverantwortung	Prof. Dr.-Ing. Christian Schwede
Projektkontext	Projekt in Zusammenarbeit mit dem Unternehmen Febrü Büromöbel GmbH und dem Institute for Data Science Solutions (IDaS) ; Anstellung als Hiwi durch die Hochschule ist vorgesehen.

Abstrakt

Ziel des Projektes ist die Einlagerung von Holzplatten für die Büromöbelproduktion zu optimieren. Die Schwierigkeit besteht darin, dass zum Zeitpunkt der Einlagerung der Platten auf unterschiedliche Stapel die Produktionsaufträge noch nicht vollständig bekannt sind und die Bedarfe somit auf Basis von historischen Daten vorhergesagt werden müssen. Hierzu sollen Modelle des Maschinellen Lernens eingesetzt werden.

Kurzbeschreibung

Febrü ist ein mittelständisches Unternehmen mit Sitz in Herford, das sich auf die Produktion von Büromöbeln spezialisiert hat. Das Unternehmen beschäftigt rund 250 Mitarbeiter:innen und erzielt einen Jahresumsatz von etwa 45 Millionen Euro. Febrü produziert ausschließlich in Deutschland und setzt auf eine nachhaltige Produktion mit hohem Qualitätsanspruch und individuellen Lösungen für die moderne Arbeitswelt. Ein wichtiger Produktionsschritt der variantenreichen Produktion basiert auf extern angelieferten Holzspanplatten in ca. 90 verschiedenen Dekoren. Hierfür steht neben einem kleinen Außenlager ein Produktionslager mit 64 Stellplätzen bereit auf denen die Platten gestapelt gelagert werden. Ein Einzelzugriff auf die Platten ist also nicht möglich und eine Entnahme der unteren Platten nur mit aufwändigem Umlagern. Um den Zugriff möglichst effizient zu gestalten, müssen die Platten möglichst so eingelagert werden, dass die Teile, die zuerst in der Produktion benötigt werden, oben auf den Stapeln liegen. Die Schwierigkeit ist jedoch, dass zum Zeitpunkt der Einlagerung nicht alle Produktionsaufträge vorliegen.

Aufgabenstellung

Die Student:in soll in dem Projekt Verfahren aus dem Bereich des Maschinellen Lernens nutzen, um auf Basis der historischen und der aktuell bereits verfügbaren Aufträge ein fallspezifisches realistisches Lastszenario der Produktion bereits zum Zeitpunkt der Einlagerung zu prognostizieren. Auf Basis dieses Lastszenarios soll dann ein Optimierungsalgorithmus implementiert werden, der eine möglichst gute Einlagerungsreihenfolge und Stapelplatzzuordnung berechnet. Die Lösung soll mit echten Produktionsdaten validiert werden.

Bezug zum Thema Data Science

Die verwendeten Methoden des Maschinellen Lernens sind Bestandteil der Veranstaltung im Forschungsmaster und Kernbereiche der Data Science.

Verfügbare Ressourcen

- Daten und Fachexperten aus der Produktion werden von Febrü bereitgestellt
- Hardware für Machine Learning ist über das Data Science Lab, das CfADS, sowie dem KI-Rechencluster yourAI der HSBI verfügbar

Projektplan

Erstes Semester: Erstellung eines Forschungsexposés als Prüfungsleistung. Einarbeitung in die Aufgabenstellung im Unternehmen, Sichtung der Daten und Definition der Optimierungskriterien.

Zweites Semester: Literaturrecherche zur zu Verfahren des maschinellen Lernens insbesondere zu Auftragsprognose. Implementierung und eines ersten Verfahrens. Erstellung eines Papers, das einen Überblick über das Forschungsgebiet gibt, ist Prüfungsleistung.

Drittes Semester: Vergleich unterschiedlicher Verfahren zur Auftragsprognose und Auswertung der Ergebnisse. Veröffentlichung eines Papers mit den ersten Ergebnissen ist Prüfungsleistung.

Viertes Semester: Masterarbeit und Kolloquium. Implementierung des Optimierungsverfahren auf Basis der Prognostizierten Aufträge und Validierung der Ergebnisse mit echten Produktionsdaten.

Eignungskriterien

Zwingend:

- Programmierkenntnisse (vzw. Python)

Optional:

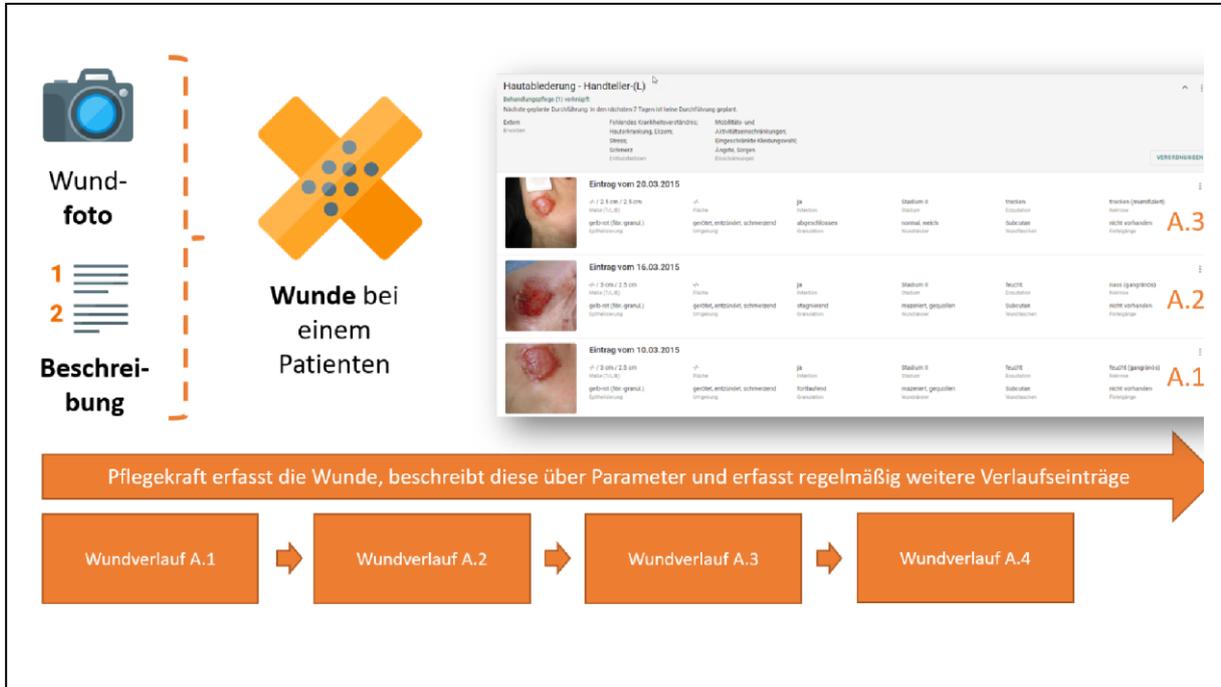
- Erfahrung mit Maschinellem Lernen
- Erfahrung mit Optimierungsverfahren
- Erfahrung in Produktion und Logistik

Erwerbbarer Kompetenzen

- Maschinelle Lernverfahren zur Auftragsprognose
- Optimierungsverfahren zur Produktionssteuerung
- Produktions- und Logistik Knowhow in der variantenreichen diskreten Fertigung
- Publikation von wissenschaftlichen Veröffentlichungen auf internationalen Konferenzen
- Kompetenzen in der Arbeit im Team

Forschungsprojekt für den Forschungsmaster Data Science

Projekttitel: 15 Assistenz bei der Wundversorgung mittels Künstlicher Intelligenz zur Wundanalyse, -einschätzung und -versorgung



Projektübersicht

Anzahl Studierende	1
Art	Projekt mit externen Partnern
Projektverantwortung	Prof. Dr.-Ing. Wolfram Schenck , Björn Gorniak (Connex Communication GmbH), medizinische Unterstützung durch Prof. Dr. med. Rena Amelung
Projektkontext	Projekt in Zusammenarbeit mit der Firma Connex Communication GmbH aus Paderborn sowie dem Center for Applied Data Science Gütersloh

Abstrakt

Das Ziel des Projekts ist es, den Heilungsverlauf von Wunden mittels optimaler Behandlung sowie fachgerechter Therapie zu verbessern, und zwar im Kontext der Wundversorgung in der Altenhilfe und pflege. Die Aufgabe von Verfahren der künstlichen Intelligenz (KI) ist dabei, Bilder von Wunden bezüglich verschiedener Merkmale automatisch zu klassifizieren. Darauf aufbauend sollen Wundverläufe vorhergesagt und Behandlungsempfehlungen generiert werden, um Pflegekräfte in ihrer täglichen Arbeit zu unterstützen.

Kurzbeschreibung

Das Ziel des Projekts *Assistenz bei der Wundversorgung mittels Künstlicher Intelligenz zur Wundanalyse, -einschätzung und -versorgung* ist es, den Heilungsverlauf von Wunden mittels optimaler Behandlung sowie fachgerechter Therapie zu verbessern. Grundlage dafür ist die Wundversorgung in der Altenhilfe und -pflege.

In der Altenhilfe entstehen aufgrund veränderter Hautzustände und Druckbelastung sogenannte Druckgeschwüre (Dekubitus). Ein Dekubitus kann entstehen, wenn das (Haut-)Gewebe langfristig einem starken Druck und einer nicht mehr gewöhnlichen Belastung ausgesetzt ist. Durch das Zusammenpressen von Blutgefäßen werden die Zellen nicht mehr versorgt und sterben ab [<https://de.wikipedia.org/wiki/Dekubitus>]. Es entsteht eine Wunde, die im Alter in der Regel nicht mehr gut verheilt. Diese Wunden müssen nun professionell behandelt und versorgt werden.

Dabei besteht die Herausforderung, dass Wunden und deren Behandlung einen komplexen Arbeitsprozess darstellen. Besonders ausgebildete Mitarbeiter*innen übernehmen die Bewertung, Behandlungsbeschreibung und Einschätzung der Wunden in Pflegeeinrichtungen. Diese Arbeit ist vor allem durch eine Vielzahl an Erfahrungen und ‚community of practices‘ gekennzeichnet.

Oftmals stellen Abweichungen und besondere Situationen in der Wundveränderung für die behandelnden Pflegekräfte eine besondere Herausforderung dar. Ein assistierendes System soll den Mitarbeitenden in der Pflege die Unterstützung bieten, die Einschätzung des Ist-Zustandes der Wunde korrekt vorzunehmen. Anschließend kann ein intelligentes System aus dieser Einschätzung eine Behandlungstherapie ableiten.

Grundlage für dieses Vorgehen ist die Analyse des Ist-Zustands der Wunde und eine Einschätzung des Wundverlaufs. Dabei steht das Foto der Wunde im Mittelpunkt der Analyse. Es wird – in der Regel – mittels eines Smartphones erfasst und in eine standardisierte Wunddokumentation nach Expertenstandard übernommen. Diese Datenbasis soll verwendet werden, um die gewonnenen Bilddateien durch Bildanalyse einzuschätzen.

Die dabei verwendeten Techniken werden bereits in anderen Wirtschaftszweigen angewendet, z.B. um auf Satellitenbildern eine Veränderung der Infrastruktur von Landflächen [<https://computerwelt.at/news/ki-und-satellitenbilder-gegen-armut-in-afrika/>] vorzunehmen und Strukturveränderungen zu erkennen.

Aufgabenstellung

Der / Die Studierende soll im Rahmen des Projektes maschinelle Lernverfahren (ML) zur Bildanalyse auswählen, ggfs. anpassen und anwenden, die eine Wiedererkennung von Mustern und Strukturen in einem Bild einer Wunde ermöglichen. Verbunden mit den beschreibenden, strukturierten Daten von Wunden ist so ein System möglich, dass anhand eines Wundfotos eine erste Einschätzung zur Unterstützung der versorgenden Pflegekraft generiert.

Im weiteren Projektverlauf soll anhand des Clusterings von Wundverläufen eine umfassendere Bewertung von Behandlungssituationen mit ML-Techniken erreicht werden. Das System soll vor allem zur Entlastung und Unterstützung der Menschen in der täglichen Arbeit angewendet werden.

Wenn es zeitlich möglich ist, ist es wünschenswert, dass dieses Verfahren in Form einer Service-Struktur implementiert wird und als Anwendung zur Verfügung steht.

Problemstellung und Ziele der Teilaufgaben

Das Gesamtziel ist die Verbesserung der Wundheilung für Bewohner/Patienten in der Altenpflege. Da diese Branche von der Herausforderung des Fachkräftemangels besonders betroffen ist und die Versorgungssituation immer komplexer wird, soll entlastet und ein Teil der Aufgaben sinnvoll unterstützt werden.

Im Fokus steht die Betrachtung von komplexen Wunden, die durch eine Vielzahl von Ausprägungen nicht alltäglich für die einzelnen Pflegekräfte sind. Durch spezialisiertes Personal wie pflegerische Wundmanager/-experten ist hier schon eine personelle Problemlösung angegangen worden, doch ist diese durch die Vielzahl an Wundverläufen und -ausprägungen nicht zu beherrschen. Ein zentrales Element ist der Kostenfaktor, der sich aus den drei Bausteinen Hilfsmittel für die Wundtherapie, medizinische Beratung durch Fachärzte und Personalaufwendungen in der täglichen Versorgung zusammensetzt.

Ethisch zielt die Fragestellung auf den Begriff der Pflegebedürftigkeit ab, denn das Entstehen von Wunden sorgt immer für eine Verschlechterung des Allgemeinzustandes. Dieser basiert v.a. auf dem erhöhten Betreuungs- und Versorgungsbedarf einer Person und den emotionalen Implikationen einer Wunde. Zudem entstehen indirekte Kosten wie die Schmerzbehandlung und -therapie, die als Folgen nicht immer berücksichtigt werden.

Von diesem Gesamtziel lassen sich einzelne Aufgabenpakete ableiten, die als Meilensteine bei der Erreichung dienen sollten:

- Analyse der vorhandenen, strukturierten Wund-Daten
- Auswahl / Diskussion eines Analyse-Verfahrens / ML-Verfahrens zur abstrakten Wiedererkennung von Eigenschaften des Wundbildes
- Anpassung / Justierung eines solchen Verfahrens und Optimierung auf die besonderen Ansprüche des Sozial- und Gesundheitswesens
- Umsetzung und Integration in eine bestehende Micro-Service-Architektur

Um dieses zu erreichen, kann auf einen vorhandenen Datenbestand von Pflegedokumentationen zurückgegriffen werden. Diese Wunddaten wurden in den vergangenen Jahren erfasst und können historisch von Kunden der Connex Communication GmbH, die sich beteiligen, analysiert werden. Diese Daten können mittels einer API / Schnittstelle anonymisiert betrachtet werden. Darüber hinaus stehen voraussichtlich Bilddaten aus spezialisierten Behandlungseinrichtungen zur Verfügung.

Anhand dieser vorhandenen Daten sollen Mustern und Kenngrößen ermittelt werden, die wiederkehrend und gleichermaßen in der Bewertung durch die bisherigen Anwender vorgenommen wurden. Diese Kenngrößen sollen fachlich evaluiert werden (nicht durch den / die Studierende/n zu erbringen). Dafür stehen Erkenntnisse und Fachansprechpartner aus diesem Bereich zur Verfügung.

Ähnlich gelagerte Projekte und Studien legen nahe, dass es bereits existierende Verfahren und ML-Instrumente gibt, die eine Einschätzung von Bildern / eine sinnvolle Bildanalyse ermöglichen. Hier ist es wünschenswert, wenn auf bestehenden Verfahren aufgesetzt werden kann und diese etablierten ML-Methoden verwendet werden. Außerdem kann an Vorarbeiten aus einem schon abgeschlossenen Forschungsmasterprojekt zu einer ähnlichen Themenstellung angeknüpft werden.

Bezug zum Thema Data Science

Im Rahmen der Tätigkeit ist es dem Studierenden im Austausch mit den Mitarbeitern der Connex Communication GmbH möglich, die Daten systematisch auszuwerten. Die Versorgungsdaten werden

dabei mittels REST-API aus den Kundensystemen bereitgestellt und durch Vorbehandlung in einheitliche Formate und anonyme Strukturen gewandelt.

Im Rahmen der Nutzung einer Cloud-Plattform können diese Daten verarbeitet und analysiert werden. Als Kooperationspartner steht dabei u.a. die Microsoft Azure Plattform zur Verfügung. Andere Plattformen, die eine sinnvollere Analyse und Bearbeitung ermöglichen, sind aber ebenfalls denkbar.

Verfügbare Ressourcen

Für die Bearbeitung des Projekts kann der Rechencluster am Center for Applied Data Science Gütersloh genutzt werden. Außerdem steht die Infrastruktur der Connex Communication GmbH zur Verfügung. Diese basiert vor allem auf den Cloud-Strukturen der Microsoft Azure Plattform, wenn es um die Analyse geht. Dabei kann dort auf verschiedene Open-Source-KI-Frameworks zurückgegriffen werden. Die Datengrundlage wird gemeinsam mit einem Modell-Anwender zu Beginn erarbeitet und gemeinsam mit der Connex Communication GmbH definiert.

Projektplan

Erstes Semester: Konkretisierung des Forschungsvorhabens und Analyse des Nutzungskontexts. Dies beinhaltet die fachliche Einarbeitung in die Thematik sowie in die technische Cloud-Infrastruktur der Connex Communication GmbH (Produktname Vivendi Assist Services), in der die Datenstrukturen und die fachlichen Prozesse dargestellt werden. Hinzu kommt eine Recherche nach vergleichbaren Ansätzen und Verfahren inklusive Modellbetrachtung anhand von Literaturquellen. Die Erarbeitung eines Forschungsexposés am Ende des Semesters ist Prüfungsleistung.

Zweites Semester: Entwicklung der Analyse und ggfs. Anpassung der benötigten Algorithmen, so dass eine erste Implementierung in Form eines Prototyps erfolgen kann. Verwendung von eingegrenzten Datenbeständen anhand einer Forschungs Kooperation mit einem Connex-Kunden. Die Erstellung eines Papers zum Stand der Forschung (Überblick über das jeweilige Forschungsgebiet) ist Prüfungsleistung.

Drittes Semester: Erweiterung der Analyse auf weitere Datenbestände, um eine Evaluation des Verfahrens vorzunehmen. Fachliche Bewertung anhand eines Beta-Verfahrens in der Verwendung durch den Connex-Kunden. Die Erstellung eines Papers über das Benchmarking der eingesetzten ML-Verfahren ist Prüfungsleistung.

Viertes Semester: Umsetzung des assistierenden Systems in Form als Micro-Services-Architektur zur Analyse von Wundbildern. Gemeinsame Anbindung der Connex Software an diesen Service. Ein angepasstes Einsatzszenario sowie die technische Lösung liegen vor. Die Masterarbeit inklusive Kolloquiums ist Prüfungsleistung.

Eignungskriterien

Zwingend:

- Bachelorabschluss in einer einschlägigen Fachrichtung (Informatik, Elektrotechnik, angewandte Mathematik, Kognitionswissenschaft o.ä.)
- Umfassende Programmierkenntnisse in mindestens einer objektorientierten Programmiersprache
- Gute mathematische Kenntnisse
- Gute Englischkenntnisse

- Teamfähigkeit und Interesse Optional:
- Grundlegende Kenntnisse in der Bildverarbeitung
- Grundlegende Kenntnisse im maschinellen Lernen
- Erfahrung im Erstellen, Trainieren und Evaluieren von tiefen neuronalen Netzen

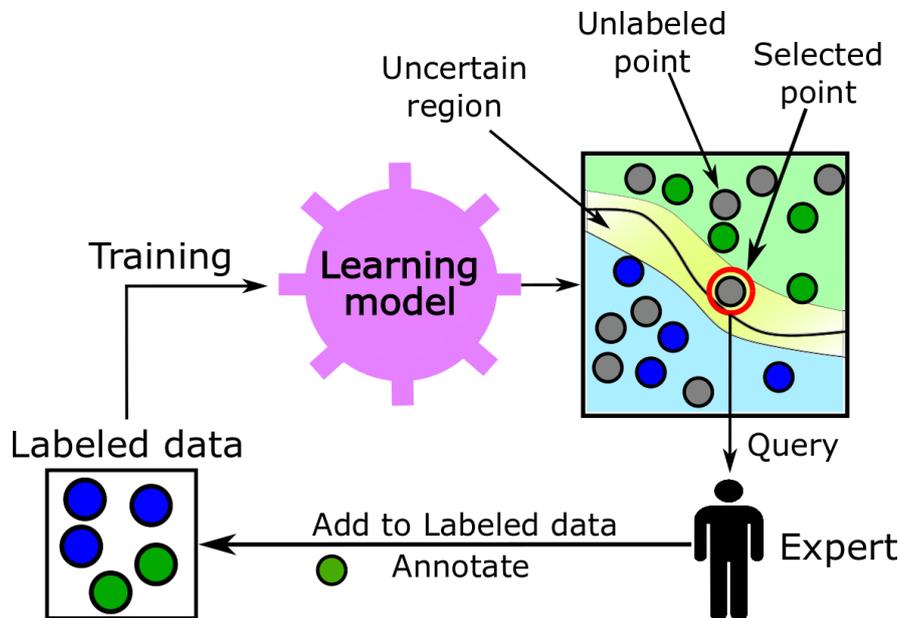
Erwerbbarer Kompetenzen durch das Projekt

Der / die Studierende ist nach Abschluss des Projekts in der Lage,

- einen ML- und Cloud-basierten Datenanalyse-Workflow für die Bilderkennung aufzusetzen,
- die für die Bildverarbeitung relevanten ML-Verfahren zielgerichtet anzuwenden und anwendungsbezogen anzupassen und ggf. weiterzuentwickeln,
- Deep-Learning-Architekturen anwendungsspezifisch auszuwählen und zu designen,
- die theoretischen Anforderungen von ML-Verfahren mit den Erfordernissen der Praxis in einer realen Anwendung in Einklang zu bringen,
- die eigenen Forschungsergebnisse vor einem Fachpublikum zu präsentieren
- und wissenschaftliche Texte zu verfassen.

Forschungsprojekt für den Forschungsmaster Data Science

Project title: 16 Uncertainty Quantification in Active Learning



Project overview

Number of Students	1-2
Project Type	Master Student Project
Project Owner	Dr. Peter Kuchling Dr. Alaa Othman Prof. Dr.-Ing. Wolfram Schenck
Project Context	Project within the Center for Applied Data Science Gütersloh (CfADS) with internal university partners.

Abstract

Despite the vast amounts of data generated by IoT factories, healthcare systems and various industries, much of it remains 'unlabelled', limiting its usefulness for machine learning (ML) models. Labeling data can be expensive and time-consuming, creating a barrier to effective model development. Active Learning (AL) addresses this issue by enabling models to selectively query the most informative and representative data points. This research proposal investigates "Uncertainty Quantification in Active Learning", focusing on improving the selection process within AL frameworks. Using methods such as Bayesian inference and Gaussian processes, together with ensemble techniques, we will investigate how uncertainty quantification affects the efficiency of active learning. The study aims to improve the decision-making process in data selection, potentially advancing applications in areas where obtaining labeled data is difficult and costly.

Zusammenfassung

Trotz der riesigen Datenmengen, die von IoT-Fabriken, Gesundheitssystemen und verschiedenen Branchen erzeugt werden, bleibt ein Großteil dieser Daten „unetikettiert“, was ihren Nutzen für Modelle des maschinellen Lernens (ML) einschränkt. Die Kennzeichnung von Daten kann teuer und zeitaufwändig sein, was die Entwicklung effektiver Modelle behindert. Aktives Lernen (AL) geht dieses Problem an, indem es Modelle in die Lage versetzt, selektiv die informativsten und repräsentativsten Datenpunkte abzufragen. Dieser Forschungsvorschlag untersucht die „Quantifizierung von Unsicherheiten beim aktiven Lernen“ und konzentriert sich auf die Verbesserung des Auswahlprozesses innerhalb von AL-Algorithmen. Mit Hilfe von Methoden wie Bayes'scher Inferenz und Gauß'schen Prozessen sowie Ensemble-Techniken wird untersucht, wie die Quantifizierung von Unsicherheit die Effizienz des aktiven Lernens beeinflusst. Die Studie zielt darauf ab, den Entscheidungsfindungsprozess bei der Datenauswahl zu verbessern und damit Anwendungen in Bereichen voranzutreiben, in denen die Beschaffung gekennzeichnetener Daten schwierig und kostspielig ist.

Short description

In the rapidly evolving machine learning landscape, raw or unlabelled data is becoming very large and free in many areas such as IoT, healthcare and industry. Despite the massive amount of data being generated, the cost and time associated with labelling this data is hindering effective model training. The key challenge is to identify which data points will provide the most value when labelled, ensuring efficient learning without overwhelming resources. The active learning (AL) technique offers a solution by querying the most informative and representative points to form a small but high-quality training data that improves the performance and generalization of learning models. However, there are many AL strategies. In this proposal, we propose to incorporate uncertainty quantification into AL algorithms. By using methods such as Bayesian inference and Gaussian processes, our approach enhances the ability of the model to assess its confidence in predictions. This allows intelligent selection of the most informative data points, rather than random sampling. As a result, we can optimise labelling efforts, reduce costs and improve model performance.

In practice, this methodology is particularly beneficial in environments where data is abundant but labelling is expensive. For example, in a healthcare setting, active learning can identify uncertainties in patient data and guide targeted labelling efforts to improve diagnostic accuracy. This strategic focus not only streamlines the learning process, but also maximizes the use of limited resources, paving the way for more effective machine learning applications across multiple domains.

Task definition

The student(s) will develop and implement a framework for uncertainty quantification in active learning algorithms. This framework will focus on enhancing the selection process for labeling data points in scenarios where unlabeled data is abundant. The goal is to integrate techniques such as Bayesian inference and Gaussian processes to accurately assess uncertainty in model predictions, thereby identifying the most informative data points for labeling. Students will work on refining the algorithm to ensure that it intelligently queries data based on uncertainty metrics, optimizing the labeling process and reducing costs associated with data annotation. The practical application of this framework will be demonstrated in a relevant industrial or healthcare setting, where the effectiveness of active learning can be evaluated in real-world scenarios. By focusing on uncertainty quantification,

this project aims to improve model performance and efficiency, ultimately facilitating more effective machine learning applications in data-scarce environments.

Reference to the topic of data science

The proposed research aligns closely with fundamental data science principles by integrating uncertainty quantification into active learning frameworks. This approach complements the research master's curriculum, which emphasizes advanced methodologies in predictive modeling, data analysis, and decision-making based on data insights. The project offers students the opportunity to explore and apply innovative data science techniques in a practical setting, enhancing their understanding of how uncertainty quantification can improve the efficiency and effectiveness of machine learning models. By focusing on the strategic selection of data points for labeling, students will gain valuable experience in optimizing data-driven processes, ultimately contributing to more effective applications in various fields, including IoT and healthcare.

Available Resources

- **Expert Supervision:** The project benefits from the support of knowledgeable and experienced supervisors who are proficient in data science techniques, including active learning, as well as IoT and industrial applications. Students can draw on this expertise for guidance, feedback, and mentorship during the research process, helping to ensure the quality and relevance of their work.
- **Collaborative spaces:** The CfADS group at HS Bielefeld offers collaborative spaces for students to connect with each other, exchange ideas, and access extra resources. These hubs create an atmosphere that supports interdisciplinary cooperation and encourages a comprehensive approach to solving problems.
- **No additional hardware required:** The project utilizes the current hardware resources in the IoT factory, avoiding the necessity for further investment. Students can easily incorporate their research into the existing infrastructure, facilitating the implementation of adaptive sensor activation through active learning algorithms.

Project plan

First Semester: Project Setup and Exploration

- Conduct a literature review on uncertainty quantification and active learning applications.
- Identify challenges and gaps in integrating uncertainty quantification into active learning.
- Familiarize with theoretical foundations of uncertainty estimation techniques.
- Write a literature review paper summarizing findings.

Second Semester: Initial Development and Prototyping

- Design the architecture for the active learning framework.
- Implement the framework using appropriate programming languages.
- Integrate active learning algorithms for data selection.
- Conduct initial experiments to evaluate performance.
- Analyze results to identify improvements.

Third Semester: System Refinement and Integration

- Evaluate the model on relevant datasets.
- Compare results with baseline and state-of-the-art methods.
- Identify limitations and refine the framework based on findings.
- Write a research paper detailing the evaluation and improvements.

Fourth Semester: Optimization and Final Evaluation

- Explore various experimental scenarios, including dataset sizes.
- Analyze the framework's impact on model performance, convergence speed, and labeling effort.
- Investigate scalability on large datasets and specific applications.
- Summarize results, draw conclusions, and recommend future research directions.
- Write the Master Thesis documenting the entire research process and findings.

Necessary Competencies

Mandatory: Strong programming skills, particularly in languages suitable for ML applications (e.g., Python).

Optional:

- Good mathematical background.

Acquirable Competencies

- Proficiency in uncertainty quantification for active learning.
- Experience with machine learning libraries and programming languages.
- Skills in evaluating model performance against benchmarks.
- Ability to conduct literature reviews and write research papers.
- Experience in designing experiments to assess model variables.

Forschungsprojekt für den Forschungsmaster Data Science

Projekttitle: 17 Predictive Health



Projektübersicht

Anzahl Studierende	1
Art	Studienprojekt (interdisziplinär, fachbereichsübergreifend, praxisnahe Anbindung an ein Reallabor)
Projektverantwortung	Prof. Dr. W. Schenck, Dr. Christoph Ostrau Beraterin: Prof. Dr. Annette Nauerth
Projektkontext	Das Projekt findet im Rahmen des TransCareTech und dessen Reallabor Geriatrie statt. Außerdem ist das Vorhaben an das Center for Applied Data Science (CfADS) Gütersloh und den Fachbereich Gesundheit angebunden.

Abstrakt

In der ambulanten Pflege älterer Patient*innen herrscht akuter Personalmangel mit entsprechender Auswirkung auf die Qualität der Versorgung. Der effiziente Einsatz von Pflegekräften könnte diesen Fachkräftemangel etwas abmildern. Das Reallabor Geriatrie im TransCareTech bietet die Möglichkeit, echte Daten von Patient*innen zu erheben. In diesem Projekt werden Methoden der Data

Augmentation und der Predictive Maintenance genutzt, um Pflegebedarfe vorherzusagen und den Gesundheitszustand unter Positive Health Aspekten zu bewerten.

Kurzbeschreibung

Die Pflegesituation von **geriatrischen Patient*innen** als auch pflegebedürftigen älteren Menschen hat sich in den letzten Jahren verschlechtert. Dabei spielen akuter Fachkräftemangel und finanzieller Druck die Hauptrollen. Aufgrund von fehlender technischer Ausstattung und Standardisierung bleiben Chancen und Möglichkeiten der Digitalisierung oftmals ungenutzt. Im **TransCareTech** wollen wir uns genau diesen Themen widmen, um so langfristig die Situation pflegebedürftiger Mitmenschen zu verbessern.

Das vorgeschlagene Projekt ist eng verzahnt mit dem **Reallabor Geriatrie**, das sich gegenwärtig noch im Aufbau befindet. Dort werden Patient*innen in einer Beispielwohnung nach einer stationären Behandlung geriatrisch rehabilitiert. Neben der technischen Ausstattung der Wohn- und Behandlungsräume, die die Aufnahme von Vital- und Bewegungsdaten ermöglicht, werden die Probanden regelmäßig zu diversen Aspekten befragt. Ein Ziel dieser Arbeit ist die Berechnung eines **Gesundheits-Scores**, der sich nicht nur auf die körperliche Gesundheit bezieht, sondern auch Kategorien wie die mentale Gesundheit, die Lebensqualität und die soziale Einbindung (Stichwort **Positive Health**) mit in den Blick nimmt. Auf Basis der vorliegenden Datenquellen soll bewertet werden, inwieweit ein solcher Score sinnvoll gebildet werden kann. Eine weitere Aufgabe ist es, den sinnvollen Einsatz von Pflegepersonal durch die **Vorhersage von Pflegebedarfen und Pflegenotfällen** zu evaluieren. Hierbei werden KI-Methoden der „**Predictive Maintenance**“ auf vorliegende Fälle übertragen. Da ein solches Vorhaben nur unter der Nutzung großer Datensätze möglich wird, muss dafür zunächst ein **Data Augmentation-Ansatz** verfolgt werden, um den zur Projektzeit vorliegenden Datensatz entsprechend zu vergrößern. Diese Arbeit ist damit eng an die noch aufzubauende **CareDateninfrastruktur** angebunden und bildet einen essenziellen Baustein ebendieser. Eine Rückkommunikation der Scores und deren zeitlichen Verlauf an die Probanden und die behandelnden Fachkräfte verbessert das Selbstmanagement der Patient*innen. Die Einbeziehung in die Aufbauarbeiten ermöglicht eine Teilhabe der Patient*innen an dem Forschungsprojekt.

Aufgabenstellung

Das Projekt besteht aus zwei größeren Zielen: Zum einen dient ein zusammenfassender Score des allgemeinen Gesundheitszustands als Indikator für den Bedarf und Optimierungserfolg ambulanter Pflege. Zum anderen ermöglicht die Datenerweiterung in Bezug auf das Reallabor die anschließende Anwendung maschineller Lernverfahren zur Vorhersage von Pflegebedarfen/-notfällen. Außerdem wird zum Aufbau der Care-Dateninfrastruktur beigetragen. Daher umfasst das Aufgabenspektrum die folgenden Bereiche:

- Datenvorverarbeitung und Katalogisierung der Daten.
- Evaluation der Datenquellen als Grundlage für die Bildung eines Gesundheits-Scores zur Bewertung der Gesamtsituation einer Proband*in unter Positive Health Aspekten.
- Erweiterung des vorhandenen Datensatzes zur Vorhersage von Pflegebedarfen und -notfällen.
- Umsetzung einer KI zur Vorhersage von Pflegebedarfen

Bezug zum Thema Data Science

Die Arbeit ist eng an den Aufbau einer Dateninfrastruktur angebunden. Daher werden die Teilbereiche der Vorverarbeitung und der Archivierung/Strukturierung von Datensätzen behandelt.

Bei der Datenverarbeitung spielt die Bewertung der Datenquellen zur Bestimmung der Gesundheit eine große

Rolle. Um maschinelle Lernverfahren, die auf Big Data angewiesen sind, im Reallabor anwenden zu können, steht Data Augmentation im Mittelpunkt. Zuletzt werden Lernverfahren aus der Predictive Maintenance auf die erhaltenen Datensätze angewandt.

Verfügbare Ressourcen

Für die rechenintensiven Anteile des Projekts stehen die Infrastruktur des CfADS, insbesondere des Data-Analytics-Cluster, zur Verfügung. Die Datengrundlagen bilden Erhebungen im Reallabor Geriatrie des TransCareTech Forschungsprojektes.

Projektplan

Erstes Semester:

Einarbeitung in die Infrastruktur des CfADS, Analyse der im Zusammenhang mit dem Reallabor Geriatrie anfallenden Daten, Literaturrecherche zur Bewertung von ganzheitlichen Gesundheitsaspekten, insbesondere des Positive Health Ansatzes, und zum Thema „Predictive Maintenance“, Überblick über domänenspezifische Datensätze.

Zweites Semester:

Vorverarbeitung der Daten des Reallabors und Einbindung in die Care-Dateninfrastruktur, Einarbeitung in das Thema Data Augmentation.

Drittes Semester:

Augmentieren der Daten des Reallabors, Herausstellung entscheidender Charakteristika von Pflegebedarfen und Generierung synthetischer Daten, Berechnung eines wochengenauen Gesundheits-Scores.

Viertes Semester:

Umsetzung der Vorhersagen (hinsichtlich Versorgungsbedarfe/akuter -notfälle) und Evaluation in dem Reallabor Geriatrie, Vergleich mit dem State-Of-The-Art und Potentialanalyse.

Eignungskriterien

Zwingend:

- Programmierkenntnisse in mindestens einer objektorientierten Sprache
- Englischkenntnisse zur Lektüre englischsprachiger Veröffentlichungen □
Teamfähigkeit

Optional:

- Programmierkenntnisse in Python
- Grundkenntnisse in Hadoop
- Grundkenntnisse in HBase

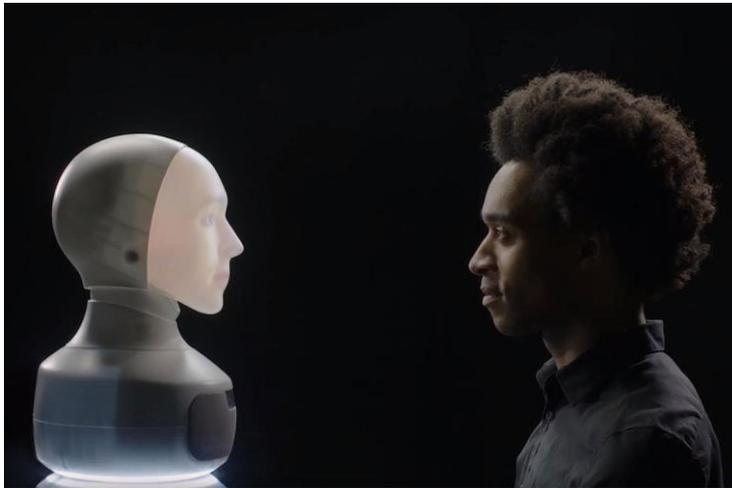
Erwerbbarer Kompetenzen

Der/die Studierende ist nach Abschluss des Projekts in der Lage,

- ML-basierte Verfahren auf großen Datensätzen anzuwenden.
- Datensätze künstlich zu erweitern, um Big Data Methoden in Bereichen mit Sparse Data zu benutzen.
- ML-Verfahren auf sequenziellen Datensätzen anzuwenden. □ wissenschaftliche Publikationen zu verfassen.
- die eigenen Ergebnisse vor einem Fachpublikum zu präsentieren.
- im Team zusammenzuarbeiten und fachbereichsübergreifend zu kommunizieren.

Forschungsprojekt für den Forschungsmaster Data Science

Projekttitle: 18 Mensch-Roboter Interaktion: Design, Implementierung und Nutzung eines humanoiden Roboters als individuellen Gesprächspartner



Projektübersicht

Anzahl Studierende	1 bis 2
Art	Studienprojekt
Projektverantwortung	Prof. Dr. Thomas Süße und Dr. Maria Kobert
Projektkontext	Mögliche Anstellung als HiWi ist abhängig von vorhandenen finanziellen Ressourcen. Zusammenarbeit mit Unternehmen ebenfalls denkbar.

Abstrakt

Die Interaktion zwischen Menschen und sozialen humanoiden Robotern ist ein zentraler Bestandteil der Mensch-Maschine Interaktion der Zukunft. Soziale Roboter können mit uns Menschen so kommunizieren, wie wir es miteinander tun - indem sie sprechen, zuhören, Emotionen zeigen und Augenkontakt halten. Sie können zum Beispiel eingesetzt werden, um Kunden zu bedienen, Gesellschaft zu leisten, Mitarbeiter*innen zu schulen oder eine Sprache zu unterrichten. Ein Beispielsszenario mit dem am Campus vorhandene Roboter Furhat wird in diesem Video gezeigt:

<https://www.youtube.com/watch?v=3IEQDf9Cv4s>

Trotz der vielen Einsatzmöglichkeiten und der großen Nachfrage stellen sich bei der Entwicklung und dem Einsatz dieser vielversprechenden Technologien neue Herausforderungen bezüglich der Passung bzw. Kompatibilität zwischen Bedürfnissen und Anforderungen der Nutzenden und humanoiden Robotern dar. Eine Herausforderung liegt darin, die Roboter bezüglich Sprache, Mimik und Gestik so zu konfigurieren, dass Sie den individuellen Bedürfnissen der Nutzer gerecht werden. An diesem Punkt setzt das vorliegende Projekt an. Das übergeordnete Ziel ist es, den humanoiden Roboter Furhat, der dem Fachbereich Ingenieurwissenschaften und Mathematik am Campus Gütersloh bereits zur

Verfügung steht, so zu konfigurieren, dass er in zu definierenden praktischen Anwendungsszenarien angemessen mit Menschen interagieren kann. Hierzu soll Furhat zunächst in die Lage versetzt werden, in einem bestimmten praktischen Szenario mit Menschen kommunizieren und kollaborieren zu können. Das praktische Szenario wird gemeinsam mit den Projektbetreuenden und den Studierenden definiert. Zudem soll mit Hilfe des maschinellen Lernens erreicht werden, dass der Roboter aus den Interaktionen mit seinen menschlichen Gesprächspartnern lernt und sich an dessen Sprache, Mimik, Gestik, Vorlieben und Gesprächsinhalte erinnert. Furhat soll somit „seine Fähigkeiten ausbauen“ und als akzeptierter, angenehmer sowie hilfreicher Gesprächspartner von seinem menschlichen Gegenüber wahrgenommen werden. Begleitend zur technischen Weiterentwicklung von Furhat sollen die Interaktionen zwischen den menschlichen Probanden und Furhat auch aus der Perspektive des Menschen untersucht werden. Hierbei soll ein experimentelles Setting aufgebaut werden, das spezifische Varianten von Konfigurationen hinsichtlich des „Auftretens“ (insb. Mimik, Sprache, Optik) von Furhat und deren Wirkung auf den menschlichen Gegenüber untersucht.

Kurzbeschreibung

Gegenwärtig nimmt die Bedeutung der Interaktion zwischen Menschen und sozialen Robotern fortwährend zu. Der Einsatz von sozialen Robotern verbreitet sich immer mehr, im Gesundheitsbereich, im Bildungsbereich, in Hotellerie und Gastronomie, in Shopping Malls, in der Industrie und im Haushalt. Mögliche Einsatzfelder sind u.a. die Information sowie die Aktivierung von älteren Personen, der Support in pflegenahen Dienstleistungen, die Förderung von Kindern und Jugendlichen z.B. mit autistischen Krankheitsbildern, die Hausaufgabenbetreuung bzw. generell die Wissensvermittlung im Aus- und Weiterbildungsbereich oder der Empfang und die Begleitung von Besucherinnen und Besuchern in Firmen, Organisationen oder Einkaufszentren. Trotz der vielen Potenziale, die solche Roboter mit sich bringen, sind jedoch auch zahlreiche Herausforderungen mit deren Einsatz verbunden. Beispielsweise weisen erste Studien mit menschlichen Probanden eine geringe Akzeptanz der Roboter bei den Menschen auf. Um die Akzeptanz zu erhöhen, besteht eine zentrale Herausforderung darin, die Roboter bezüglich Sprache, Mimik, Gestik und Optik so zu konfigurieren, dass Sie den Bedürfnissen der Nutzer gerecht werden. Dies soll das übergreifende Ziel des vorliegenden Projektes sein. Hierzu soll ein lernender Algorithmus entwickelt werden, der Furhat in die Lage versetzt, sich an die Besonderheiten der menschlichen Gesprächspartner*innen zu erinnern und sich diesen anzupassen.

Die forschungsleitende Frage des Projektes ist: Wie kann Furhat Personen kennenlernen und sich an diese erinnern?

Zu diesem Zweck soll mit dem sozialen humanoiden Roboterkopf Furhat gearbeitet werden, der vom schwedischen Unternehmen Furhat Robotics entwickelt wurde und vertrieben wird. Der Furhat ist ein Roboterkopf ohne Gliedmaße mit einem auf die Innenseite projizierten Gesicht, bei dem die äußere Erscheinung wie die Hautfarbe, die Position der Augenbrauen und das Make-up angepasst werden kann. Der Furhat Roboter realisiert dadurch sanfte Gesichtszüge und kann sich durch natürliche Bewegungen wie Kopfschütteln und Kopfnicken direkt an einem Gespräch beteiligen. Mit einer modernen Spracherkennung, einem fortschrittlichen Konversationssystem sowie einer automatisierten Lippensynchronisation werden ausdrucksstarke Charaktere geschaffen.

Zunächst steht der Furhat den Studierenden als Rohversion zur Verfügung. Dieser soll in einem ersten Schritt anhand eines praktischen Szenarios (Use Case) konfiguriert und interaktionsfähig gemacht werden. Im zweiten Schritt sollen regelmäßige Interaktionen mit menschlichen Probanden durchgeführt werden, z.B. wöchentliche Treffen. Mit Hilfe des maschinellen Lernens soll Furhat im Zuge der gemeinsamen Treffen eine Gesprächshistorie aufbauen und sich so an vergangene Gespräche mit bestimmten Personen erinnern können. Hierzu soll ein lernender Algorithmus entwickelt werden,

der es Furhat ermöglicht, sich an sein jeweiliges Gegenüber, dessen Sprache, Mimik, Gestik, Vorlieben und Gesprächsinhalte zu erinnern und diese wieder abrufen zu können. Furhat soll demnach die Fähigkeit entwickeln, als "Gesprächspartner" für Menschen an Informationen und Ergebnisse vergangener Gespräche anzuknüpfen und diese weiterzuführen. Dies kann an einem praktischen Szenario (Use Case), bei dem eine gemeinsame Aufgabe zwischen Mensch und Furhat über mehrere Gesprächstermine hinweg gelöst werden soll, erfolgen. Begleitend dazu wird mit Hilfe von Interviews und Beobachtungen die Mensch-Roboter Interaktion aus menschlicher Perspektive untersucht.

Aufgabenstellung

1. Der als Rohversion bereitgestellte humanoide Roboterkopf Furhat wird anhand eines praktischen Szenarios (Use Case) konfiguriert und interaktionsfähig gemacht.
2. Ein lernender Algorithmus wird entwickelt, der es Furhat ermöglicht, im Zuge regelmäßig stattfindender Interaktionen mit bestimmten Personen im Zuge des unter 1. entwickelten Use Case sich an sein jeweiliges Gegenüber, dessen Sprache, Mimik, Gestik, Vorlieben und Gesprächsinhalte zu erinnern.
3. Mit Hilfe von Interviews und Beobachtungen zu den stattgefundenen Interaktionen wird die Mensch-Roboter Interaktion aus menschlicher Perspektive untersucht.

Bezug zum Thema Data Science

Es wird ein lernender Algorithmus entwickelt.

Verfügbare Ressourcen

Der Roboterkopf Furhat und die notwendige Software, um den Roboter zu programmieren wird den Studierenden zur Verfügung gestellt.

Projektplan

Erstes Semester: Erstellung eines Forschungsexposés ist Prüfungsleistung.

Zweites Semester: Erstellung eines Papers, das einen Überblick über das jeweilige Forschungsgebiet gibt, ist Prüfungsleistung.

Drittes Semester: Erstellung eines Papers, mit ersten quantitativen Ergebnissen ist Prüfungsleistung.

Viertes Semester: Masterarbeit und Kolloquium

Eignungskriterien

Zwingend: Programmierkenntnisse, vorzugsweise in Python

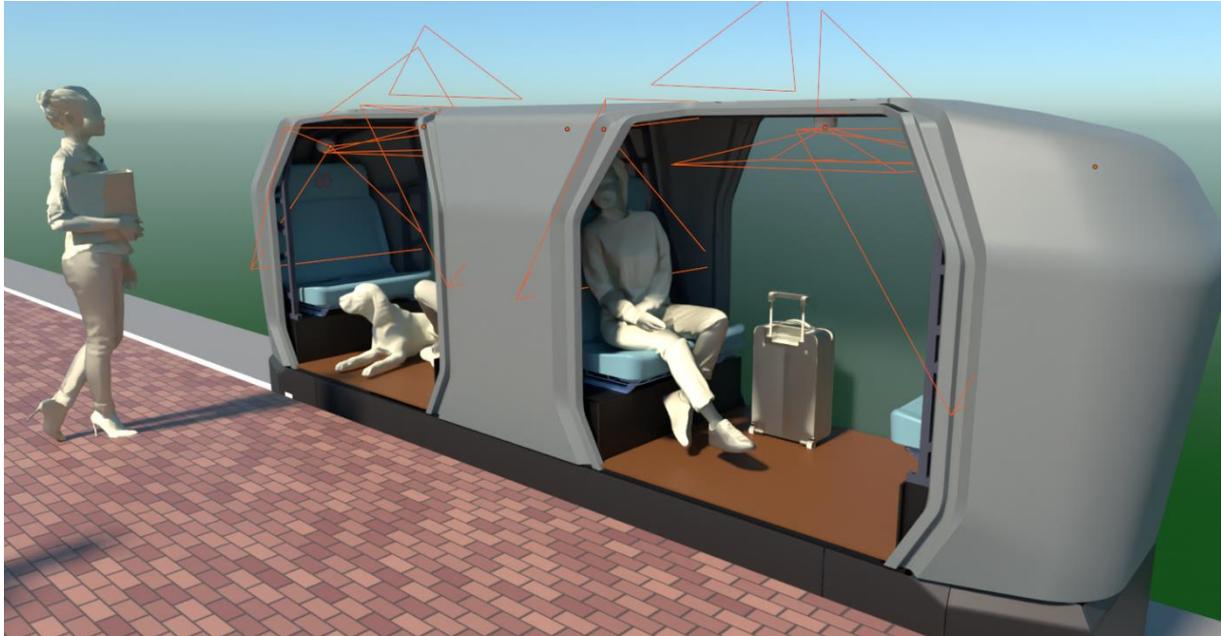
Optional: Kenntnisse im Durchführen von sozialwissenschaftlichen Studien (z.B. Durchführung von Interviews)

Erwerbbarer Kompetenzen

- Erprobung eines humanoiden Roboters
- Verfahren der künstlichen Intelligenz zur Problemlösung
- Mensch-Roboter-Interaktion

Forschungsprojekt für den Forschungsmaster Data Science

Projekttitel: 19 Sensorfusion und KI-gestützte Datenanalyse zur Innenraumüberwachung autonom fahrender Züge



Projektübersicht

Anzahl Studierende	1
Art	Gefördertes Forschungsprojekt
Projektverantwortung	Prof. Dr. Thorsten Jungeblut
Projektkontext	Zusammenarbeit mit dem Projekt enableATO ; parallele Anstellung als wissenschaftliche Hilfskraft ist möglich

Abstrakt

Ziel des Projekts ist die Entwicklung eines Systems zur Innenraumüberwachung autonomer Züge durch Sensorfusion und KI-Methoden. Dabei werden verschiedene Sensortypen kombiniert, um Gefahrensituationen zuverlässig zu erkennen. Die wissenschaftliche Herausforderung liegt in der Auswahl geeigneter Sensoren, der Bewertung verschiedener Fusionsansätze und der Anwendung von KI-Algorithmen. Am Ende entsteht eine Lösung, die die robuste Überwachung gewährleistet und somit die Sicherheit in autonomen Zügen verbessern kann.

Kurzbeschreibung

Die Mobilität der Zukunft muss ressourcenschonend, nutzerorientiert und innovativ sein. Das Projekt **enableATO** adressiert diese Anforderungen durch die Entwicklung autonomer Schienenfahrzeuge (Grade of Automation Level 4) für den Einsatz in ländlichen Räumen. Ziel ist es, kleinere, automatisierte Fahrzeuge zu nutzen, um eine nachhaltige und effiziente Mobilität zu fördern sowie die Reaktivierung stillgelegter Strecken zu ermöglichen.

Ein zentraler Aspekt autonomer Züge ohne Begleitpersonal ist die Gewährleistung von Sicherheit und Nutzerfreundlichkeit. Der Innenraum dieser Züge muss kontinuierlich überwacht werden, um

Ereignisse wie Stürze, Hilfebedarf oder unvorhergesehene Notfälle frühzeitig zu erkennen. Unterschiedliche Sensortypen wie RGB-Kameras, Radar und Infrarot bieten jeweils spezifische Vorteile, stoßen jedoch unter widrigen Bedingungen oder bei komplexen Szenarien an ihre Grenzen.

Die **Sensorfusion** kombiniert verschiedene Sensortypen, um die Robustheit und Genauigkeit der Überwachungssysteme zu verbessern. Zusätzlich spielt die Auswertung der Sensordaten durch **Machine Learning- und Deep Learning-Methoden** eine entscheidende Rolle, um komplexe Szenarien im Innenraum zu bewältigen. KI-gestützte Ansätze ermöglichen die präzise Analyse von Bewegungsmustern, die Erkennung von Gefahrensituationen und die Durchführung von Echtzeitreaktionen, beispielsweise bei Stürzen oder Verhaltensauffälligkeiten von Fahrgästen.

Das Projekt untersucht, wie Sensorfusion und KI-gestützte Datenanalyse zur Innenraumüberwachung in autonom fahrenden Zügen eingesetzt werden können, um Sicherheitsrisiken zu minimieren und die Benutzerfreundlichkeit zu maximieren. Im Rahmen von **enableATO** werden technologische Grundlagen für die Mobilität von morgen geschaffen, die die Schienenverkehrssysteme effizienter, intelligenter und sicherer machen.

Aufgabenstellung

In diesem Projekt entwickeln die Studierenden ein System zur Sensorfusion und KI-gestützten Innenraumüberwachung, das speziell auf die Erkennung von Gefahrensituationen in autonomen Zügen ausgerichtet ist.

Dazu sollen geeignete Sensortypen identifiziert werden, die sich für den konkreten Anwendungsfall eignen und sich in ihrer Funktionalität ergänzen. Des Weiteren sollen geeignete ML- und KI-Algorithmen sowie Fusionstechniken ausgewählt und evaluiert werden, um die Sensordaten effektiv zu kombinieren und eine präzise Gefahrenerkennung zu gewährleisten. Die Untersuchung umfasst das Training und den Vergleich von Algorithmen auf Basis der ausgewählten Sensorkombinationen.

Das Ziel ist die Entwicklung eines Prototyps, der aus einer geeigneten Sensorkombination besteht und durch passende KI-Modelle sowie ein Fusionsverfahren realisiert wird. Aus der Arbeit soll hervorgehen, welche Sensoren, KI-Algorithmen und Fusionstechniken die beste Performanz für den Anwendungsfall bieten.

Bezug zum Thema Data Science

Die Bewertung und Anwendung von KI/ML-Methoden, wie beispielsweise der Einsatz von Convolutional Neural Networks (CNNs) in der Bilderkennung oder von Zeitreihenanalysen, sind zentrale Themen der Data Science und werden in den Modulen „Advanced Machine Learning“ und „Artificial Intelligence“ vertieft behandelt. Zudem steht die Aufnahme von Daten durch verschiedene Sensoren im Fokus, was hohe Anforderungen an die Organisation und Verarbeitung der Daten stellt und im Modul „Big Data Architectures“ behandelt wird. Nicht zuletzt ist die Datenanalyse ein wesentlicher Bestandteil des Projekts, was im Modul „Data Mining & Machine Learning“ ausführlich behandelt wird.

Verfügbare Ressourcen

- **Systeminformationen:** Informationen, die zur Erstellung des Szenarios benötigt werden (z.B. Systembeschreibung, relevante Kennzahlen), werden durch die Ansprechperson von enableATO bereitgestellt.
- **Sensoren:** Benötigte Materialien wie die zu untersuchenden Sensoren werden vom Projekt enableATO zur Verfügung gestellt.

- **Mockup des Fahrzeuginnenraums:** Ein Mockup des Fahrzeuginnenraums steht zur Verfügung, in dem Testdaten aufgenommen werden können.
- **Rechenressourcen:** Hardware für das komplexere Maschine Learning ist über das Data Science Lab, das CfADS, sowie dem KI-Rechencluster yourAI der HSBI verfügbar.
- **Projektbetreuung:** Eine Ansprechperson von enableATO wird über die Projektlaufzeit zur Verfügung stehen.

Projektplan

Erstes Semester: Erstellung eines Forschungsexposés ist Prüfungsleistung. Einarbeitung in das Konzept verschiedener Sensortechnologien, Fusion-Methoden und KI-Algorithmen (CNN, DNN), insbesondere der Objekterkennung und Bilderkennung.

Zweites Semester: Erstellung des Systemkonzepts für die Sensorfusion mit Blick auf den konkreten Anwendungsfall. Recherche zu relevanten Arbeiten im Bereich Sensorfusion für Innenraumüberwachung und zugehöriger Einsatz von KI-Verfahren. Erstellung eines Papers, das einen Überblick über das jeweilige Forschungsgebiet gibt, ist Prüfungsleistung.

Drittes Semester: Praktische Umsetzung der Sensorfusion mit konkreten Sensoren und eigener Datenerhebung. Umsetzung verschiedener Fusion-Methoden und maschineller Lernverfahren zur Gefahrenerkennung sowie deren Evaluation. Erstellung eines Papers, mit ersten quantitativen Ergebnissen als Prüfungsleistung.

Viertes Semester: Masterarbeit und Kolloquium. Finale Evaluation durch Vergleich der implementierten Strategien.

Eignungskriterien

Zwingend:

- Gute Erfahrung mit Python

Optional:

- Erfahrung mit dem Versions-Kontroll-System „git“
- Erste Erfahrung zu Datenanalysen
- Erste Erfahrung in den Python-Bibliotheken PyTorch, TensorFlow oder Scikit-Learn

Erwerbbarer Kompetenzen

Kompetenzen, die durch das Projekt erworben werden

- Sensorfusion
- KI/ML-Methoden
- Sensornähe Informationsverarbeitung
- Kompetenzen in der Arbeit im Team

Forschungsprojekt für den Forschungsmaster Data Science

Projekttitle: 20 NLP-Driven Configuration for Mass Customization (NLP-KiMaC)



Projektübersicht

Anzahl Studierende	1
Projektart	Gefördertes Projekt mit externen Partnern
Projektverantwortung	Prof. Dr. Stefan Berlik / Dr. Mohammad Seidpisheh
Projektkontext	Eine interdisziplinäre Forschungsinitiative in Zusammenarbeit mit produzierenden Unternehmen, die sich auf die Umsetzung von Mass Customization unter Verwendung von Techniken der natürlichen Sprachverarbeitung (NLP) konzentriert. Es besteht die Möglichkeit einer Beschäftigung als wissenschaftliche Hilfskraft.

Kurzbeschreibung

Das Projekt zielt darauf ab, Produktionsprozesse durch NLP-gestützte Mass Customization neu zu definieren, indem es die Personalisierung von maßgeschneiderten Produkten mit der Effizienz der Massenproduktion kombiniert. Durch den Einsatz von NLP-Technologien konzentriert sich das Projekt darauf, intuitive und automatisierte Konfigurationssysteme zu ermöglichen, die die Benutzerinteraktion verbessern und die Produktionsabläufe rationalisieren. Zu den wichtigsten Innovationen gehört die Entwicklung intelligenter Assistenten für die Produktkonfiguration und die

Optimierung von Fertigungsaufträgen, die statische und manuelle Konfigurationsabläufe in automatisierte, skalierbare und benutzerfreundliche Prozesse umwandeln.

Aufgabenbeschreibung

Das KiMaC-Projekt ist ein innovatives Vorhaben im Bereich der Mass Customization, die das Know-how der GRAUTHOFF Türengruppe GmbH und der Solarlux GmbH mit fortschrittlichen KI-Technologien kombiniert, um die Produktion von Türen und Glasfaltwänden zu optimieren. Die Initiative hebt nicht nur die technologische Innovation hervor, sondern auch die Nachhaltigkeit und die Anpassungsfähigkeit, die KI in die Fertigungsprozesse einbringt. Das vorgeschlagene Folgeprojekt wird sich auf die Integration von NLP-Techniken in das KiMaC-Projekt konzentrieren.

GRAUTHOFF und Solarlux werden zum Projekt reale Produktionsszenarien beisteuern und Betriebsdaten bereitstellen, um die Entwicklung und Validierung der NLP-gestützten Konfigurationssysteme zu unterstützen. Ihre Beteiligung stellt sicher, dass die Lösungen praktisch und effektiv sind und den Anforderungen der Industrie entsprechen. Das NLP-KiMaC-Projekt zielt darauf ab, NLP-Technologien zu nutzen, um den Konfigurationsprozess zu rationalisieren und eine benutzerfreundliche und effiziente Produktion von hoch personalisierten Produkten zu ermöglichen. Diese intelligenten Systeme ermöglichen eine bessere Kommunikation zwischen den Beteiligten, eine höhere Präzision beim Design und schnellere Produktionszyklen ohne Qualitätseinbußen.

Die Synergie zwischen dem Know-how von GRAUTHOFF und Solarlux, gepaart mit dem transformativen Potenzial von NLP versetzt NLP-KiMaC in die Lage, Interaktion, Effizienz und Personalisierung in der Fertigung neu zu definieren.

Problemstellung und Ziele

Der Studentin / dem Studenten kommt die Schlüsselrolle bei der Integration von NLP-Techniken in den Konfigurationsprozess zu, die dafür sorgt, Konfiguration in eine nahtlos integrierte und effiziente Aufgabe zu verwandeln. Zu den Hauptaufgaben gehören:

- 1. Entwicklung von NLP-gesteuerten Konfigurationssystemen:**
Entwerfen intuitiver Systeme, die es den Benutzern ermöglichen, auf natürliche Weise mit Konfigurationssystemen über dialogorientierte Schnittstellen zu interagieren und so komplexe Arbeitsabläufe zu vereinfachen.
- 2. Entwicklung intelligenter Assistenten für die Konfiguration:**
Erstellung von NLP-gestützten Assistenten, die Vorschläge in Echtzeit machen, die Entscheidungsfindung vereinfachen und Konfigurationsfehler reduzieren.
- 3. Evaluierung integrierter Systeme:**
Bewertung der Benutzerfreundlichkeit, Geschwindigkeit und Skalierbarkeit von Systemen in realen Produktionsumgebungen, um ihre Effizienz und Auswirkungen auf die Anpassungsprozesse zu validieren

Bezug zum Thema Data Science

Das Projekt integriert zentrale Data-Science-Methoden, darunter natürliches Sprachverständnis, maschinelles Lernen und prädiktive Modellierung. Mit diesen Technologien werden reale Herausforderungen angegangen, darunter die Vereinfachung von Konfigurationsprozessen, die genaue Erfassung von Kundenanforderungen und die Gestaltung effizienter Benutzerinteraktionen.

Vorhandene Ressourcen

Die Zusammenarbeit mit Industriepartnern bietet Zugang zu realen Produktionsumgebungen, Betriebsdaten und IT-Infrastrukturen für die Entwicklung und Implementierung von KI-Modellen und Systemen in der Praxis. Für die Entwicklung wird eine moderne Cloud-Umgebung genutzt, die der Hochschule bereitgestellt wird und das Projekt durch umfangreiche Rechenressourcen für ML-Training und Optimierungsaufgaben unterstützt.

Grober Projektplan

Erstes Semester: Forschungsexposé über den Entwurf von NLP-gesteuerten Konfigurationssystemen und die erste Integration von KI-Modellen.

Zweites Semester: Systematische Literaturrecherche zu NLP-Anwendungen im Bereich Mass Customization und User Interaction Design.

Drittes Semester: Entwicklung und Test von NLP-gestützten Konfigurationssystemen in simulierten Umgebungen.

Viertes Semester: Masterarbeit mit Schwerpunkt auf der Integration, Bewertung und Optimierung dieser Systeme in realen Produktionsumgebungen, gefolgt von einem Kolloquium.

Benötigte Kompetenzen der Bewerberin oder des Bewerbers

Zwingend:

- Bachelor-Abschluss mit Schwerpunkt Informatik, Data Science oder einem verwandten Fachgebiet.
- Fortgeschrittene Kenntnisse in Programmiersprachen wie Python.
- Grundlegendes Verständnis von maschinellem Lernen, Statistik und Optimierung.
- Interesse an der Anwendung von NLP und KI auf industrielle Herausforderungen.

Optional:

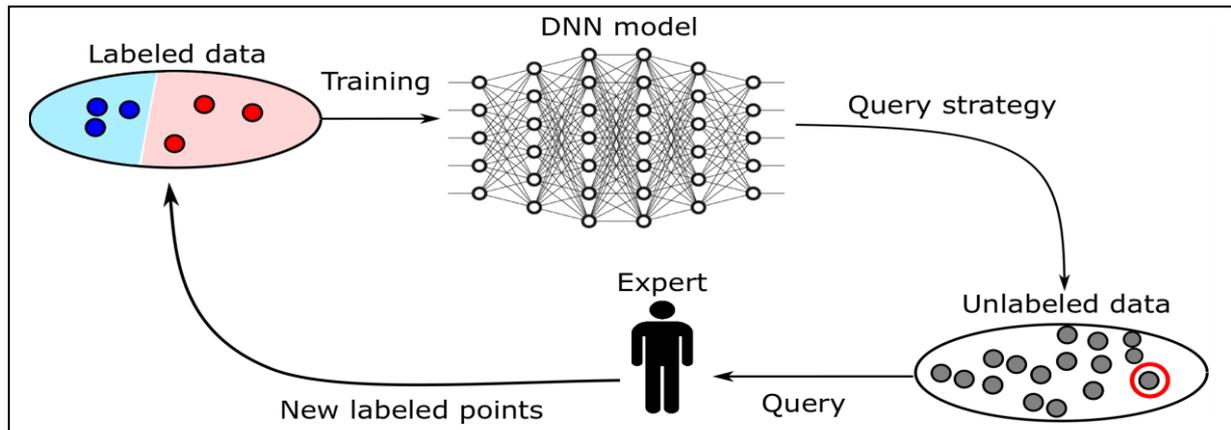
- Erfahrung mit fortgeschrittenen NLP-Techniken.

Erwerbbarer Kompetenzen durch das Projekt

- Erfahrung in der Anwendung von NLP-Technologien auf komplexe, reale Herausforderungen in der Personalisierung und Fertigung.
- Tiefgreifendes Verständnis von Mass Customization Workflows unter Verwendung von NLP.
- Erweiterte Forschungskompetenzen durch die Konzeption, Entwicklung und Evaluierung modernster NLP-Systeme in einem interdisziplinären Kontext.
- Erweiterte Forschungskompetenzen durch die Entwicklung, Implementierung und Evaluierung von innovativen KI-Systemen in einem interdisziplinären Umfeld.

Research Project for the Research Master Data Science

Project title: 21 Deep Active Learning: Smart Training Data Selection for Deep Learning models



Project overview

Number of Students	1-2
Project Type	Master Student Project
Project Owner	Dr. Alaa Othman Prof. Dr. Wolfram Schenck
Project Context	Project within the Center for Applied Data Science Gütersloh (CfADS) with internal university partners.

Abstract

In deep learning, the performance of neural networks depends heavily on the quality and quantity of training data. Traditional approaches often use random or predefined sampling methods for data selection, which may not fully exploit the potential of the available data. This research project explores the benefits of deep active learning, which intelligently selects training data to improve the performance of deep neural networks. By combining active learning techniques with deep learning frameworks, we aim to improve model accuracy, generalization, and efficiency. The goal of this project is to investigate different active learning strategies and their impact on deep learning tasks such as image classification and image segmentation. Through extensive experimentation and analysis, we aim to demonstrate the effectiveness of intelligent training data selection in unleashing the full potential of deep learning models. The results of this research will help advance the field of deep learning by providing valuable insights into the benefits and practical applications of deep active learning for intelligent training data selection.

Short description

The motivation for this research project stems from the recognition that the performance of deep learning models is highly dependent on the quality and diversity of the training data. However, traditional data selection methods often rely on random or predefined sampling, which may not fully exploit the richness of available data. This limitation poses a significant challenge in achieving optimal performance and generalization in deep learning tasks. Therefore, there is a need to explore innovative approaches that can intelligently select training data to improve the performance of deep neural networks.

The goal of this research project is to investigate the benefits of deep active learning as a solution to the aforementioned challenges. Deep active learning combines active learning techniques with deep learning frameworks to intelligently select the most informative and representative training data points. By actively selecting and incorporating these data points into the training process, we aim to improve the accuracy, generalization, and efficiency of deep learning models. The project will explore different active learning strategies, such as uncertainty sampling or query-by-committee, and evaluate their impact on different deep learning tasks, such as image segmentation or image classification.

The results of this research project will have broad applicability in various domains where deep learning is applied, especially in tasks such as image segmentation and image classification. By using deep active learning, we can improve the performance of deep neural networks in these specific applications. For example, in image segmentation, intelligent selection of training data can lead to more accurate and precise delineation of objects within images. In image classification, deep active learning can optimize the use of training data, leading to improved classification accuracy and robustness. The research results will contribute to the advancement of the field of deep learning by providing practical insights into the application and effectiveness of deep active learning in solving data selection challenges in various domains.

Task definition

The student(s) will develop and implement a deep active learning framework for intelligent data selection in image classification tasks. This framework will use active learning algorithms to identify

informative data points, targeting uncertainties and potential errors. The goal is to optimize the use of training data and overcome challenges associated with large datasets. The student(s) will refine and implement the algorithm, selectively selecting data samples that are sufficiently representative and also informative by quantifying uncertainty. This will improve the efficiency and accuracy of image classification/segmentation models using deep active learning technology. The practical application of this framework will be demonstrated in real-world scenarios, showing its ability to increase data efficiency and improve model performance.

Reference to the topic of data science

This research project is aligned with the core principles of deep learning and active learning algorithms. It offers students the opportunity to explore cutting-edge techniques in deep active learning for image classification tasks. By integrating active learning strategies into the training of deep neural networks, students will gain expertise in optimizing model performance and data efficiency. This project is highly relevant to the Research Master's curriculum, which emphasizes advanced techniques in machine learning and pattern recognition.

Available Resources

No additional hardware required: One of the advantages of this deep active learning research project is that it does not require any additional hardware. Students can use existing computing resources, such as personal computers or our clusters, to develop and implement the deep active learning framework. This eliminates the need for significant financial investment in specialized equipment, making the project more accessible and feasible for students to pursue.

Expert supervision: This deep active learning research project benefits from expert supervision, providing students with guidance and support from experienced researchers and faculty members. Their expertise in deep learning and active learning algorithms ensures that students receive valuable insight and support throughout the project to help them make informed decisions and achieve meaningful results.

Collaborative spaces: The research project provides access to collaborative spaces where students can engage with other researchers and exchange ideas. These spaces foster a collaborative and stimulating environment that encourages discussion, brainstorming, and knowledge sharing. By working with peers, students can benefit from diverse perspectives and collective problem solving, enhancing the overall quality and depth of their research.

Project plan

First Semester: Understanding and Literature Review

- Conduct a comprehensive literature review on deep active learning methods and their applications to image classification/segmentation tasks.
- Identify key challenges and gaps in the current research landscape.
- Become familiar with the theoretical foundations and algorithms of deep and active learning.
- Develop a clear research question or hypothesis to guide the subsequent phases of the project.
- Write a paper of a literature review is the mandatory artefact.

Second Semester: Framework design and implementation

- Design an architecture for the deep active learning framework, taking into account key components such as data selection, uncertainty estimation, and model training.
- Implement the framework using appropriate deep learning libraries and programming languages.
- Integrate active learning algorithms to intelligently select training data points based on uncertainty and information gain metrics.
- Collect initial results.

Third Semester: Evaluation and performance optimization

- Evaluate the implemented model on appropriate datasets.
- Compare and analyze results against baseline approaches and existing state-of-the-art methods.
- Identify potential limitations or areas for improvement and refine the framework accordingly.
- Write a paper.

Fourth Semester Experimentation and Analysis

- Explore different experimental scenarios and variations, such as different dataset sizes, class imbalances, and active learning strategies.
- Analyze the impact of the deep active learning framework on model performance, convergence speed, and data labeling effort.
- Investigate the scalability of the framework on large datasets or specific application domains.
- Summarize and document the results, draw meaningful conclusions, and provide recommendations for future research directions.
- Write a Master Thesis.

Necessary Competencies

Mandatory:

- Strong programming skills, especially in languages suitable for deep learning applications (e.g. Python).
- Familiarity with machine learning concepts and algorithms.

Acquirable Competencies

1. Proficiency in implementing and using active learning methods, specifically for deep learning and image classification tasks.
2. Hands-on experience with different deep learning frameworks in some hot topics such as image classification and image segmentation.
3. Writing scientific research papers.