



Sachbericht zum Verwendungsnachweis des vom BMFTR geförderten Vorhabens



Vorhabenbezeichnung: Interaktive Künstliche Intelligenz für Domänenexperten und Alltagsnutzer	
Förderkennzeichen: 01IS20045	
Laufzeit des Vorhabens: 01.10.2020 – 31.12.2024	
Zuwendungsempfänger: Technische Universität Darmstadt	
Autoren: Dorothea Koert, Lisa Kempf (geb. Scherf), Susanne Trick, Vildan Salikutluk, João Müller Carvalho (geb. Carvalho), Dirk Balfanz	
Das diesem Bericht zugrunde liegende Vorhaben wurde mit Mitteln des Bundesministeriums für Forschung, Technologie und Raumfahrt (BMFTR) unter dem Förderkennzeichen 01IS20045 gefördert. Die Verantwortung für den Inhalt dieser Veröffentlichung liegt bei den Autorinnen und Autoren.	Gefördert durch:  Bundesministerium für Forschung, Technologie und Raumfahrt

Inhalt

Inhalt.....	1
1 Kurzbericht	2
1.1 Aufgabenstellung	2
1.2 Anknüpfung an den wissenschaftlichen und technischen Stand.....	2
1.3 Ablauf des Vorhabens	3
1.4 Wesentliche Ergebnisse und Forschungszusammenarbeit	3
2 Eingehende Darstellung.....	4
2.1 Verwendung der Zuwendung und erzielte Ergebnisse	4
2.2 Die wichtigsten Positionen des zahlenmäßigen Nachweises	21
2.3 Notwendigkeit und Angemessenheit der geleisteten Arbeit	21
2.4 Darstellung des voraussichtlichen Nutzens.....	22
2.5 Fortschritt auf dem Gebiet des Vorhabens bei anderen Stellen	22
2.6 Erfolgte oder geplante Veröffentlichung des Ergebnisses.....	23

1 Kurzbericht

1.1 Aufgabenstellung

Künstliche Intelligenz (KI) besitzt das Potential, sich sowohl zu einer der Kerntechnologien industrieller Anwendungen als auch zu einem integralen Bestandteil des täglichen Lebens zu entwickeln. Obwohl in den letzten Jahren KI-Lösungen in immer mehr Anwendungsbereiche vordringen, ist ihre Entwicklung und Bereitstellung wesentlich auf die Expertise von KI-Expert:innen angewiesen. IKIDA soll es ermöglichen, KI-Algorithmen in hohem Maße durch direkte Interaktion mit Anwender:innen anzupassen und zu optimieren. Dadurch können Anwendungshürden von KI-Lösungen gesenkt und ihre Nachhaltigkeit sowie Akzeptanz gestärkt werden. Technisch-wissenschaftliches Gesamtziel von IKIDA war die Entwicklung von interaktiven, probabilistischen KI-Algorithmen, die von der Interaktion mit Anwender:innen profitieren. Zur KI-Algorithmenentwicklung wurden dabei auch kognitive Modelle herangezogen, neue kognitive Modelle zur Mensch-KI-Interaktion abgeleitet und der interaktive Mensch-KI-Lernprozess auf Praxisanwendungen, speziell auch für Mensch-Roboter-Interaktion, evaluiert.

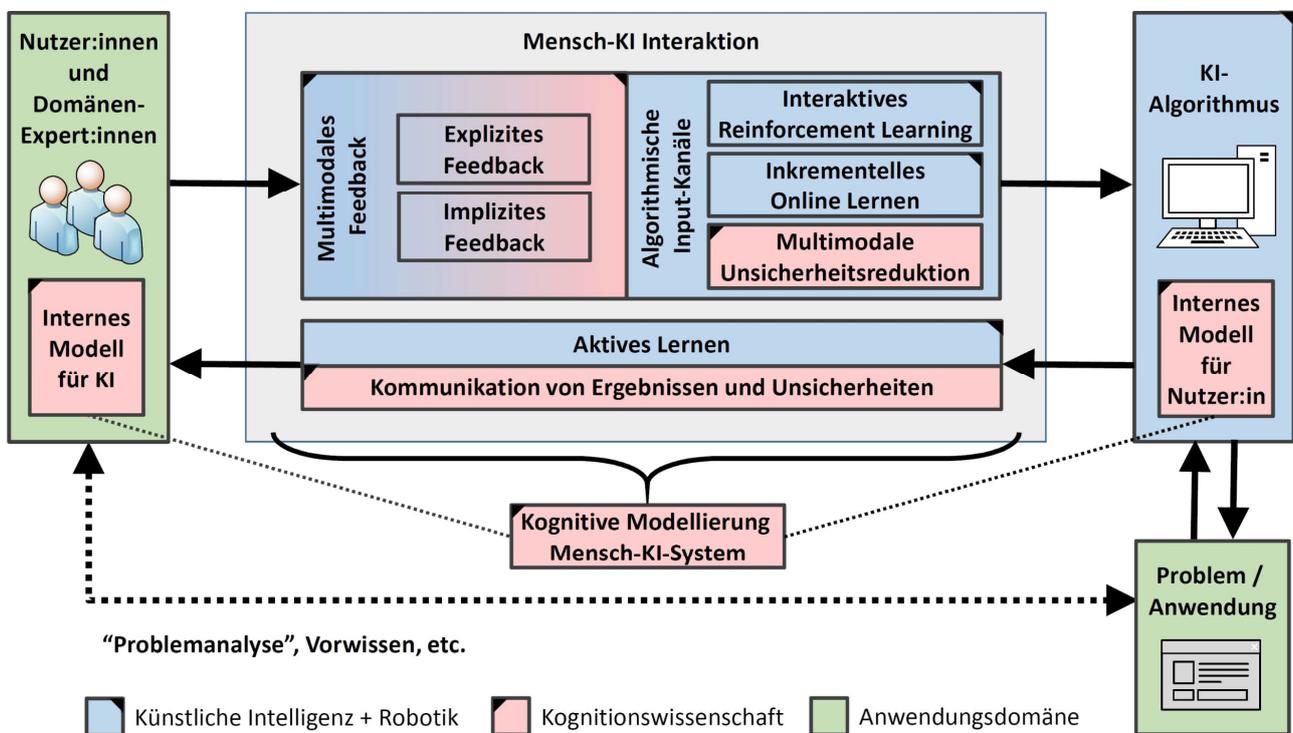


Abbildung 1: Übersicht über die Forschungsthemen. IKIDA betrachtet Mensch-KI-Interaktion als interdisziplinäres Forschungsfeld an der Schnittstelle von KI, Robotik und Kognitionswissenschaften und legt einen Fokus auf Evaluationen in praktischen Anwendungsdomänen.

1.2 Anknüpfung an den wissenschaftlichen und technischen Stand

Interaktives maschinelles Lernen kann helfen, kontinuierliche Anpassung und Gestaltung durch Anwender:innen auch zur Laufzeit der KI-Algorithmen zu ermöglichen und die initial benötigten Trainingsdatenmengen zu verringern. Speziell im Anwendungsbereich Robotik ist eine solche verringerte Trainingsdatenmenge wesentlich, um den Praxistransfer von KI zu ermöglichen. Dabei ist eine interdisziplinäre und ganzheitliche Betrachtung von KI und Mensch als "Team lernender Einheiten" notwendig um eine verbesserte Nutzbarkeit von KI-Systemen für die Allgemeinheit zu ermöglichen und interaktive KI für eine breite Masse an Anwendungen zukunftsfähig zu machen. Wissenschaftliche Herausforderung in IKIDA war es dabei, Mensch-KI-Interaktion durch algorithmisches Design zu ermöglichen und dabei menschliches Domänenwissen und die computationale Stärke von KI synergetisch zu verbinden.

Die in IKIDA erforschten interaktiven KI-Algorithmen sollen so zukünftig z. B. Alltags- und Industrieanwender:innen dabei unterstützen, Robotern neue bzw. personalisierte Fertigkeiten beizubringen oder es KI-Systemen ermöglichen, in Anwendungen zur automatisierten Datenanalyse interaktiv von Domänenexperten zu lernen.

1.3 Ablauf des Vorhabens

Die Projektlaufzeit von IKIDA betrug 51 Monate, inkl. einer 3-monatigen kostenneutralen Verlängerung. Die Projektarbeit war organisiert in 5 Arbeitspaketen (AP): AP 1 „Entwicklung interaktiver, probabilistischer KI-Algorithmen“, AP 2 „Mensch-/aufgabenzentriertes Design der Feedback-Modalitäten“, AP 3 „Iteratives Vorgehen und Sicherung der Praxisrelevanz“, AP 4 „Studien zu interaktivem Lernen, Industrie-Board sowie ethische, soziale und rechtliche Fragen (ELSI)“ sowie AP 5 „Mentoring und wissenschaftliches Coaching“.

Der Projektverlauf wurde strukturiert durch die Meilensteine (MS) des Projektes. So wurden zunächst Projektstrukturen der neuen Nachwuchsgruppe und der Kontakt zu den assoziierten Industriepartnern etabliert (bis MS 1 am 07.05.2021), in Experimenten zur Mensch-Mensch-Interaktion und Mensch-KI-Interaktion die Grundlagen zur algorithmischen Entwicklung gelegt sowie industrienaher Use Cases definiert (bis MS 2 am 11.03.2022), erste Prototypen in Pilotstudien evaluiert (bis MS 3 am 28.04.2023) und unter Einbeziehung der ersten Ergebnisse die Algorithmen iterativ weiterentwickelt, mit Proband:innen getestet und Teilergebnisse mit den assoziierten Industriepartnern diskutiert und getestet (bis MS 4 am 16.04.2024 bzw. MS 5 am 13.12.2024).

1.4 Wesentliche Ergebnisse und Forschungszusammenarbeit

Technisch-wissenschaftliches Ziel von IKIDA war die Entwicklung neuer, interaktiver und probabilistischer KI-Algorithmen unter Berücksichtigung von menschen- und aufgabenzentriertem Design der Feedback-Modalitäten, d. h. das Verständnis und die kognitive Modellierung des Wechselwirkungsprozesses interaktiver KI-Algorithmen mit den KI-nutzenden Menschen. In iterativen Evaluationen und Nutzerstudien in verschiedenen Praxisbereichen (lernende Roboter und KI gestützte Datenanalyse) wurde dabei ein KI-System entwickelt, das menschliche Unsicherheit mit multimodalen Daten (Kamera, Audio, Reaktionszeiten) auf einem vergleichbaren Niveau wie menschliche Testpersonen erkennen kann. Es wurden neue Algorithmen entwickelt, die so erkannte Unsicherheiten mit geschätzten eigenen Unsicherheiten einer KI im Reinforcement Learning kombinieren, um besseren Lernerfolg zu erzielen trotz teils suboptimalen menschlichen Inputs. Außerdem wurde ein Algorithmus entwickelt, der durch Bayes'sche Kombination multimodale Unsicherheitsreduktion erreicht, was sowohl für Klassifikationsprobleme in Mensch-Roboter-Interaktion als auch zur Entscheidungsunterstützung in Multi-Expert-Systemen positiv evaluiert wurde. In IKIDA entstand weiterhin ein hierarchischer Ansatz für das Fertigkeitlernen von Robotern, der sowohl ein neues Konzept beinhaltet High-Level-Verhaltensbäume direkt von menschlichen Videodemonstrationen zu extrahieren, als auch Diffusions-KI-Modelle für Low-Level-Bewegungsplanung und Greifpositionen zu nutzen. In Experimenten zur Zusammenarbeit von Mensch und KI/Roboter in geteilten Arbeitsräumen konnte ein neues Modell zu dynamisch-adaptiver Autonomie-Adaption erarbeitet und dessen Vorteile gegenüber fixen Autonomiestufen gezeigt werden. Außerdem wurden Large-Language-Modelle (LLMs) und deren Einsatz in der Mensch-KI-Interaktion für das Lösen von Schätzaufgaben erforscht und Fragestellungen über ethische Implikationen von LLMs untersucht, speziell deren Bias gegenüber marginalisierten Gruppen.

Da alle beteiligten Wissenschaftler:innen an der TU Darmstadt verortet waren, konnte das Team trotz der Einschränkungen durch die COVID-19-Pandemie durchgängig eng integriert arbeiten. Die interdisziplinären Verbindungen zwischen Kognitionswissenschaft, KI und Robotik wurden gestärkt und legen so die Grundlage für eine andauernde, vertiefte interdisziplinäre Forschungsarbeit der beteiligten Forscher:innen und Gruppen. Die assoziierten Industriepartner Porsche Motorsport und Energy Robotics haben das Projekt begleitet, praxisrelevante Use Cases eingebracht und die hohe Relevanz der Forschungsfragen des Projektes für die Anwendung bestätigt.

2 Eingehende Darstellung

Gesamtziel von IKIDA war die Erforschung und Entwicklung interaktiver KI-Algorithmen. Der Lösungsansatz basierte dabei auf den interdisziplinär verknüpften Teilen (1) Entwicklung interaktiver, probabilistischer KI-Algorithmen (AP 1), (2) menschen- und aufgabenzentriertes Design der Feedback-Modalitäten (AP 2) und (3) iteratives Vorgehen und Sicherung der Praxisrelevanz (AP 3, AP 4), die nachfolgend in den zugehörigen Arbeitspaketen detailliert beschrieben werden.

In IKIDA wurden dabei in AP 1 Algorithmen entwickelt, die ein für Menschen kompatibles Reinforcement Learning (verstärkendes Lernen) auch mit suboptimalen menschlichen Angaben unter einer kontinuierlichen Anpassung ermöglichen. Dabei wird zudem die Multimodalität der menschlichen Interaktion zur aktiven Unsicherheitsreduktion von KI-Modellen innerhalb einer bayesianischen Architektur genutzt. In AP 2 wurden menschen- und aufgabenzentriertes Design der Feedback-Modalitäten untersucht. Es gab zur Zeit der Projektdurchführung zwar erste Arbeiten zur Gestaltung von Mensch-KI-Schnittstellen, jedoch kaum unter Berücksichtigung kognitiver Zusammenhänge. Diese Zusammenhänge sind für gelingende Interaktion jedoch grundlegend. Hierfür muss auch die menschliche Seite, d.h. Menschen als potentielle Nutzer untersucht werden, wobei Modelle zu menschlichen Denk- und Handlungsprozessen generiert werden. Diese Modelle können anschließend genutzt werden, um eine optimale Interaktion zwischen Menschen und dem KI-System zu ermöglichen. In IKIDA wurden dabei ein multimodales Modell für menschliche Unsicherheitserkennung und ein Konzept zu dynamischer Autonomieadaptation bei Zusammenarbeit von Mensch und KI in geteilten Arbeitsräumen entwickelt. Zusätzlich wurde in Studien erforscht wie man KI-gestützt eine aufgaben-unabhängige Intention zur Interaktion in der Mensch-Roboter-Interaktion erkennen kann und es wurden kognitive Modelle zu menschlichen Problemlösungsstrategien in offenen (Guesstimation) Fragestellungen und deren Unterstützung durch LLMs erforscht.

Zur Sicherung der Praxisrelevanz wurden die assoziierten Unternehmen in den Forschungsprozess integriert durch Workshops zur gemeinsamen Definition von Use Cases und durch Ko-Betreuung studentischer Arbeiten (AP 3 und AP 4).

Im Folgenden werden die Arbeiten und Ergebnisse der einzelnen Arbeitspakete detailliert beschrieben.

2.1 Verwendung der Zuwendung und erzielte Ergebnisse

AP 1	Entwicklung interaktiver, probabilistischer KI-Algorithmen
	<p>AP 1.1 Interaktives Reinforcement Learning</p> <p>Im Reinforcement Learning (RL = verstärkendes Lernen) interagiert ein Agent mit der Umgebung und lernt dabei selbstständig mit dem Ziel, erhaltene Belohnungen zu maximieren. Im interaktiven Reinforcement Learning können menschliche Nutzer zusätzlich Feedback geben oder Aktionen vorschlagen um den Lernprozess zu beschleunigen.</p> <p>Interaktiver RL-Algorithmus für suboptimale Aktionsvorschläge</p> <p>Menschliches Feedback kann in bestimmten Situationen (States) fehlerhaft sein, zum Beispiel aufgrund einer eingeschränkten Wahrnehmung der Umgebung oder aufgrund fehlenden Wissens über die zugrunde liegende Aufgabe. Um suboptimale menschliche Aktionsvorschläge erkennen zu können, wurde ein Modell für Learning from Unreliable Action Advice (LUNAA) [3] entwickelt, das situationsbedingt entscheidet, ob eine Aktion basierend auf den Aktionsvorschlägen des Menschen oder dem RL-Modul ausgewählt werden soll (Abbildung 2). Zu diesem Zweck werden verschiedene Indikatoren zu einer situationsabhängigen Größe für das Vertrauen in die Aktionsvorschläge kombiniert. Bei den Indikatoren handelt es sich um die Konsistenz der Aktionsvorschläge für einen bestimmten State, die retrospektive Optimalität basierend auf den resultierenden</p>

Belohnungen und Hinweise auf Unsicherheit im Verhalten des Menschen, wie zum Beispiel Änderungen in der Gesichtsdynamik oder eine zeitliche Verzögerung in der Auswahl der nächsten Aktion durch den Nutzer.

In einer Umgebung mit simulierten, suboptimalen Aktionsvorschlägen wurde gezeigt, dass die beschriebene Methode das Lernen beschleunigen kann im Vergleich zu Methoden, die eine situationsunabhängige Größe für das Vertrauen in die Aktionsvorschläge berechnen. Außerdem wurden Änderungen in der Gesichtsdynamik und Antwortzeiten in einer Sortieraufgabe mit einem Roboterarm und 28 menschlichen Versuchspersonen untersucht. Es konnte ein Zusammenhang zwischen den Antwortzeiten der Versuchspersonen und unsicheren bzw. sicheren Aktionsvorschlägen festgestellt werden.

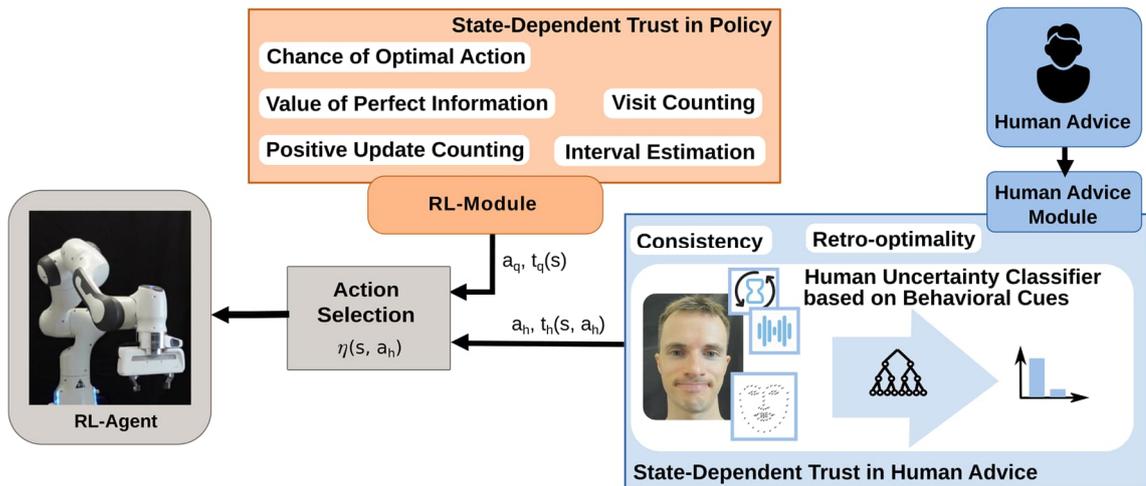


Abbildung 2: Übersicht des LUNAA-TIP Algorithmus, der zustandsabhängige Abschätzungen zu Vertrauen in die eigene Policy mit Vertrauensabschätzungen zu menschlichem Input kombiniert um einen verbesserten interaktiven RL-Algorithmus für unzuverlässige Aktionsvorschläge zu erreichen [18].

Nach der ersten Publikation dieser Teilergebnisse [3] wurde der LUNAA Ansatz um Unsicherheitsmaße auf Seiten des RL-Agenten erweitert (LUNAA-TIP). Hierzu wurden fünf verschiedene Unsicherheitsmaße für die Policy in den bestehenden LUNAA Algorithmus integriert und verglichen [A17, 18, P1]. Zusätzlich wurde die in AP 4.1 entwickelte multimodale menschliche Unsicherheitserkennung integriert. In einer Umgebung mit simulierten, suboptimalen Aktionsvorschlägen wurde gezeigt, dass die Unsicherheitsmaße auf Seiten des RL-Agenten das Lernen zusätzlich beschleunigen im Vergleich zu LUNAA und Methoden, die eine situationsunabhängige Größe für das Vertrauen in die Aktionsvorschläge berechnen.

Auswertungen in einer Gridworld-Umgebung mit simulierten, suboptimalen Aktionsvorschlägen zeigen, dass unser Ansatz eine zustandsunabhängige Vergleichsmethode bezüglich der Lerngeschwindigkeit deutlich übertrifft. Roboterexperimente mit perzeptueller Unsicherheit und echten, teils suboptimalen Ratschlägen von 26 Teilnehmern, bestätigen die Nützlichkeit der enthaltenen menschlichen Unsicherheitsklassifikation als Indikator für unzuverlässige Ratschläge. Darüber hinaus konnten wir zeigen, dass unser Ansatz im Vergleich zu einer zustandsunabhängigen Berechnung des Vertrauens in die gelernte Strategie des Roboters robuster gegenüber falschen Ratschlägen ist. Der LUNAA-TIP Ansatz wurde in einem Workshop präsentiert [18]. Die Ergebnisse der ausführlichen Experimente sind zu Projektende unter Begutachtung für eine weitere Publikation [P1].



Abbildung 3: Übersicht des Experiment-Setups mit Roboter, um teils suboptimale menschliche Angaben in einem RL-Algorithmus zum Lernen zu nutzen [P1].

Multimodales Interaktives Reinforcement Learning

Es wurde ein neuer Ansatz zur Integration von menschlichem Input für interaktives Reinforcement Learning (verstärkendes Lernen) entwickelt. Das entwickelte System (MIA-IRL) ermöglicht es dem Menschen, einem Roboter Handlungsvorschläge zu machen, damit dieser eine Aufgabe schneller lernen kann [5, A4]. Es wurde in der Fachzeitschrift Robotics and Automation Letters (RA-L) veröffentlicht [5] sowie auf der IROS 2022 Konferenz präsentiert. MIA-IRL ermöglicht es Menschen, einem Roboter Handlungsvorschläge zu machen, damit dieser eine Aufgabe schneller lernen kann. Dabei kann der Mensch bestimmte Aktionen vorschlagen, indem er die beiden Modalitäten Gesten und Sprache verwendet. Für beide Modalitäten wurde ein eigener probabilistischer Klassifizierer entwickelt. Die Ausgaben beider Klassifizierer werden mit der Fusionsmethode Independent Opinion Pool kombiniert, die bayesianisch herleitbar ist und die Unsicherheit der Entscheidung für eine Aktion reduziert, wenn beide Klassifizierer dieselbe Aktion vorhersagen.

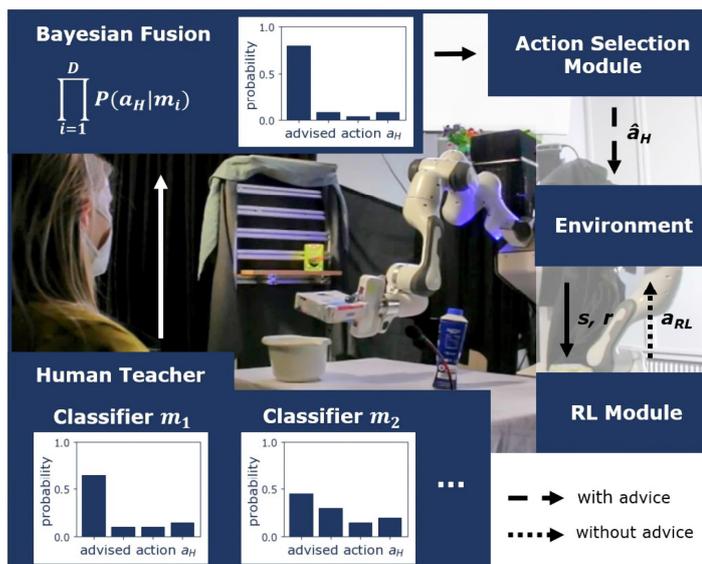


Abbildung 4: Übersicht des Ansatzes zu multimodalem interaktivem Reinforcement-Lernen mit der Fusionsmethode Independent Opinion Pool (MIA-IRL). [5]

Um die auszuführende Aktion auszuwählen, wird von der kombinierten Verteilung über alle möglichen Aktionen gesampelt. Dadurch kann die Unsicherheit der Verteilung bei der

Aktionwahl berücksichtigt werden (AP 1.3), wohingegen in vergleichbaren Arbeiten üblicherweise einfach die Aktion mit der höchsten Wahrscheinlichkeit gewählt wird und damit die Unsicherheit der Entscheidung vernachlässigt wird. In einem Mensch-Roboter-Szenario mit 10 Versuchspersonen konnten wir zeigen, dass das Lernen dieser Aufgabe durch die Verwendung der Bayes'schen Fusionsmethode schneller erfolgte als mit vergleichbaren Methoden.

AP 1.2 Inkrementelles Online Lernen

Es wurde untersucht, wie man Inkrementelles Online Lernen nutzen kann, um einem Roboter zuerst Fertigkeiten in Form von Bewegungsprimitiven durch menschliche Demonstrationen beizubringen und diese anschließend durch selbstgesteuertes Lernen inkrementell weiter zu verbessern.

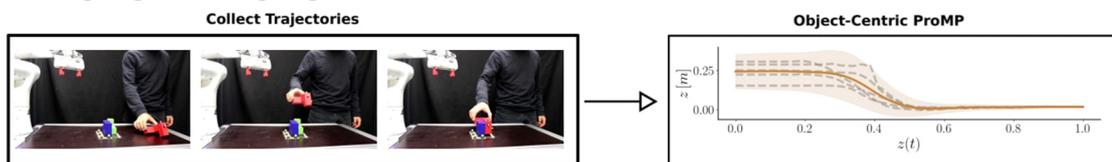
Darüber hinaus wurde eine Methode zur Beschleunigung von Bewegungsplanungs-algorithmen für die Robotik entwickelt, die aus zuvor gezeigten optimalen Trajektorien lernt und sich online an neue Umgebungen anpasst.

Residual Robot Learning

Residuales Roboterlernen ermöglicht es, dass ein Roboter seine Fähigkeiten online an eine bestimmte Aufgabe anpasst, indem er Techniken von Imitations-Lernen und Reinforcement Learning (Verstärkendes Lernen) kombiniert.

Wir haben hierbei ein System entwickelt, das eine menschliche Demonstration einer Platzierungsaufgabe aus mehreren Positionen und ohne kinästhetischen Unterricht verwendet, was eine natürlichere Methode für einen Menschen ist, einem Roboter eine Aufgabe beizubringen. Mit diesen Demonstrationen lernen wir eine probabilistische Bewegungsprimitivdarstellung (ProMP) von Objekt-Trajektorien.

DEMONSTRATIONS



ONLINE LEARNING

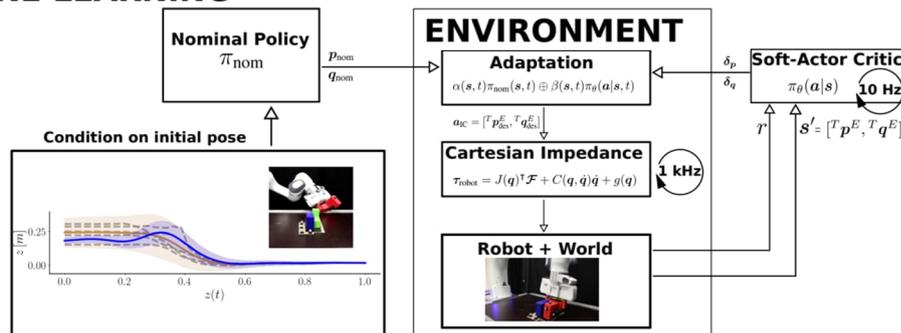


Abbildung 5: Übersicht der Methode zum Inkrementellen Online Lernen für Residual Policies in Kombination mit Probabilistischen Bewegungsprimitiven [4].

Diese Arbeit wurde erfolgreich auf der HUMANOIDS-Konferenz in Okinawa, Japan, präsentiert [4]. Wir haben dieses Thema zudem in einer Masterarbeit über das Lernen stabiler Vektorfelder mit Residual Learning [A20] weiter erforscht.

Zusätzlich wurde in einer Bachelorthesis erforscht, wie Roboter direkt von Video-Demonstrationen lernen können [A5] und zwei Masterthesen durchgeführt, in welchen

einerseits hierarchische Ansätze zu aufgaben-abhängigen hierarchischen Reglermodellen untersucht [A6] und andererseits Kontext-Abhängigkeiten modelliert wurden [A27].

AP 1.3 Aktives Lernen

In Zusammenarbeit mit dem assoziierten Industriepartner Porsche Motorsport wurde im Rahmen einer gemeinsam betreuten studentischen Abschlussarbeit ein Prototyp implementiert, der menschliches Feedback durch einen Ansatz für aktives Lernen in ein KI-System zur interaktiven Anomalie-Erkennung integriert [A25].

AP 1.4 Multimodale Unsicherheitsreduktion

Um multimodale Unsicherheitsreduktion zu erreichen wurden in IKIDA verschiedene Bayes'sche Modelle entwickelt und evaluiert.

Bayesian Classifier Fusion with an Explicit Model of Correlation

Es wurde ein bayesianisches Modell zur Fusion verschiedener probabilistischer Klassifizierer entwickelt.

Wenn die Basisklassifizierer statistisch unabhängig voneinander sind und die a-priori Verteilung über die möglichen Klassen gleichverteilt ist, ist Independent Opinion Pool Bayes-optimal und daher die mathematisch korrekte Fusionsmethode. Jedoch sind verschiedene Basisklassifizierer für dieselbe Klassifizierungsaufgabe in der Praxis meist nicht voneinander unabhängig. Aus diesem Grund wurde ein hierarchisches bayesianisches Modell zur Fusion mehrerer Klassifizierer entwickelt, das die Korrelationen zwischen den Basisklassifizierern explizit modelliert und für deren Fusion berücksichtigt. Die kategorialen Ausgabe-Verteilungen jedes Basisklassifizierers werden mit Dirichlet-Verteilungen modelliert, wodurch die Eigenschaften der einzelnen Klassifizierer wie Bias, Varianz und Unsicherheit für die Fusion berücksichtigt werden. Zur zusätzlichen Modellierung von Korrelationen zwischen den kategorialen Ausgabe-Verteilungen der Basisklassifizierer wurde eine Erweiterung der Dirichlet-Verteilung neu entwickelt. Diese neue, korrelierte Dirichlet-Verteilung ermöglicht die Modellierung von korrelierten Dirichlet-verteiltern Zufallsvariablen.

In Evaluationen auf simulierten sowie realen Datensets von korrelierten Basisklassifizierern konnte gezeigt werden, dass die aus der Fusion der Klassifizierer resultierende Unsicherheitsreduktion unter der Nutzung des entwickelten Bayes'schen Fusionsmodells geringer wird, je größer die Korrelation der Basisklassifizierer ist. Dementsprechend reduziert die Fusion im Extremfall einer Korrelation von $r=1$ zwischen den Basisklassifizierern die Unsicherheit überhaupt nicht. Zudem konnte gezeigt werden, dass das vorgeschlagene Modell zur Fusion korrelierter Klassifizierer hinsichtlich Genauigkeit und Unsicherheit ähnlichen Modellen überlegen ist. Diese Arbeit wurde auf der internationalen Konferenz AISTATS (Artificial Intelligence and Statistics) 2022 veröffentlicht und präsentiert [6].

Bayesian Combination of Experts' Probability Estimates

Es wurde ein Modell zur Fusion von probabilistischen Expertenmeinungen entwickelt und in der Fachzeitschrift Judgment and Decision Making veröffentlicht [16].

Das Modell ermöglicht es, von mehreren menschlichen Experten zur Verfügung gestellte subjektive Wahrscheinlichkeitsschätzungen zu kombinieren. Solche subjektiven Wahrscheinlichkeitsschätzungen können beispielsweise quantifizieren, wie sicher ein Experte ist ob eine Aussage falsch oder richtig ist oder für wie wahrscheinlich ein Experte das Eintreffen eines zukünftigen Events wie z. B. den Ausgang einer Wahl hält. Unser Modell repräsentiert das probabilistische Antwortverhalten der Experten mit Beta-Verteilungen (AP 2.2) und kann so normativ, d. h. mathematisch korrekt quantifizieren, wie durch Menschen abgegebene Wahrscheinlichkeitsschätzungen nach dem Satz von

	<p>Bayes kombiniert werden sollten. Außerdem kalibriert es die von Menschen abgegebenen Wahrscheinlichkeitsschätzungen implizit, d. h. es korrigiert Expertenschätzungen, die zu sicher oder zu unsicher sind. Für die Evaluation des Fusionsmodells wurde ein Datensatz von uns zur Verfügung gestellt, der aus probabilistischen Einschätzungen verschiedener Studierender zu verschiedenen Wissensfragen besteht. Die Evaluation auf diesem Datensatz und einem bereits bestehenden Datensatz zeigen, dass das von uns vorgeschlagene Beta Expert Fusion Model bezüglich des Mean Absolute Error (MAE) bessere Ergebnisse erzielt als vergleichbare Modelle. Bezüglich eines anderen Maßes für die Performance der Fusionsmodelle, nämlich des Brier Scores, zeigten vergleichbare Modelle allerdings teilweise eine bessere Performance. Dies konnte darauf zurückgeführt werden, dass das vorgeschlagene Beta Expert Fusion Model zu extreme, d. h. zu sichere fusionierte Wahrscheinlichkeiten zurückgibt, also overconfident ist, denn MAE belohnt extreme Wahrscheinlichkeitsschätzungen, während der Brier Score diese ahndet. Diese Overconfidence des vorgeschlagenen Modells ist Folge der Annahme, dass die Wahrscheinlichkeitsschätzungen verschiedener Experten, gegeben des Wahrheitswertes der einzuschätzenden Fragestellung, voneinander unabhängig sind. Da die Wahrscheinlichkeitsschätzungen verschiedener Experten in der Regel korreliert sind, ist diese Annahme in der Realität häufig nicht erfüllt. Daher wurde das Fusionsmodell in einem zweiten Schritt zu einem Fusionsmodell für korrelierte subjektive Wahrscheinlichkeitsschätzungen von Experten erweitert. Dieses neue Modell repräsentiert die Wahrscheinlichkeitsschätzungen ebenfalls mit Beta-Verteilungen, aber repräsentiert dabei zusätzlich explizit die Fähigkeiten der einzelnen Experten und die Schwierigkeit der Fragestellungen, für die Wahrscheinlichkeitsschätzungen bereitgestellt werden. So kann die Korrelation der Wahrscheinlichkeitsschätzungen verschiedener Experten modelliert und für die Fusion berücksichtigt werden. Die Evaluation auf dem oben beschriebenen, von uns veröffentlichten Datensatz ergab eine deutliche Verbesserung der Performance des neuen Fusionsmodells für korrelierte Wahrscheinlichkeitsschätzungen gegenüber dem Vorgängermodell für unabhängige Wahrscheinlichkeitsschätzungen und verwandten Fusionsmodellen, sowohl bzgl. des MAE als auch bzgl. des Brier Scores.</p> <p>Um die Bayes'sche Fusion von menschlichen Experten und Klassifizierern zu untersuchen wurde eine Masterthesis mit dem Titel „Bayesianische Kombination der Klassifikationen von Menschen und Maschinen“ betreut [A26].</p>
AP 2	Mensch-/aufgabenzentriertes Design der Feedback-Modalitäten
	<p>2.1 Menschliche Feedback-Mechanismen und -Modalitäten</p> <p>Für interaktives Reinforcement Learning (RL) wurde zu Beginn des Projekts implizites menschliches Feedback in Form von Gesichtsdynamik in direkter Reaktion auf ein positives oder negatives Verhalten des RL-Agenten untersucht [A3, A35]. Auch wenn eine leichte Korrelation zwischen impliziter Reaktion der Nutzer:innen und dem Verhalten des RL-Agenten gefunden werden konnte war es in den von uns durchgeführten Experimenten in einer simulierten Umgebung nicht möglich darauf aufbauend ein stabiles Lernsystem zu entwickeln. Die Gründe hierfür liegen in der komplexen Natur des Gesichtsverhaltens sowie in der Versuchsanordnung, die kein hohes Engagement und damit kein konsistentes Gesichtsverhalten hervorrief. Deswegen wurde das implizite gesichtsdynamik-basierte Feedback in IKIDA nicht als direkter RL-Reward genutzt. Stattdessen wurde multimodales implizites Feedback zur menschlichen Unsicherheitserkennung weiter erforscht. Die resultierende Methode ermöglicht es einem RL Agenten trotz eines teilweise falschen menschlichen Inputs immer noch erfolgreich lernen zu können [A16, A18, 14, 15].</p>

Speziell wurde dabei ein Setup gewählt in dem Probanden mit einem menschlichen Partner, einem Roboter und einem Tablet interagieren (Abbildung 6), um auch Einflüsse des Interaktionspartners auf die implizite Kommunikation von Unsicherheiten untersuchen zu können. Es wurde dabei ein multimodaler Datensatz (Gesichtsdynamik, Audio, Reaktionszeiten, subjektive Unsicherheitsangabe, third person labels) aufgenommen. Erste Teilergebnisse wurden auf der Computational Cognition Conference (ComCo) vorgestellt [14] und die gesamte Arbeit wurde auf der Internationalen HRI Konferenz präsentiert [15].

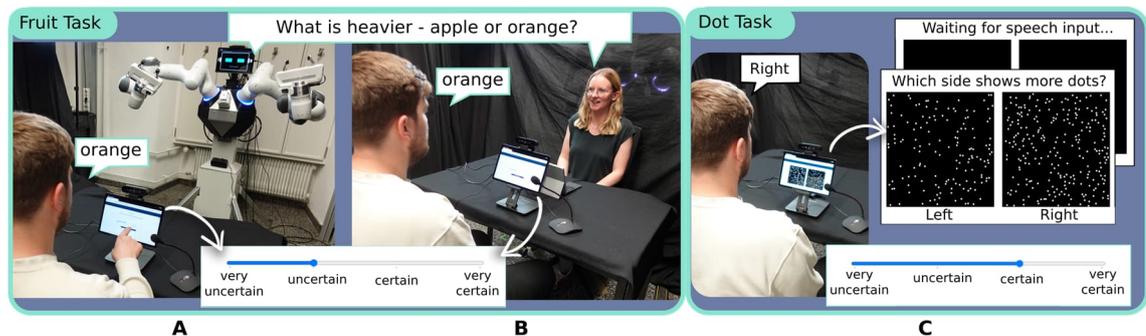


Abbildung 6: Übersicht des experimentellen Setups zur Datenaufnahme. Interaktionspartner war entweder ein Roboter (A) ein Mensch (B) oder ein Tablet (C) [15].

Es konnte gezeigt werden, dass das gelernte Klassifikations-Modell für menschliche Unsicherheit menschliche Third-Person-Annotatoren in ihrer Genauigkeit übertreffen konnte. In Studien zu multimodalem Reinforcement Learning und zu suboptimalem Feedback im Reinforcement Learning (AP 1.1) wurden speziell auch die expliziten Feedbackmodalitäten Gesten und Sprache untersucht.

Auf der International Conference on Multimodal Interaction 2021 wurde vor diesem Hintergrund unter der Beteiligung von IKIDA ein internationaler Workshop organisiert unter dem Thema „Empowering Interactive Robots by Learning Through Multimodal Feedback Channel“ [2].

AP 2.2 Kognitive Modelle der (Lern-)Interaktion

Intention zur Interaktion

Es wurde ein Ansatz zur automatischen Erkennung einer menschlichen Intention zur Interaktion mit einem Roboter entwickelt [A2, A8] und auf der internationalen Konferenz RO-MAN 2023 (32nd IEEE International Conference on Robot and Human Interactive Communication) in Busan, Südkorea vorgestellt und veröffentlicht [17].

Die Intention zur Interaktion, im Folgenden Intention for Interaction oder kurz IFI genannt, bezeichnet dabei die Intention eines Menschen, eine Interaktion mit einem Roboter zu starten. Um es Menschen zu ermöglichen, möglichst natürlich und intuitiv mit dem Roboter zu interagieren, wurde in einem Verhaltensexperiment mit 21 menschlichen Versuchspersonen zunächst erfasst, wie Menschen eine IFI gegenüber einem zweiarmigen Roboter natürlicherweise äußern. Die Versuchspersonen wussten dabei nicht, dass es um die Äußerung ihrer Intentionen ging. Während sie nach vorgegebenen Anleitungen einen Turm aus Bausteinen zusammenbauten, benötigten sie jedoch immer wieder die Unterstützung des Roboters und mussten daher immer wieder eine IFI äußern. Die Reaktion des Roboters wurde dabei versteckt durch die Versuchsleitung gesteuert (Wizard of Oz). Die Position der Schultern, Augen und des Nackens der Versuchspersonen sowie ihre sprachlichen Äußerungen wurden während des gesamten Experiments aufgenommen. Basierend auf diesen Daten wurden verschiedene probabilistische Klassifizierer zur Erkennung einer IFI trainiert, die entweder unimodal nur Körper-Daten,

nur Sprach-Daten oder multimodal sowohl Körper-Daten als auch Sprach-Daten verwendet. Die beste Erkennung einer IFI mit einem F1 score von 0,81 konnte dabei mit einem multimodalen Klassifizierer erreicht werden, der mit der Bayes'schen Fusionsmethode Independent Opinion Pool die Ausgaben von zwei unimodalen Klassifizierern kombiniert, die jeweils nur mit Körper- bzw. Sprach-Daten arbeiten.

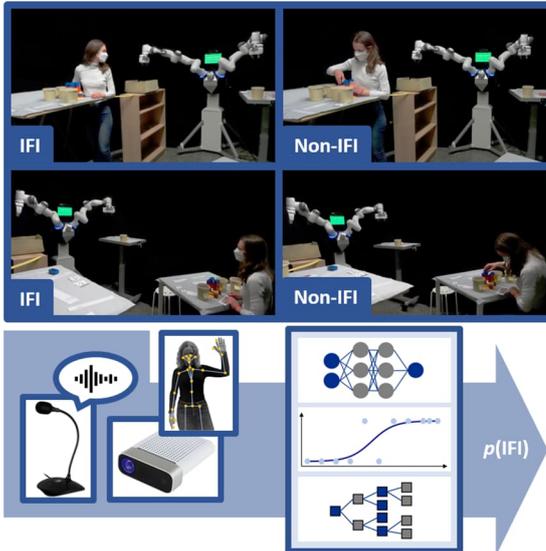


Abbildung 7: Übersicht des experimentellen Setups und des multimodalen Klassifizierens zur Erkennung einer Intention zur Interaktion [17].

Situativ-adaptive Autonomie

In der zur Projektlaufzeit aktuellen Literatur werden für Mensch-KI-Interaktion tendenziell entweder Modelle aus der Mensch-Computer-Interaktion (Human-Computer Interaction, HCI) oder aus der Mensch-Mensch-Interaktion genutzt. Diese beiden Arten von Modellen legen den Fokus auf unterschiedliche Weise: während HCI das System, mit dem der Mensch interagiert, als reines Tool sieht, das keine wirkliche eigene „Intelligenz“ und Autonomie besitzt, werden in der Mensch-Mensch-Interaktion beide Partner:innen als gleichwertig und autonom verstanden. In IKIDA sehen wir die zu entwickelnden Interaktionsmodelle für Mensch-KI-Interaktion auf einem situativ-adaptiven Spektrum dazwischen (siehe Abbildung 8).

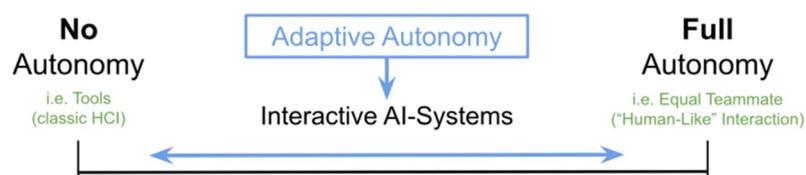


Abbildung 8: zeigt das Konzept von situativ-adaptiver Autonomie eines interaktiven KI-Systems. Das KI-System kann dabei skalierend mehr wie ein Werkzeug oder wie ein „gleichwertiger“ Teampartner agieren, je nach dem was für die Teamperformance in der aktuellen Situation am besten ist [12].

Am Beispiel einer Mensch-Roboter-Interaktion in einem geteilten Arbeitsraum haben wir ein Konzept für Situational Adaptive Autonomy entwickelt und in einer Simulationsumgebung mit Testpersonen evaluiert [A31, A32, 12, 20]. Dabei haben wir wichtige Aspekte herausgearbeitet, die zentral sind für adaptive Autonomie. Diese sind die Kompetenz des Roboters, seine Sicherheit darüber, eine vergleichende Kompetenzanalyse ob der Roboter oder der Mensch eine Aufgabe besser erledigen kann, die Konsequenzen, die Fehler oder eine unerfolgreiche Beendigung einer Teilaufgabe mit sich bringen sowie kognitive Modelle, wie z. B. Modelle der Theory of Mind (Abbildung 9). Die Arbeit wurde auf der internationalen CHI Konferenz präsentiert und publiziert [20].

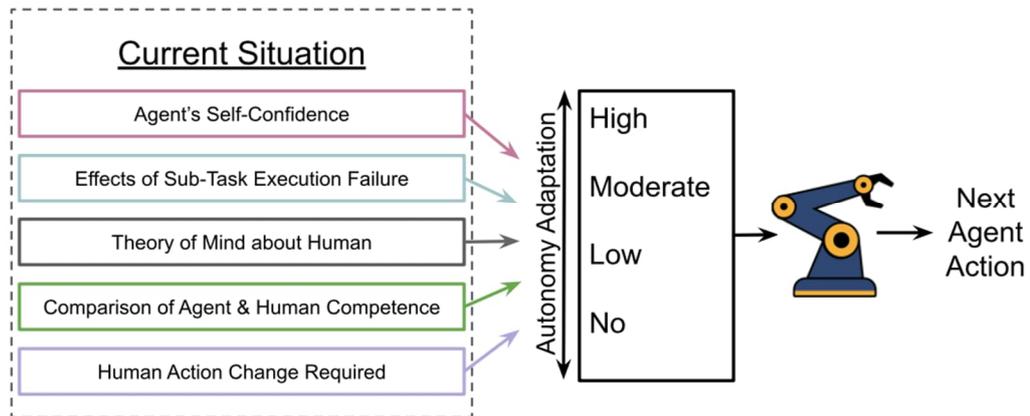


Abbildung 9: Aspekte, die situativ die Adaption von keiner/wenig Autonomie zu voller Autonomie beeinflussen sind z. B. die Aufgabenkomplexität, Modelle der Theory of Mind oder die Einschätzung der KI wie gut sie eine Aufgabe, auch im Vergleich zum Menschen, erfüllen kann.

In zwei Abschlussarbeiten wurde das entwickelte Konzept auf einen echten Robotersystem übertragen und als Prototyp implementiert [A36, A42].

AP 2.3 Gestaltung der Mensch-KI-Interaktionsschnittstelle

Wie in den Zielsetzungen beschrieben, wurden verschiedene Modalitäten für implizites und explizites Feedback untersucht. Speziell die Erkennung von menschlicher Unsicherheit anhand von Gesichtsdynamik, Reaktionszeiten und ggf. Inkonsistenz im gegebenen Feedback wurde untersucht (AP 1.1). Auch Gesten und direkte Eingaben von Nutzern als explizites Feedback sind in verschiedenen Anwendungsfällen getestet und integriert worden (APs 1.1, 1.4, 3.3, 3.4). Für den Anwendungsfall mit dem Industriepartner Porsche Motorsport wurde in einer gemeinsam betreuten Masterthesis begonnen Frontend und Backend für KI-gestützte Anomaliedetektion in eine graphische Nutzerschnittstelle zu integrieren [A25]. Für den Anwendungsfall mit dem Industriepartner Energy Robotics wurden Daten für Zeigegesten als Interaktionsmodalität gesammelt und evaluiert [A39]. Für das Interaktive Fertigkeitlernen von Robotern wurde ein Webinterface mit ROS-Schnittstelle entwickelt [A15].

AP 2.4 Personalisierung und Präferenzen

Für das interaktive Lernen von Inspektionsrouten wurden verschiedene Möglichkeiten des Folgeverhaltens des Roboters getestet [A7]. Eine Personalisierung basierend auf Nutzerpräferenzen und Robotertyp ist dabei ein interessanter zukünftiger Forschungsgegenstand. Auch für multimodale menschliche Unsicherheitserkennung (AP 1.1) und situativ-adaptive Autonomie (AP 2.2) wurden in den Experimenten personen-spezifische Präferenzen erkannt, die in weiterer Forschung berücksichtigt werden sollten.

AP 3 Iteratives Vorgehen und Sicherung der Praxisrelevanz

AP 3.1 Code Integration

Im Projekt wurden verschiedene Algorithmen entwickelt und für Experimente im Softwaresystem integriert. Ausgewählte Algorithmen wurden als Open Source Code der Forschungscommunity bereitgestellt. Dazu gehören der Algorithmus für Multimodales Interaktives Reinforcement Learning aus AP 1.1 [C4], der Algorithmus für Bayesian Correlated Classifier Fusion aus AP 1.4 [C5] und das Modell für Motion Planning Diffusion aus AP 3.3 [C6]. Zusätzlich sind die in IKIDA entstandenen Datensätze zur

Erkennung der Intention für Interaktion aus AP 2.2 [C1], von den Experimenten zur menschlichen Unsicherheit aus AP 2.1 [C2] sowie ein Datensatz für Knowledge Test Confidence aus AP 1.4 [C3] als Open Source online verfügbar.

AP 3.2 Untersuchung von aufgabenrelevantem Interaktionsdesign

Während der Projektlaufzeit wurden Experimente zu interaktiver KI an verschiedenen Aufgaben und Experimentalsettings durchgeführt. Dabei wurden sowohl strukturierte, wohldefinierte Aufgabenkontexte untersucht, als auch weniger strukturierte, offenere Fragestellungen. Zusätzlich gab es Unterschiede ob ein Roboter als Verkörperung der KI mit den Nutzern interagiert, oder ob die KI-Interaktion nur bildschirmbasiert stattfand. Hierbei konnten wir beobachten, dass nicht nur persönliche Präferenzen bei der zukünftigen Entwicklung der Interaktion mit KI beachtet werden sollten (AP 2.4) sondern, dass für ein gutes Interaktionsdesign auch Aspekte wie das Erscheinungsbild der KI und der Aufgabentyp mitgedacht werden müssen.

AP 3.3 Interaktives Fertigkeitlernen für Roboter

Es wurde ein Framework für Fertigkeitlernen von Robotern entwickelt, das es auch Nutzern ohne Robotik-Vorwissen ermöglicht, einem Roboter eine neue Fertigkeit beizubringen. Das Framework umfasst zum einen das Lernen von Low-Level-Aktionen in Form von geeigneten Repräsentationen wie probabilistische Bewegungsmotive oder Punkt-zu-Punkt-Bewegungen und zum anderen das Lernen von High-Level-Fertigkeiten bestehend aus einer Abfolge von Aktionen (Abbildung 10). Es wurde eine Nutzungsoberfläche in Form eines Webinterfaces entwickelt, die verschiedene Funktionalitäten bereitstellt, Nutzer:innen durch den Prozess des Erlernens Fertigkeiten führt und mit welchem bereits gelernte Fertigkeiten ausgeführt werden können. Auch zweiarmliges Fertigkeitlernen wurde in studentischen Abschlussarbeiten untersucht [A40, A44].

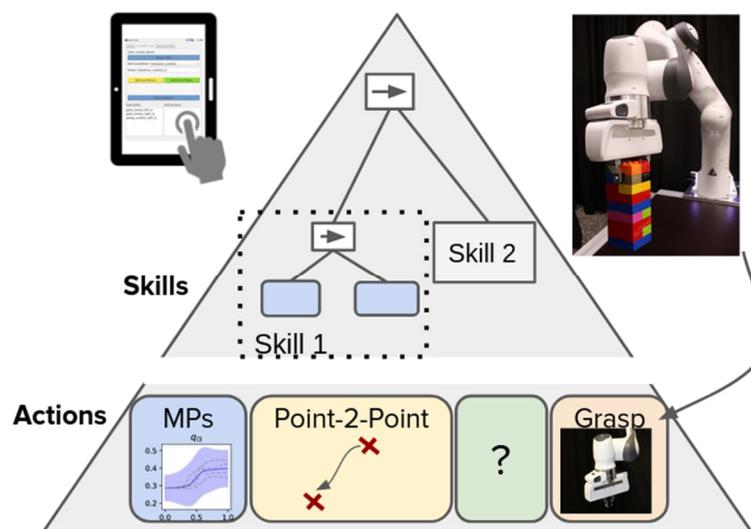


Abbildung 10: Übersicht über die Struktur des Frameworks für Roboter-Fertigkeitlernen, adaptiert von [1].

Interaktives Lernen von Behavior Trees basierend auf Demonstrationen

Es wurde ein neuer Ansatz zum Lernen eines Behavior Trees (BTs) basierend auf wenigen Nutzerdemonstrationen entwickelt und im *Frontiers Journal* veröffentlicht [22, 9]. Der Ansatz bietet Nutzenden eine intuitive Möglichkeit, um einem Roboter durch das Demonstrieren einer Aufgabe eine neue Fertigkeit beizubringen. Hierzu werden visuelle Features (Objektdistanzen) und die Sequenz der gezeigten High-Level-Aktionen von den Videos der Demonstrationen extrahiert. Darauf basierend werden Pre- und Post-

Konditionen für jede Aktion gelernt und ein initialer BT mithilfe des Backchaining-Ansatzes gebildet. Der Roboter führt diesen BT aus und erkennt automatisch potentiell auftretende Fehlerfälle. Diese Fehlerfälle werden gelöst, indem weitere Informationen vom Nutzer über ein Webinterface angefordert werden.

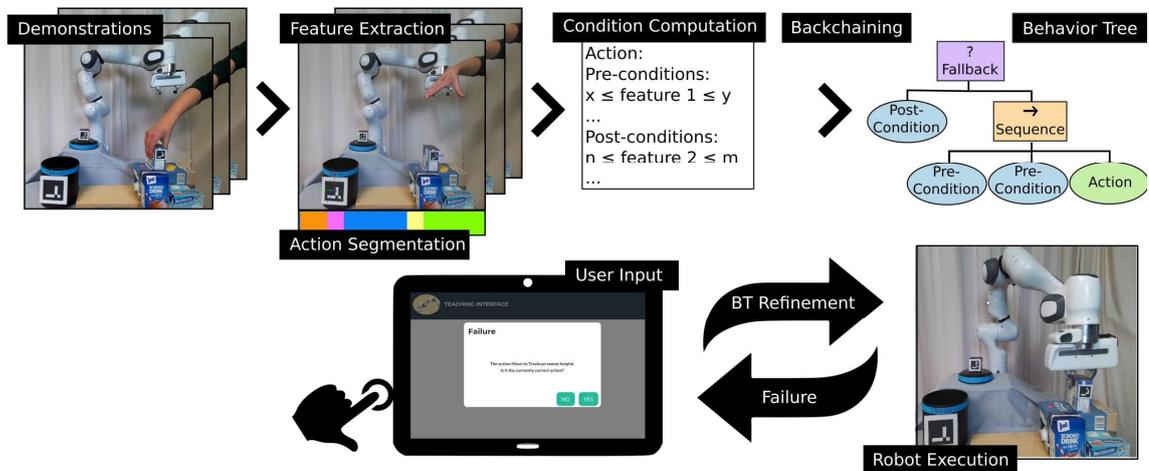


Abbildung 11: Das Lernen von Behavior Trees aus menschlichen Demonstrationen [9].

Der initiale BT wird dementsprechend verbessert. Ein Überblick der Methode ist in Abbildung 11 abgebildet, Abbildung 12 zeigt den Versuchsaufbau.

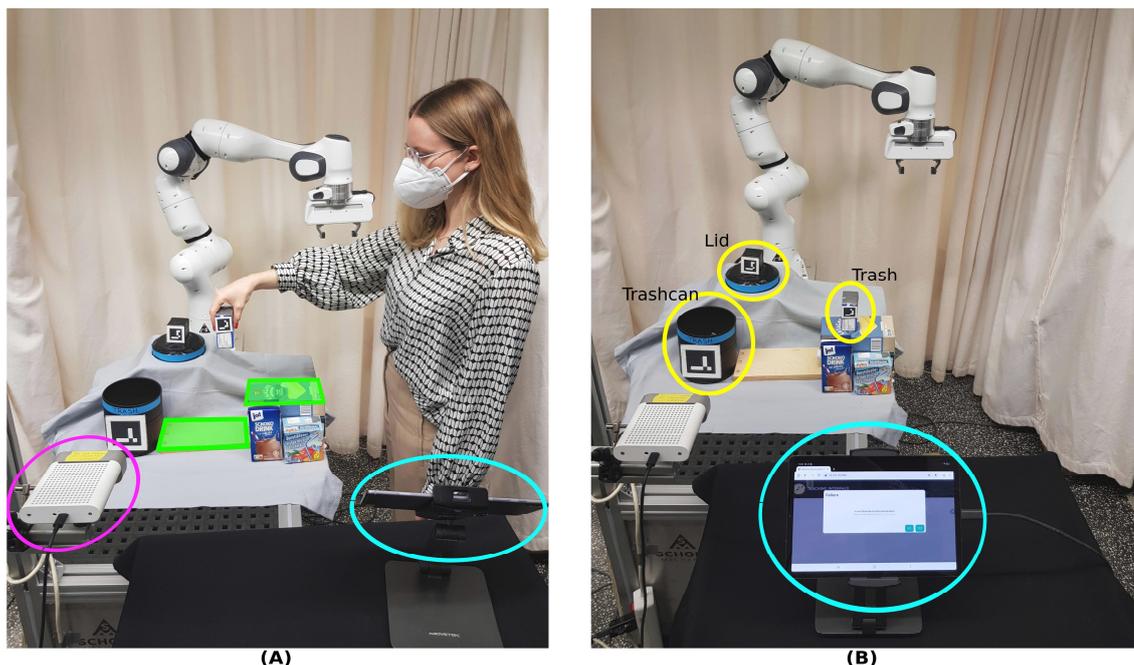


Abbildung 12: Experimentaufbau zum interaktiven Lernen von Behavior Trees. (A) Der Nutzer demonstriert die Aufgabe. Die Demonstrationen werden mithilfe einer Kamera (magenta) aufgenommen. (B) Der Roboter führt die gelernte Aufgabe aus, während der Nutzer Input über ein Tablet gibt (blau) [9].

Der oben beschriebene Ansatz zur Bestimmung von pre- und post-conditions für jede Aktion wurde im Rahmen einer studentischen Masterarbeit verbessert [A28] und die Ergebnisse als Late Breaking Results auf der internationalen HRI Konferenz präsentiert [21]. Statt die relevanten visuellen Features im Vorhinein manuell zu definieren, wurde der Feature-Raum hierzu zunächst verkleinert. Für die Verkleinerung des Feature-Raums

wurden zwei Methoden verglichen: eine Auswahl basierend auf Korrelationen zwischen den verschiedenen Features und eine Auswahl basierend auf einem Entscheidungsbaum. Daraufhin wurden aus diesem verkleinerten Feature-Raum für jede Aktion relevante pre- und post-conditions automatisch ausgewählt, basierend auf drei verschiedenen varianz-basierten Metriken.

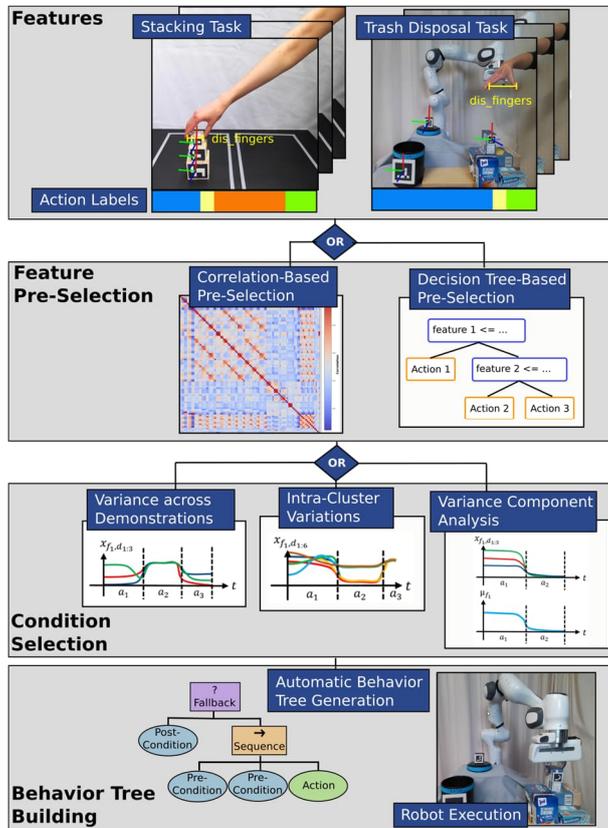


Abbildung 13: Übersicht zum Ansatz für automatische Featureextraktion und Condition Computation um Behavior Trees von Demonstrationen zu lernen [A28, 21].

Ein Überblick über die Methoden ist in Abbildung 13 abgebildet. Die verschiedenen Methoden wurden auf zwei verschiedenen Datensätzen von Nutzerdemonstrationen evaluiert. Die Ergebnisse zeigen, dass es möglich ist relevante pre- und post-conditions für Aktionen auszuwählen, die zur Generierung eines Behavior Trees geeignet sind.

Generative KI-Modelle für Bewegungsplanung

Bewegungsplanung ist ein wichtiges Thema in einer Robotik-Manipulationspipeline. Wenn ein Roboter eine ähnliche Aufgabe bereits viele Male ausgeführt hat, sollte er nicht alle Berechnungen wiederholen müssen, sondern stattdessen lernen, diese Informationen zu kodieren und von seinen vorherigen Erfahrungen zu lernen.

Wir haben eine Methode zum Erlernen von Bewegungsplanungsprioritäten für große Datenmengen entwickelt, die auch dann verwendet werden kann, wenn ein Roboter mit einer neuen Aufgabe konfrontiert wird, die Objekte enthält, die er während der Trainingsphase noch nie gesehen hat. Der entwickelte Algorithmus heißt Motion Planning Diffusion [A21, 7, 11].

Wir haben unsere neue Methode mit einem simulierten Roboter Arm in verschiedenen Umgebungen mit zunehmender Komplexität getestet. Unsere Ergebnisse zeigen, dass der Ansatz in der Lage ist, eine höhere Erfolgsrate und eine höhere Multimodalität in den generierten Trajektorien zu erreichen als die üblicherweise verwendeten generativen Modelle. Außerdem zeigen wir, dass diese Methode direkt auf einen realen Roboter

übertragen werden kann. Diese Arbeit wurde auf der IROS-Konferenz 2023 präsentiert [11] und befindet sich zu Projektende in Begutachtung für ein Journal [P3].

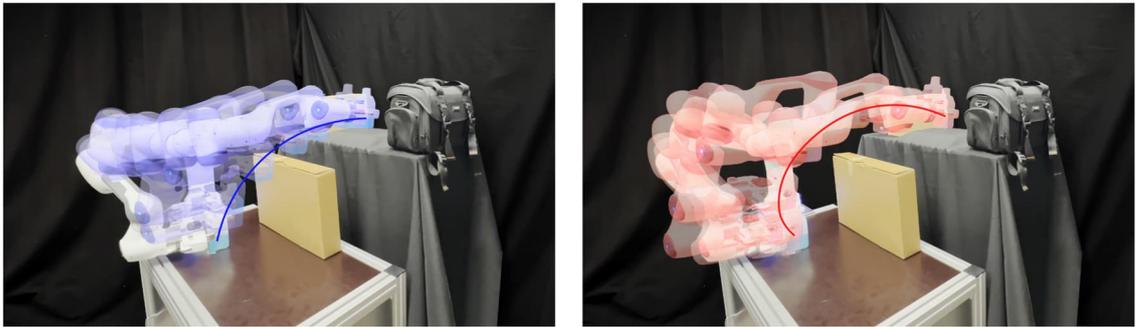


Abbildung 14: Beispiel für die Methode Motion Planning Diffusion, die bei einer realen Roboter-aufgabe zwei unterschiedliche Trajektorien erzeugt [11].

Generative KI für Greifposen

Das erfolgreiche Greifen von Objekten mit nur einer Einzelansichtskamera ist für viele Roboter-manipulationsaufgaben entscheidend.

Ein Ansatz zur Lösung dieses Problems ist die Nutzung von Simulationen, um große Datensätze von Objekt- und Greifposen zu erstellen und dann ein generatives KI-Modell zu lernen. Die Greifposen-Daten sind sehr multimodal, da es oft mehrere Möglichkeiten gibt, ein Objekt zu greifen.

Daher haben wir ein generatives Griffmodell mit Diffusionsmodellen entwickelt, um aus einer partiellen Punktwolke eines Objekts mögliche Griffhaltungen zu ermitteln [A43, P2]. Ein neuartiger Aspekt unserer Methode ist die Berücksichtigung von Diffusion im vielfältigen Raum der Rotationen und der Vorschlag einer Kollisionsvermeidungs-Kostenführung, um die Erfolgsrate des Greifens während der Inferenz zu verbessern. Um das Greifen zu beschleunigen, verwenden wir aktuelle Techniken aus der Diffusionsliteratur, um kürzere Inferenzzeiten zu erreichen. Wir konnten in Simulationen und realen Experimenten zeigen, dass unser Ansatz mehrere Objekte aus Tiefenbildern mit einer hohen Erfolgsrate erfassen und erfolgreich greifen kann, und haben ihn mit verschiedenen Vergleichsmodellen verglichen.

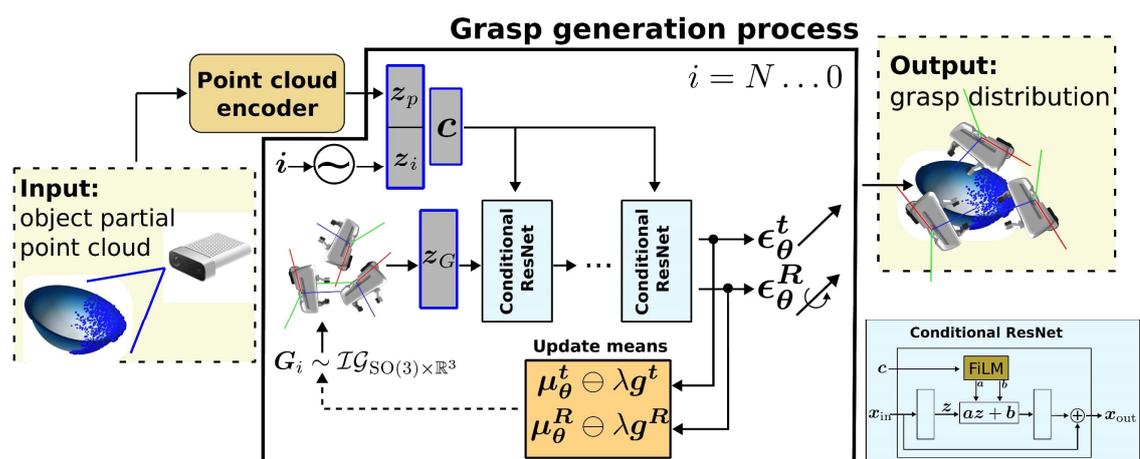


Abbildung 15: Übersicht über unsere neue Methode Grasp Diffusion Network, die aus einer Teilansicht eines Objekts als Punktwolke mögliche Positionen für erfolgreiches Greifen erzeugt [P2].

Abbildung 15 zeigt eine Übersicht unserer Methode. Diese Arbeit ist zu Projektende zur Begutachtung beim Journal Robotics and Automation Letters (RA-L) [P2].

AP 3.4 Interaktive Datenauswertung/-klassifikation mit KI

Interaktive Aktionssegmentierung

Es wurde ein Ansatz zur interaktiven Aktionssegmentierung entwickelt, der es ermöglicht Videos von Demonstrationen anhand visueller Merkmale in High-Level-Aktionen zu segmentieren ohne dass ein gelabelter Datensatz für das Trainieren eines Modells benötigt wird. Zudem kann der Nutzer das Modell zur Aktionssegmentierung durch Interaktion mit einem Interface verbessern. Das Modell besteht aus einem Prototypical Network (ProtoNet) in Kombination mit einem Hidden Semi-Markov Model (HSMM), um overfitting zu vermeiden. Die entwickelte Methode wurde erfolgreich bei der bei der RO-MAN Konferenz präsentiert [10].

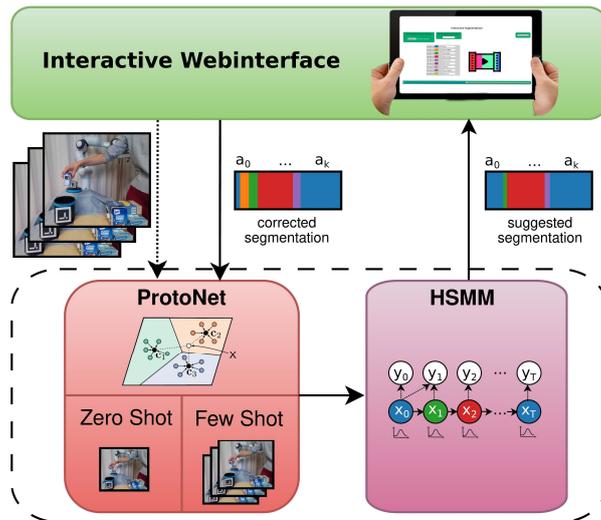


Abbildung 16:

Übersicht zum entwickelten Interaktiven Webinterface und KI-Backend zur interaktiven Aktionssegmentierung [10].

Interaktive Erkennung von Anomalien

In Zusammenarbeit mit dem Industriepartner Porsche Motorsport wurde an dem definierten Anwendungsfall „Interaktive KI für Anomalieerkennung“ zur Nutzung bestehender maschineller Lernalgorithmen zur automatischen Erkennung von Anomalien unter Einbezug von Domänen-Expertenwissen in einem interaktiven, maschinellen Lernschema gearbeitet. Dafür wurden in verschiedenen Abschlussarbeiten erste Ideen entwickelt [A11, A14, A24] und in einer gemeinsam mit Porsche Motorsport betreuten Masterthesis wurde abschließend ein erster Prototyp entwickelt der Frontend und Backend mit bestehender Porsche-Software integriert [A25]. Die Integration von Nutzerfeedback in Machine Learning Modelle wurde in einer weiteren industrienahen Masterthesis untersucht [A41].

AP 4

Studien zu interaktivem Lernen, Industrie-Board sowie ELSI

AP 4.1 Studien zum interaktiven Mensch-Mensch-Lernen

Es wurden kognitive Grundlagen des Problemlösens und Lernens bei Menschen in Experimenten erforscht. Hierzu wurde eine Studie mit „Lautem Denken“ beim Lösen von offenen Problemen (Schätzaufgaben, sogenannte Guesstimation Aufgaben) durchgeführt. Die daraus resultierenden Denkprotokolle wurden analysiert und durch diese konnten von Menschen angewandte Lösungsstrategien sowie Schritte des kognitiven Prozesses entdeckt und beschrieben werden. Dabei wurden die Lösungsabläufe der Versuchspersonen formalisiert und in AP 4.2 angewandt. Außerdem wurde in einer Studie untersucht, wie Versuchspersonen ihre Antworten mit Unsicherheitshinweisen ergänzen

mittels Angabe der Antworten als Verteilung, nachdem wir hierzu verschiedene Darstellungsmethoden recherchiert und deren Vor- und Nachteile untersucht hatten [A23]. Genauere Details zu diesen Studien können der Publikation „Deliberation in Guesstimation Problems“ entnommen werden [P4], die sich zu Projektende noch in Begutachtung befindet.

AP 4.2 Studien zum interaktiven Mensch-KI-Lernen

Es wurden Studien zur Mensch-KI-Interaktion bei „offenen“ Problemen wie Brainstorming für Schätzaufgaben (Guesstimation) und Studien zur Zusammenarbeit von Mensch und KI bei strukturierteren Aufgaben z. B. für Kollaboration von Mensch und Roboter in geteilten Arbeitsräumen durchgeführt.

KI-gestütztes Brainstorming für Guesstimation-Probleme

Die in AP 4.1 entstandenen Resultate und Formalisierungen der kognitiven Prozesse beim Problemlösen sowie die daraus definierten Strategien wurden genutzt, um nicht nur festzustellen, an welchen Stellen Menschen Unterstützung brauchen beim Lösen solcher Aufgaben, sondern auch um ein entsprechendes KI-Tool zu nutzen, welches darauf ausgelegt ist in diesen Situationen helfen zu können [11, A9, A22]. Hierbei wurde ein KI-Tool entwickelt, das Menschen beim Brainstorming zu Guesstimation-Problemen helfen kann. Abbildung 17 zeigt eine Übersicht über den Ansatz.

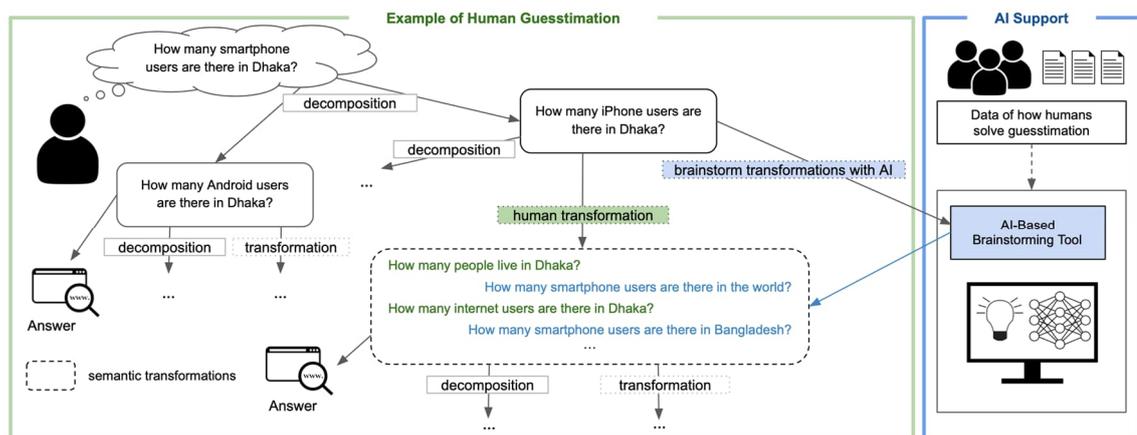


Abbildung 17: Übersicht des Ansatzes für ein KI-Tool zum Brainstorming-Support in Schätzaufgaben (Guesstimation) [11]

Die Erkenntnisse und Daten aus AP 4.1 darüber, wie Menschen solche Aufgaben bewältigen wurden dabei auch genutzt um ein KI-Modell zu prompten, sodass es sinnvolle und menschenähnliche Fragen brainstormen kann. In einer Studie konnten wir dabei zeigen, dass Menschen, die von der KI oder anderen Personen generierten Vorschläge nicht eindeutig voneinander unterscheiden konnten. Anschließend wurde das KI-Tool in einem weiteren Experiment eingesetzt, um zu testen, ob Versuchspersonen dieses nutzen, wenn sie feststecken und damit ihre Antwortgenauigkeit verbessern können. Obwohl das Tool erfolgreich menschenähnliche Vorschläge produzierte, zögerten viele Proband:innen es zu benutzen. Aus unseren Ergebnissen schließen wir, dass KI-Systeme die Assoziationen der Nutzenden nicht imitieren, sondern ergänzen müssen, wenn die Interaktion zwischen Mensch und KI mit LLMs erfolgreich sein soll [11].

Kollaboration in geteilten Arbeitsräumen

Die Gestaltung von Interaktionen für Mensch-KI-Teams kann aufgrund der potentiellen Autonomie eines KI-Agenten eine Herausforderung darstellen. Frühere Arbeiten deuten darauf hin, dass eine höhere Autonomie nicht immer die Teamleistung verbessert und eine situationsabhängige Anpassung der Autonomie von Vorteil sein könnte. Es fehlt

jedoch an systematischen empirischen Evaluierungen einer solchen Autonomieanpassung in der Mensch-KI-Interaktion. Wir haben daher eine räumlich kooperative Aufgabe entworfen, um die Auswirkungen von festen Niveaus der KI-Autonomie im Vergleich zu einer situationsabhängigen Autonomieanpassung auf die Teamleistung und die Zufriedenheit der Nutzer:innen zu untersuchen [12, 20, A31, A32, A36, A42].

Die Versuchspersonen sollen mit der KI zusammen gelieferte Boxen ausräumen und den Inhalt entsprechend sortieren. Gesamtziel ist es dabei den Inhalt von so vielen Boxen wie möglich in einem festgelegten Zeitrahmen zu sortieren. Dafür müssen beispielsweise Bücher in ein Bücherregal geräumt werden und Unterlagen sortiert, gelabelt und eingehftet werden. Beide Teampartner (Mensch und KI) können dabei nicht jede Teilaufgabe (gleich gut) erledigen und müssen sich daher miteinander koordinieren und kooperieren, um das Gesamtziel zu erreichen.

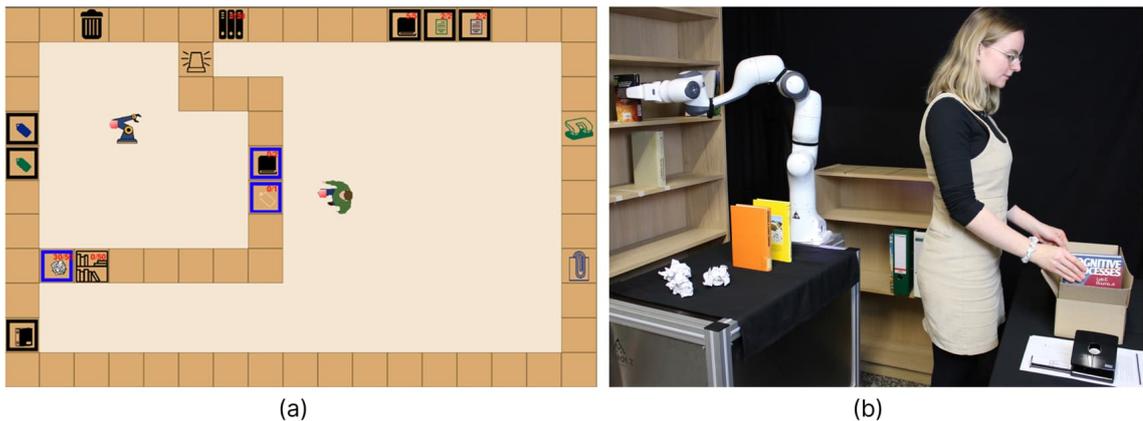


Abbildung 18: (a) zeigt die Simulationsumgebung in welcher der Mensch navigieren und zusammen mit der KI (dargestellt durch den Roboter Arm) eine Organisationsaufgabe lösen muss. (b) zeigt den Aufbau der Aufgabe im echten Roboter Labor.

Spezifisch haben wir untersucht, welche Auswirkungen der Autonomiegrad sowie die automatische Anpassung, also Zu- und Abnahme der Autonomie, je nach Situation auf die Performance des Mensch-KI-Teams hat. In quantitativen Auswertungen wird hierbei untersucht, ob es einen signifikanten Unterschied gibt zwischen 5 Autonomiearten, welche die KI haben konnte: gar keine, wenig, mittel, viel und dynamische Autonomie. Wir haben dabei Anpassungsregeln für KI-Autonomie aus früheren Arbeiten, verschiedenen Vorstudien [A10, A12] und einer Pilotstudie abgeleitet.

Um die Adaption der Autonomie gewinnbringend einzusetzen, wurden die aktuelle Situation sowie kognitive Modelle, wie z. B. Modelle der Theory of Mind (siehe auch AP 2.2) einbezogen. Die Ergebnisse zeigen, dass ein KI-System, das seine Autonomie dynamisch der Situation anpasst in unserem Setting am besten mit dem Menschen zusammenarbeiten kann und so im Schnitt die beste Teamperformance hervorbringt. Außerdem nahmen die Versuchspersonen dieses KI System als am intelligentesten und insgesamt als positiv und hilfreich wahr.

Anhand dieser Ergebnisse haben wir auch den Einfluss unterschiedlicher Autonomiegrade auf Mensch-KI-Teams in gemeinsamen Arbeitsumgebungen diskutiert. Weitere Details zu der Studie können der Publikation „An Evaluation of Situational Autonomy for Human-AI Collaboration in a Shared Workspace Setting“ entnommen werden [20].

AP 4.4 Industrie-Board: Praxisrelevanz

Es wurden mehrere (virtuelle) Workshops mit den assoziierten Industriepartnern Porsche-Motorsport und Energy Robotics durchgeführt, um Nutzen und potentielle Hürden für den Einsatz von (interaktiver) KI in der Industrie zu evaluieren und

gemeinsam praxisrelevante Use Cases für interaktive KI zu finden. Aus diesen Workshops entstanden die zwei industrienahen Use Cases „Interaktive KI-gestützte Anomalie Detektion“ und „Intuitives Fertigkeitlernen für Inspektionsroboter“.

Interaktives Erlernen einer Inspektionsroute

Im Rahmen der Zusammenarbeit mit dem Industriepartner Energy Robotics wurden Methoden entwickelt zum interaktiven Demonstrieren einer Inspektionsroute. Ziel war es, ein System zu entwickeln, das es Inspekteur:innen ohne Vorwissen ermöglicht, einem Roboter eine Inspektionsroute beizubringen. Es wurde ein Ansatz entwickelt, der den Roboter befähigt eine Person zu erkennen, dieser mit einem gewissen Abstand zu folgen und gleichzeitig den Pfad einzuspeichern. Zudem wurde eine Methode entwickelt, um Zeigegesten und die dazugehörige Zeigerichtung zu erkennen. Dafür wurden vor Ort beim Industriepartner auch Daten aufgenommen um darauf angepasste KI-Modelle zu trainieren [A39]. Durch diese Zeigegesten wird dem Roboter signalisiert, wo sich auf der Inspektionsroute Sensoren befinden, die abgelesen werden sollen. In Zukunft soll das Gesamtsystem in Experimenten mit Versuchspersonen evaluiert werden. Zudem soll der Einfluss der äußeren Erscheinung des Roboters auf die Qualität der Interaktion und Präferenzen der Nutzer:innen untersucht werden.

Interaktive KI-gestützte Anomalie Erkennung

Zunächst wurden detaillierte Interviews mit Expert:innen bei Porsche Motorsport geführt, um zu verstehen wie diese bei der Analyse und Erkennung von Anomalien in ihren Daten zu Rennfahrzeugen vorgehen [A11] und auch um die jeweiligen Workflows zu klären.

So konnten wir sicherstellen, dass die spezifischen Nutzer:innen im Fokus der Entwicklung standen und entsprechend zu entwerfende KI-Systeme sowohl diese Expert:innen bestmöglich unterstützen als auch durch die KI-Mensch-Interaktion ein systemischer Gewinn entstehen kann. Erste Algorithmen, die für KI-basierte interaktive Anomalie-Erkennung nutzbar sind wurden in einer gemeinsam betreuten Masterthesis evaluiert [A24]. In dieser Thesis wurde auch ein Prototyp für ein Frontend und Backend entwickelt.

Ethische Aspekte

Da wir in verschiedenen Interaktionsstudien Sprachmodelle nutzen (Large Language Models), haben wir nicht nur untersucht wie Menschen mit diesen gewinnbringend bei der Lösung von z. B. Guesstimation-Aufgaben interagieren könnten, sondern haben diese genutzten Modelle auch hinsichtlich ihrer ethischen Aspekte evaluiert [A30, A33]. Insbesondere haben wir vier, zur Projektlaufzeit aktuelle Modelle (GPT-3.5, GPT-4, Llama 2 und Mistral AI) darauf getestet, ob sie hinsichtlich Namen stereotypische und negativ konnotierte Zuweisungen machen. Viele Studien zeigen, dass solche Probleme existieren, obwohl die Sprachmodelle inzwischen auch oft versuchen mithilfe von Filtermethoden negative und mit Bias behaftete Aussagen zu reduzieren. Nichtsdestotrotz fanden wir in unserer Studie stereotypische und negative Zuweisungen bezüglich Geschlecht, d. h. wie männliche und weibliche Namen zugeordnet werden, sowie Religion. Hier verglichen wir, wie muslimische und nicht-muslimische Namen behandelt werden [A33, 19]. Außerdem wurden Effekte aufgedeckt, die zeigen, dass häufige und seltene Namen unterschiedlich behandelt werden und daher auch diese Dimension berücksichtigt werden müsste.

Auch in Workshops mit den assoziierten Industriepartnern wurden ethische Aspekte zum Thema Praxis-Einsatz von KI diskutiert. Speziell ging es dabei um Aspekte des Datenschutzes bei der Nutzerdaten-Auswertung oder Kameradatenaufnahmen sowie um Robustheit und Sicherheitsaspekte der entwickelten KI-Modelle.

AP 5	Mentoring und wissenschaftliches Coaching
	Zusätzlich zu den 5 (teils virtuellen) Meilensteintreffen (AP 5.1) wurden mehrere interne Team-Workshops durchgeführt um den IKIDA-Wissenschaftler:innen individuelles Feedback zu ihren Arbeiten innerhalb des Projekts und auch der weiteren Karrieregestaltung zu geben (AP 5.2). Es wurden insgesamt 26 Masterarbeiten und 18 Bachelorarbeiten im Rahmen von IKIDA erfolgreich beendet (AP 5.2). Besonders hervorzuheben ist hierbei auch die erfolgreiche Integration von Studierenden in das IKIDA-Team als wissenschaftliche Hilfskräfte, wodurch die Studierenden parallel zu ihrem Studium erste, eigene Erfahrungen in Forschungsnähe machen und auch wertvolle Einblicke in projektorientiertes Arbeiten erhalten konnten.

2.2 Die wichtigsten Positionen des zahlenmäßigen Nachweises

Das Budget des Projekts deckte sich zum größten Anteil mit Personalkosten. Von den zu Projektende nachgewiesenen Kosten entfielen 83,5 % auf wissenschaftliche Mitarbeiter:innen, 5,5 % auf wissenschaftliche Hilfskräfte. 8,6 % des Budgets waren Investitions-/Anschaffungskosten für Robotik, Sensorik und zugehörige Technik bzw. Software. Schließlich entfielen 2% der Kosten auf Reisekosten zu wissenschaftlichen Konferenzen und Messen. Die Verwendung der Fördermittel ist durch die bearbeiteten Projektthemen und die erzielten Ergebnisse dargelegt.

2.3 Notwendigkeit und Angemessenheit der geleisteten Arbeit

IKIDA wurde im Rahmen der Richtlinie zur Förderung von KI-Nachwuchswissenschaftlerinnen gefördert, mit dem Ziel insbesondere qualifizierte Frauen in KI-bezogenen Anwendungsgebieten zu fördern. Zweck war die Erforschung von KI-Fragestellungen zu neuartigen und innovativen Themen durch Nachwuchsgruppen, die von Frauen geleitet werden.

Den Zielen der Förderung von KI-Nachwuchswissenschaftlerinnen konnte IKIDA in hohem Maße nachkommen. Der Anteil der Projektmonate, welche durch Wissenschaftlerinnen erbracht wurden lag bei 85%; das Kernteam bestand außer der promovierten Gruppenleiterin aus drei Doktorandinnen und einem Doktoranden. Alle genannten wissenschaftlichen Mitarbeiter:innen konnten im Projekt-rahmen (bzw. kurz nach Projektende) ihr Qualifikationsziel der Promotion erreichen.

Inhaltlich umfasste IKIDA dabei anwendungsrelevante Forschungsfragen, für die starkes grundlagenorientiertes Interesse an der TU Darmstadt besteht und ausgewiesene Expertise vorlag und vorliegt. Gleichzeitig war es in seinem Themenumfang notwendigerweise interdisziplinär und bezog Beteiligte aus der Robotik, der Kognitionswissenschaft, der Informatik sowie assoziiert angebundene Industriepartner mit ein.

Die Organisation eines solch komplexen Forschungsvorhabens im Rahmen der Stellengrundausstattung universitärer Fachgruppen ist in diesem Umfang kaum möglich und bedürfte einer mehrjährigen Vorbereitungsphase um die Verfügbarkeit der jeweiligen Planstellen aufeinander abzugleichen. Eine direkte Auftragsforschung zu den inhaltlichen Projektzielen war aus Kosten-Nutzen-Perspektive möglicher Wirtschaftspartner nicht darstellbar aufgrund des Risikos der notwendig hohen Anteile im Bereich der Grundlagenforschung sowie dem geplanten interdisziplinären Gesamt-Projektumfang.

Die erhaltene Projektförderung im Rahmen des IKIDA-Projektes hat daher überhaupt erst ermöglicht die beschriebenen Fragestellungen in dieser Breite zeitnah und sowohl wissenschaftlich fundiert, als auch dennoch durch die Praxis begleitet untersuchen zu können. Der explorative Gesamtansatz zwischen notwendiger Grundlagenforschung und Orientierung am gewählten Einsatzfeld und deren Fragestellungen, begründet dabei zugleich die dargestellten Arbeitsaufwände als notwendig im Sinne der Zielerreichung und rechtfertigt die risikoorientierte öffentliche Forschungsförderung.

2.4 Darstellung des voraussichtlichen Nutzens

KI-Systeme, die in direkter Interaktion mit Nutzer:innen lernen und dabei auch mit suboptimalen menschlichen Angaben umgehen können, haben ein sehr hohes Potential in verschiedenen Anwendungsbereichen. Diese Fähigkeit kann als eine Kerntechnologie zukünftiger, lernender Roboter angesehen werden. Exemplarisch wurde in IKIDA gezeigt wie Roboter durch multimodale Erkennung menschlicher Unsicherheit trotz teilweise fehlerhafter Rückmeldungen der Menschen ihre eigenen Fertigkeiten verbessern können und wie sie von menschlichen Demonstrationen inkrementell neue Aufgaben lernen können. Ein Hauptforschungsschwerpunkt war dabei in IKIDA auch die Multimodalität in der Interaktion und wie verschiedene Modalitäten oder Expertenmeinungen in Bayes'schen Modellen zur Unsicherheitsreduktion genutzt werden können. Mögliche Anwendungsgebiete sind hierbei neben Klassifikationsproblemen in industrienahen Anwendungen, wie z. B. KI-gestützter Anomalie-Erkennung, auch solche in der Medizin, z. B. in Form KI-assistierter medizinischer Behandlung.

Das in IKIDA entwickelte und untersuchte Konzept für dynamische Autonomieerkennung kann helfen Mensch-Roboter-Interaktion in geteilten Arbeitsräumen in der Industrie zu verbessern und Effizienz sowie Akzeptanz der Robotik-Systeme zu steigern. Gleichzeitig lässt es sich auch auf kooperative Mensch-KI-Interaktion ausweiten und kann dabei helfen zu verstehen wie in einem Mensch-KI-Team eine Kompetenz- und Initiativen-Priorisierung gewinnbringend realisiert werden kann.

Die TU Darmstadt verfolgt mit IKIDA als universitärer Forschungspartner allerdings keine unmittelbaren, eigenständigen kommerziellen Ziele. Aus wissenschaftlicher Sicht haben die im Projekt entstandenen Publikationen eine sehr gute Grundlage für weitere Forschungen in der wissenschaftlichen Community ermöglicht, natürlich insbesondere auch für die beteiligten Forscher:innen und assoziierten Industriepartner, welche nach Projektende diese Arbeiten in weitere Kontexte übertragen werden.

Die Anschlussfähigkeit der IKIDA-Themen und -Ergebnisse ist dabei sowohl im wissenschaftlichen, als auch im anwendungsbezogenen Kontext sehr hoch. Durch den aktuell verstärkten gesamtgesellschaftlichen Diskurs über Nutzen und Risiken von (interaktiven) KI-Systemen wie z. B. ChatGPT ist die menschenzentrierte KI-Algorithmik-Entwicklung weiterhin ein hoch aktuelles Forschungsthema. Damit ist auch mittel- bis längerfristig von einer hohen wissenschaftlichen und wirtschaftlichen Relevanz der in IKIDA erforschten Ansätze und Fragestellungen auszugehen.

IKIDA war Bestandteil der Förderlinie von wissenschaftlichen Nachwuchsgruppen unter Leitung von Frauen im Bereich der Künstlichen Intelligenz. Hierbei war ein Hauptfokus auch die Förderung der beteiligten Wissenschaftler:innen und deren Karriereunterstützung. In IKIDA wurden erfolgreich 18 Bachelorarbeiten (davon 10 weiblich) und 26 Masterarbeiten (davon 8 weiblich) betreut, zwei Promotionen beendet sowie zwei weitere Promotionen zu Projektende eingereicht und Beginn 2025 beendet (75% weiblich), davon eine Promotion unter hauptverantwortlicher Betreuung der Gruppenleiterin, der im Laufe des Projekts der Status einer unabhängigen Nachwuchsgruppenleiterin mit Promotionsrecht an der TU Darmstadt zuerkannt wurde.

2.5 Fortschritt auf dem Gebiet des Vorhabens bei anderen Stellen

Im Projektzeitraum entstand durch die Veröffentlichung der ChatGPT KI-Modelle in der gesellschaftlichen und wissenschaftlichen KI-Diskussion ein starker Fokus auf Interaktion mit großen Sprachmodellen (LLMs) und generativer KI (z. B. auch Stable Diffusion). Diese beeindruckenden neuen Forschungsergebnisse hatten auch Einfluss auf Themen, die in IKIDA untersucht wurden, wie z. B. die Untersuchung des Einsatzes von LLMs für Brainstorming im Guesstimation Problem Solving oder den Diffusionsmodellen für Bewegungsplanung bei Robotern.

Im Rahmen des wissenschaftlichen Projektvorgehens wurden im Übrigen internationale Forschungsansätze und Forschungsergebnisse, welche die Themengebiete von IKIDA betrafen, genau verfolgt und in unserer Arbeit und den wissenschaftlichen Publikationen berücksichtigt. Die Referenzen in den unter Abschnitt 2.6 aufgeführten Veröffentlichungen geben daher auch ein Bild der Forschungsergebnisse Dritter, welche für unsere Arbeit relevant waren.

2.6 Erfolgte oder geplante Veröffentlichung des Ergebnisses

Konferenz- und Journalbeiträge, Zeitschriften

- [1] Knaust, M., & Koert, D. (2021). Guided Robot Skill Learning: A User-Study on Learning Probabilistic Movement Primitives with Non-Experts. International Conference on Humanoid Robots.
- [2] Turan, C., Koert, D., Neergaard, K. D., & Lioutikov, R. (2021). Empowering Interactive Robots by Learning Through Multimodal Feedback Channel. In Proceedings of the 2021 International Conference on Multimodal Interaction
- [3] Scherf, L., Turan, C., & Koert, D. (2022). Learning from Unreliable Human Action Advice in Interactive Reinforcement Learning: IEEE-RAS 21st International Conference on Humanoid Robots (Humanoids).
- [4] Carvalho, J., Koert, D., Daniv, M., & Peters J. (2022). Residual Robot Learning for Object-Centric Probabilistic Movement Primitives. IEEE-RAS 21st International Conference on Humanoid Robots (Humanoids).
- [5] Trick, S., Herbert F., Rothkopf, C., & Koert, D. (2022). Interactive Reinforcement Learning with Bayesian Fusion of Multimodal Advice. Robotics & Automation Letters (RA-L) with presentation at International Conference on Intelligent Robots and Systems (IROS).
- [6] Trick, S., & Rothkopf, C. A. (2022). Bayesian Classifier Fusion with an Explicit Model of Correlation. International Conference on Artificial Intelligence & Statistics (AISTATS).
- [7] Carvalho, J., Baierl, M., Urain, J., & Peters, J. (2022). Conditioned Score-Based Models for Learning Collision-Free Trajectory Generation. NeurIPS 2022 Workshop on Score-Based Methods.
- [8] Salikutluk, V., Koert, D., & Jäkel, F., „Interacting with Large Language Models: A Case Study on AI-Aided Brainstorming for Guesstimation Problems“ (2023). International Conference on Hybrid Human-Artificial Intelligence.
- [9] Scherf, L., Schmidt, A., Pal, S., & Koert, D. (2023). Interactively Learning Behavior Trees from Imperfect Human Demonstrations. Frontiers in Robotics and AI.
- [10] Gassen, M., Metzler, F., Prescher, E., Prasad, V., Scherf, L., & Koert, D. (2023). I³: Interactive Iterative Improvement for Few-Shot Action Segmentation. International Symposium on Robot and Human Interactive Communication (RO-MAN).
- [11] Carvalho, J., Le, A., Baierl, M., Koert, D., & Peters, J. Motion Planning Diffusion: Learning and Planning of Robot Motions with Diffusion Models, (2023). IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS).
- [12] Salikutluk, V., Frodl, E., Herbert, F., Balfanz, D., & Koert, D. (2023). Situational Adaptive Autonomy in Human-AI Cooperation. CHI Workshop Automation XP23: Intervening, Teaming, Delegating Creating Engaging Automation Experience.
- [13] Scherf, L., Schmidt, A., Pal, S., & Koert, D. (2023). Interactively Learning Behavior Trees from Imperfect Human Demonstrations. Presented at the Second International Conference on Hybrid Human-Artificial Intelligence (HHAI) 2023: Augmenting Human Intellect.
- [14] Scherf, L., Gasche, L., Chemangui, C., & Koert, D. (2023). Multimodal Human Uncertainty Detection in Human-AI Interaction. Presented at Computational Cognition Conference (ComCo). (Extended Abstract)
- [15] Scherf, L., Gasche, L., Chemangui, C., & Koert, D. (2024). Are you sure? - Multi-Modal Human Decision Uncertainty Detection in Human-Robot-Interaction. 19th Annual ACM/IEEE International Conference on Human Robot Interaction (HRI).
- [16] Trick, S., Rothkopf, C.A., & Jäkel, F. (2023). A Normative Model for Bayesian Combination of Subjective Probability Estimates. Judgment and Decision Making, 18, E40.

- [17] Trick, S., Lott, V., Scherf, L., Rothkopf, C.A., & Koert, D. (2023). What Can I Help You With: Towards Task-Independent Detection of Intentions for Interaction in a Human-Robot Environment. Proceedings of the 2023 32nd IEEE International Conference on Robot and Human Interactive Communication (RO-MAN)
- [18] Scherf, L., Maurer, C., & Koert, D. (2024). Combining State-Dependent Trust in Policy and Human Advice for Interactive Reinforcement Learning. Presented at Human-Interactive Robot Learning Workshop (HIRL), 19th Annual ACM/IEEE International Conference on Human Robot Interaction (HRI)
- [19] Salikutluk, V., Doğan, E., Clev, I., & Jäkel, F. (2024). Involving affected communities to evaluate biases in large language models: A case-study on Muslim names. Workshop on "HEAL: Human-centered Evaluation and Auditing of Language Models" at CHI Conference 2024 on Human Factors in Computing Systems.
- [20] Salikutluk, V., Schöpfer, J., Herbert, F., Scheuermann, K., Frodl, E., Balfanz, D., Jäkel, F., & Koert, D. (2024). An Evaluation of Situational Autonomy for Human-AI Collaboration in a Shared Workspace Setting. Proceedings of the CHI Conference on Human Factors in Computing Systems.
- [21] Scherf, L., Fröhlich, K., & Koert, D., (2024). Learning Action Conditions for Automatic Behavior Tree Generation from Human Demonstrations. Companion of the 2024 ACM/IEEE International Conference on Human-Robot Interaction.
- [22] Prasad, V., Koert, D., Stock-Homburg, R., Peters, J., & Chalvatzaki, G. (2022). MILD: Multimodal Interactive Latent Dynamics for Learning Human-Robot Interaction. 2022 IEEE-RAS 21st International Conference on Humanoid Robots (Humanoids), 472–479.
- [23] Rawal, N., Koert, D., Turan, C., Kersting, K., Peters, J., & Stock-Homburg, R. (2022). ExGenNet: Learning to Generate Robotic Facial Expression Using Facial Expression Recognition. *Frontiers in Robotics and AI*, 8.
- [24] Vorndamme, J., Carvalho, J., Laha, R., Koert, D., Figueredo, L., Peters, J., & Haddadin, S. (2022). Integrated Bi-Manual Motion Generation and Control shaped for Probabilistic Movement Primitives. 2022 IEEE-RAS 21st International Conference on Humanoid Robots (Humanoids), 202–209.
- [25] David, R., Franziska, H., Fabian, K., Dorothea, K., Joni, P., Jan, P., & Thomas, H. W. (2024). Entropy Based Blending of Policies for Multi-Agent Coexistence. Research Square.
- [26] Göksu, Y., De Almeida Correia, A., Prasad, V., Kshirsagar, A., Koert, D., Peters, J., & Chalvatzaki, G. (2024). Kinematically Constrained Human-like Bimanual Robot-to-Human Handovers. Companion of the 2024 ACM/IEEE International Conference on Human-Robot Interaction, 497–501.
- [27] Hahne, F., Prasad, V., Kshirsagar, A., Koert, D., Stock-Homburg, R. M., Peters, J., & Chalvatzaki, G. (2024). Transition State Clustering for Interaction Segmentation and Learning. Companion of the 2024 ACM/IEEE International Conference on Human-Robot Interaction, 512–516.
- [28] Prasad, V., Kshirsagar, A., Koert, D., Stock-Homburg, R., Peters, J., & Chalvatzaki, G. (2024). MoVEInt: Mixture of Variational Experts for Learning Human–Robot Interactions From Demonstrations. *IEEE Robotics and Automation Letters*, 9(7), 6043–6050.

Preprints

- [P1] Kempf, L., Maurer, C., Turan-Schwiewager, C., & Koert, D. (submitted 2024). Can I Trust You? - Handling Unreliable Human Action Advice in Interactive Reinforcement Learning. Submitted to *ACM Transactions on Human-Robot Interaction*.
- [P2] Carvalho, J., Le, A.T., Jahr, P., Sun, Q., Urain, J., Koert, D., & Peters, J. (submitted 2024) Grasp Diffusion Network: Learning Grasp Generators from Partial Point Clouds with Diffusion

- Models in SO3xR3. Submitted to IEEE Robotics and Automation Letters (RA-L). <https://arxiv.org/abs/2412.08398>
- [P3] Carvalho, J., Le, A.T., P., Kicki, P., Koert, D., & Peters, J. (submitted 2024) Learning and Adapting Robot Motion Planning with Diffusion Models. Submitted to IEEE Transaction on Robotics. <https://arxiv.org/abs/2412.19948>
- [P4] Salikutluk, V., & Jäkel, F. (submitted 2024). Deliberation in Guesstimation. Submitted to Cognitive Science.
- [P5] Carvalho, J., Koert, D., Daniv, M., & Peters, J. (2022). Residual Robot Learning for Object-Centric Probabilistic Movement Primitives (arXiv:2203.03918). arXiv. <https://doi.org/10.48550/arXiv.2203.03918>
- [P6] Carvalho, J., Le, A., Kicki, P., Koert, D., & Peters, J. (2024). Motion Planning Diffusion: Learning and Adapting Robot Motion Planning with Diffusion Models (arXiv:2412.19948). arXiv. <https://doi.org/10.48550/arXiv.2412.19948>
- [P7] Carvalho, J., Le, A. T., Jahr, P., Sun, Q., Urain, J., Koert, D., & Peters, J. (2024). Grasp Diffusion Network: Learning Grasp Generators from Partial Point Clouds with Diffusion Models in SO(3)xR3 (arXiv:2412.08398). arXiv. <https://doi.org/10.48550/arXiv.2412.08398>
- [P8] Funk, N., Urain, J., Carvalho, J., Prasad, V., Chalvatzaki, G., & Peters, J. (2024). ActionFlow: Equivariant, Accurate, and Efficient Policies with Spatially Symmetric Flow Matching (arXiv:2409.04576). arXiv. <https://doi.org/10.48550/arXiv.2409.04576>
- [P9] Palenicek, D., Lutter, M., Carvalho, J., Dennert, D., Ahmad, F., & Peters, J. (2024). Diminishing Return of Value Expansion Methods (arXiv:2412.20537). arXiv. <https://doi.org/10.48550/arXiv.2412.20537>
- [P10] Prasad, V., Heitlinger, L., Koert, D., Stock-Homburg, R., Peters, J., & Chalvatzaki, G. (2023). Learning Multimodal Latent Dynamics for Human-Robot Interaction (arXiv:2311.16380). arXiv. <https://doi.org/10.48550/arXiv.2311.16380>

Abschlussarbeiten

- [A1] M.Sc. Thesis, Jule Brendgen, The Relation between Social Interaction and Intrinsic Motivation in Reinforcement Learning, 2021
- [A2] M.Sc. Thesis, Lisa Scherf, Learning to segment human sequential behavior to detect the intention for interaction, 2021
- [A3] M.Sc. Thesis, Tümer Tosik, Reinforcement Learning and Implicit Feedback, 2021
- [A4] B.Sc. Thesis, Franziska Herbert: Using Multimodal Human Feedback for Reinforcement Learning, 2021
- [A5] B.Sc. Thesis, Marek Daniv, One Shot Graph Imitation Learning from Visual Data, 2022
- [A6] M.Sc. Thesis, Chen Xue, Task Classification and Local Manipulation Controllers, 2022
- [A7] B.Sc. Thesis, Nathalie Woortman: Comparing and Personalizing Human Following Behaviors for Mobile Ground Robots, 2022
- [A8] B.Sc. Thesis, Vilja Lott: Detecting an Intention for Interaction in a Human-Robot Environment, 2022
- [A9] M.Sc. Thesis, Mattin Sayed: Solving Guesstimation Problems: Perceived Differences between Human and AI Support, 2022
- [A10] B.Sc. Thesis, Laura Sabioncello: The Role of Trust in AI in a Collaborative Game Setting, 2022
- [A11] B.Sc. Thesis, Erkam Ilhan: Analysis of Expert Knowledge as a Basis for AI-Aided Interactive Anomaly Detection, 2022 (in Kooperation mit Porsche Motorsport)
- [A12] B.Sc. Thesis, Simon Binz: The Role of Shielded Reinforcement Learning for Human-AI Interaction in a Collaborative Task Setting, 2022

- [A13] M.Sc. Thesis, Jessica Löhr: Detection of Unexpected Human Behavior in Human-Robot Interaction in Shared Workspaces, 2022
- [A14] B.Sc. Thesis, Sergio Cabeza: Developing a Web Interface for AI-Aided Interactive Anomaly Detection in Time Series Data, 2022
- [A15] B.Sc. Thesis, Yannik Vetter: Development of an Intuitive Web Based User Interface for Robot Skill Learning, 2022
- [A16] B.Sc. Thesis, Eya Chemangui: Detecting Human Uncertainty from Multimodal Behavioral Data in a Task with Perceptual Ambiguity, 2023
- [A17] B.Sc. Thesis, Christian Maurer: Quantifying Policy Uncertainty for Interactive Reinforcement Learning with Unreliable Human Action Advice, 2023
- [A18] M.Sc. Thesis, Lisa Alina Gasche: Detecting Human Uncertainty from Multimodal Behavioral Data in a Task with Decision Uncertainty, 2023
- [A19] M.Sc. Thesis, Julien Brosseit, The Principle of Value Equivalence for Policy Gradient Search, 2023
- [A20] M.Sc. Thesis, Jascha Hellwig, Residual Reinforcement Learning with Stable Priors, 2023
- [A21] M.Sc. Thesis, Mark Baierl, Score-Based Generative Models as Trajectory Priors for Motion Planning, 2023
- [A22] B.Sc. Thesis, Jan Kegel: Solving Guesstimation Problems with a Visual Structuring Tool, 2023
- [A23] B.Sc. Thesis, Sophie Schumbert: The Presentation of Uncertainty in Human-AI Interaction, 2023
- [A24] M.Sc. Thesis, Jan Mackensen: A Human-Centered Approach for AI-Aided Anomaly Detection in Time Series, 2023
- [A25] M.Sc. Thesis, Amine Chouchane: AI-Aided Interactive Anomaly Detection in Multivariate Time Series, 2023, ongoing (in Kooperation mit Porsche Motorsport)
- [A26] M.Sc. Thesis, Phillip Wolff, Bayesian Combination of Human and Machine Predictions, 2023
- [A27] M.Sc. Thesis, Leon Keller, Context-Dependent Variable Impedance Control with Stability Guarantees, 2023
- [A28] M.Sc. Thesis, Kevin Fröhlich, Learning Action Conditions from Human Demonstrations, 2023
- [A29] M.Sc. Thesis, Niklas Kappes, Natural Gradient Optimistic Actor Critic, 2023
- [A30] B.Sc. Thesis, Isabelle Clev, Ethical Issues in Large Language Models, 2023
- [A31] B.Sc. Thesis, Katrin Scheuermann, Human-AI Interaction: A Think Aloud Study on Cooperating with Autonomous Agents, 2023
- [A32] B.Sc. Thesis, Janik Schöpfer, Situational Autonomy in Human-AI Interaction, 2023
- [A33] B.Sc. Thesis, Elifnur Doğan, An Evaluation of Name-Based Biases in Large Language Models, 2023
- [A34] M.Sc. Thesis, Li Liu, Robot Gaze for Communicating Collision Avoidance Intent in Shared Workspaces, 2023
- [A35] M.Sc. Thesis, Julian Christopher Kerl, Analyse von impliziter Gesichtsdynamik für Reinforcement Learning, 2023
- [A36] M.Sc. Thesis Eric Frodl, Enhancing Human-AI Interaction with Probabilistic Behavior Prediction for Situational Autonomy Adaptation, 2023
- [A37] M.Sc. Thesis, Pascal Herrmann, 6DCenterPose: Multi-object RGB-D 6D pose tracking with synthetic training data, 2023
- [A38] M.Sc. Thesis, Fabio Hilt, Statistical Model-Based Reinforcement Learning, 2023
- [A39] B.Sc. Thesis, Marleen Sinsel, AI-Aided Pointing Gesture Detection for Human-Robot-Interaction, 2023

-
- [A40] M.Sc. Thesis, Franziska Herbert, Learning semantic-geometric task graphs from bimanual human demonstrations, 2024
 - [A41] M.Sc. Thesis Thomas Gruczyk, Integration of User Feedback into Machine Learning Models for Classification of Multivariate Time Series, 2024 (in Cooperation with ROBUR, now SPIE Automation)
 - [A42] M.Sc. Thesis, Hannah Wieland , Situational Autonomy Adaptation for Human Robot Interaction in a Shared Workspace, 2024
 - [A43] M.Sc. Thesis, Qiao Sun, Grasp Diffusion Network, 2024
 - [A44] M.Sc. Thesis, Nick Striebel, Bimanual Imitation Learning, 2025

Dissertationen

- [T1] Susanne Trick (2024), Bayesian Fusion of Probabilistic Forecasts
- [T2] Vildan Salikutluk (2024), Human Problem-Solving with Interactive Artificial Intelligence
- [T3] Joao Carvalho (2025), Enhancing Robot Manipulation Skills through Learning
- [T4] Lisa Scherf (2025), Learning from Imperfect Human Input in Interactive Machine Learning

Open Source Code & Datasets

- [C1] IFI Dataset <https://osf.io/mvzsa/>
- [C2] Human Uncertainty Dataset <https://osf.io/48ksh/>
- [C3] Knowledge Test Confidence data set: <https://osf.io/ae25w/>
- [C4] MIA-IRL Code <https://github.com/RothkopfLab/MIA-IRL>
- [C5] Bayesian Correlated Classifier Fusion Code https://github.com/RothkopfLab/Bayesian_Correlated_Classifier_Fusion
- [C6] Motion Planning Diffusion Code: <https://github.com/jacarvalho/mpd-public>