



Intuitive Interaktion mit kooperativen Assistenzrobotern für das 3. und 4. Lebensalter

Abschließender Sachbericht

Teilprojekt der Technischen Universität Darmstadt

Berichtszeitraum: 01.07.2018-31.12.2021



TECHNISCHE
UNIVERSITÄT
DARMSTADT

Zuwendungsempfänger
Titel des Teilvorhabens

Technische Universität Darmstadt
Intentionserkennung und Interaktionslernen
in der Mensch-Roboter-Interaktion
01.07.2018 bis 31.12.2021
16SV7984

Laufzeit des Vorhabens
Förderkennzeichen

Fördergeber
Projektträger
Förderbekanntmachung

Bundesministerium für Bildung und Forschung
VDI/VDE Innovation + Technik GmbH
Roboter für Assistenzfunktionen:
Interaktionsstrategien

Autor*innen des Berichts

Dr.-Ing. Dirk Balfanz
Dr.-Ing. Dorothea Koert
Susanne Trick

Projektkonsortium des
Gesamtvorhabens

Franka Emika GmbH (Konsortialführung)
Technische Universität Darmstadt
Technische Universität München
Technische Hochschule Rosenheim
Rummelsberger Diakonie e.V. (im Unterauftrag)

Inhalt

1 Kurzdarstellung	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	3
2 Eingehende Darstellung	4
2.1 Verwendung der Zuwendung und erzielte Ergebnisse	4
2.2 Die wichtigsten Positionen des zahlenmäßigen Nachweises	14
2.3 Notwendigkeit und Angemessenheit der geleisteten Arbeit	14
2.4 Darstellung des voraussichtlichen Nutzens.....	14
2.5 Fortschritt auf dem Gebiet des Vorhabens bei anderen Stellen	15
2.6 Erfolgte oder geplante Veröffentlichung des Ergebnisses.....	15

1 Kurzdarstellung

1.1 Aufgabenstellung

KoBo34 untersuchte wie Service-Robotik im Kontext der Pflege helfen kann. Dabei wurde im Rahmen des Vorhabens auf Einsätze in Pflegeeinrichtungen fokussiert. Das Ermitteln sinnvoll durch Robotik unterstützbarer Aktivitäten und deren technische Ausgestaltung, im Spannungsfeld zwischen verfügbarer Technik und Zielgruppe, gehörten ebenso zentral zum Projektvorhaben, wie die Aufarbeitung und Berücksichtigung der Akzeptanzerfordernisse und die Evaluation der Implementierung. So stellte die Partizipation der möglichen Nutzer*innen einen sehr wichtigen Aspekt des Projektes dar. Die Anwendungen der Service Robotik, die im Projekt erarbeitet und evaluiert wurden, sind zur Laufzeit des Projektes in Bedarfsanalysen identifiziert, umgesetzt und auf Basis der Zwischenergebnisse angepasst worden. Die Forschungsschwerpunkte des Projekts waren:

- Kollisionserkennung und sichere Reaktion in der Mensch-Roboter-Interaktion
- Zweiarmige Manipulation
- Interaktionslernen mit dem Roboter
- Intentionserkennung
- Endnutzerpartizipation, Bedarfsanalyse und Evaluation im Kontext Pflege

Im Rahmen des Projektes KoBo34 war die TU Darmstadt Forschungspartner. Sie übernahm die wissenschaftliche Untersuchung in den Bereichen Interaktionslernen und Intentionserkennung. Die Aufgabenverteilung im Gesamtprojekt zeigt Abbildung 1.




Abbildung 1: Aufgabenverteilung im Gesamtprojekt

1.2 Anknüpfung an den wissenschaftlichen und technischen Stand

Früher wurden die meisten Robotersysteme darauf optimiert, gleichbleibende Aufgaben im industriellen Umfeld zu wiederholen. Aufgrund des enormen Aufwands für das Programmieren sind solche Systeme nur in der Massenproduktion wettbewerbsfähig. Um sich kurzfristig ändernden Bedingungen anzupassen, wie beim Einsatz als Serviceroboter, braucht es adaptive, lernende und auch für Laien zu „programmierende“ Robotersysteme. Zum Einlernen komplexer Bewegungsabläufe waren im Teilprojekt der TU Darmstadt u. a. folgende Ansätze ausschlaggebend und wurden weiterentwickelt: Imitation Learning beobachtet unterschiedliche Trajektorien einer demonstrierten Bewegung und versucht deren Verteilung zu reproduzieren. Komplexe Bewegungsabfolgen werden dabei aus oft verwendeten Basiskomponenten (motion primitives) zusammengesetzt. Um die Interaktion zwischen Roboter und Mensch möglichst nahtlos erfolgen zu lassen, wurde ein Verfahren gesucht, das existierende Einzelansätze zur Erkennung und Kategorisierung u. a. für menschliche Gesten, Sprache und Blickrichtung zu einer situativen Intentionserkennung integriert.

1.3 Ablauf des Vorhabens

Die Projektlaufzeit von KoBo34 betrug 42 Monate, inkl. einer 6-monatigen Verlängerung aufgrund von Einschränkungen während der COVID-19-Pandemie. Der Projektablauf teilte sich grob in 4 Phasen, jeweils abgeschlossen durch Meilensteine (MS): MS 1 (04/2019) partizipativer Entwurf der Zielszenarien und Analyse der damit verbundenen Projekt-Anforderungen, MS 2 (01/2020) die Entwicklung der benötigten Roboterfertigkeiten, MS 3 (10/2021) die Integration von Hardware und Software, die Synthese der Zielszenarien und Weiterentwicklung der Roboterfertigkeiten sowie MS 4 (Projektende) die finale Evaluation der Pilotversuche.

1.4 Wesentliche Ergebnisse

Im Rahmen des Gesamtprojektes wurden zusammen mit Vertreter*innen einer möglichen Systemnutzung vier Zielszenarien erarbeitet: „Essen servieren“, „Anbieten von Getränken und Snacks“, „Kioskeinkauf“ und „KoBo lernt“. Auf Basis eines zweiarmigen, mobilen Serviceroboters des Projektpartners Franka Emika konnten diese Szenarien durch die technischen Partner (Franka Emika, TU Darmstadt, TU München) umgesetzt und schließlich unter Mitwirkung der Rummelsberger Diakonie durch die TH Rosenheim evaluiert werden. Akzeptanzbewertungen fanden projektbegleitend statt.

Hauptergebnisse Intentionserkennung: Für die Modalitäten Gesten, Blickrichtungen, Szenenobjekte und Sprache wurde jeweils ein Klassifizierer trainiert, der verschiedene Intentionen eines Menschen erkennen kann, z. B. die Intention zur Interaktion mit dem Roboter oder den Wunsch einen bestimmten Gegenstand zu erhalten. Es wurden unterschiedliche Verfahren des Machine Learning verwendet (u. a. Gaussian Mixture Models, Support Vector Machines und Convolutional Neural Networks) und in einem zweiten Schritt zu einem multimodalen Klassifizierer verbunden. Hierzu wurde eine neue Methode zur Classifier Fusion entwickelt, die die Unsicherheit über die zu klassifizierende Intention minimiert und durch ein hierarchisches Bayesianisches Modell ergänzt, das zusätzlich die Genauigkeit der einzelnen Klassifizierer berücksichtigt. Zugleich ist die Transparenz von Unsicherheit und Genauigkeit wichtig für die Verstehbarkeit des robotischen Handelns.

Hauptergebnisse Interaktionslernen: Der Roboter muss abhängig von der Interaktion mit dem Menschen entscheiden, was er als nächstes ausführt. Als Basis einer Bibliothek solcher interaktiven Fertigkeiten (Skills), mussten wir zunächst komponierbare Basisfertigkeiten (Actions) zur Verfügung stellen, z. B. „Greifer öffnen/ schließen“ oder „eine Basisbewegung ausführen“. Das Lehren neuer Basisbewegungen ist niederschwellig ermöglicht durch Kinesthetic Teaching (Mensch bewegt Roboter), das Training zweiarmiger Bewegungen wird durch eine eigene Lösung unterstützt. Die Modellierung der Skills erfolgt durch von uns weiterentwickelte Bewegungsprimitiven (Probabilistic Interaction Movement Primitives) sowie Behavior Trees, welche die Handlungsabläufe und Interaktionen einer Skill darstellen können. Es wurde ein vereinfachtes Interface entwickelt, um es auch Laien zu ermöglichen eine neue Skill zu komponieren. Zur Erkennung von Interaktionsabsichten der Nutzer*innen wird die Intentionserkennung genutzt. Schließlich wurde auch ein Verfahren zur Modifikation gelernter Skills durch Feedback der Nutzer*innen entwickelt, welches auf den Ansätzen des Reinforcement Learning basiert. An der TU Darmstadt stand für die Entwicklung ein nicht mobiler, zweiarmiger Franka-Roboter zu Verfügung (im Weiteren „KoBo“ genannt, siehe Abbildung 2).




Abbildung 2: Entwicklungsroboter "KoBo" @ TU Darmstadt

Zusammenarbeit der TU Darmstadt mit anderen Forschungseinrichtungen: Im Projekt fand eine enge Kooperation statt mit dem FuE-Bereich von Franka Emika (Robotersteuerung), der TU München (Bewertung von Mensch-Roboter-Kontakten), sowie der TH Rosenheim (Szenariendefinition und Evaluation). Im Rahmen der Begleitforschung „GINA“ der Fördermaßnahme „Roboter für Assistenzfunktionen“ wurde über die gesamte Projektdauer ein wissenschaftlicher Austausch mit den Forschungspartnern der anderen Förderprojekte der Fördermaßnahme gepflegt und die vielfältigen Angebote der Begleitforschung aktiv genutzt und unterstützt.


2 Eingehende Darstellung

Die Arbeit in KoBo34 war entlang 6 Arbeitspaketen (APs) organisiert (siehe auch Abbildung 1). Diese waren:

- AP 1: Nutzereinbindung und Evaluation
- AP 2: Intentionserkennung und Kommunikationsdesign
- AP 3: Intelligente Interaktionsregelung
- AP 4: Fertigungs- und Interaktionslernen
- AP 5: Systemintegration und Umsetzung der Szenarien
- AP 6: Projektmanagement

Die TU Darmstadt hat hierbei, entsprechend seinen oben skizzierten wissenschaftlichen Schwerpunktthemen im Projekt, die Arbeitspakete AP 2 und AP 4 verantwortet und maßgeblich umgesetzt, aber auch in den übrigen Arbeitspaketen mitgewirkt. Nachfolgend werden zunächst detailliert die Hauptarbeiten und Ergebnisse der TU Darmstadt in den Arbeitspaketen AP 2 und AP 4 dargestellt, danach die Mitwirkungen in den verbleibenden Arbeitspaketen.

2.1 Verwendung der Zuwendung und erzielte Ergebnisse

AP 2	Intentionserkennung und Kommunikationsdesign
	Multimodale Unsicherheitsreduktion für Intentionserkennung Da Menschen üblicherweise ihre Intentionen unter Verwendung verschiedener Modalitäten wie z. B. Sprache, Gesten oder Blickrichtungen ausdrücken, wurde im Projekt KoBo34 ein System für multimodale Intentionserkennung entwickelt und auf der Robotik-Konferenz IROS (IEEE/RSJ International Conference on Intelligent Robots and Systems) präsentiert und veröffentlicht [3]. Dieses System soll es ermöglichen, die vom Menschen ausgedrückten Intentionen mit hoher Genauigkeit und geringer Unsicherheit automatisch erkennen zu können.  <i>Abbildung 3: Schematische Darstellung der multimodalen Intentionserkennung</i> <i>Für die vier Modalitäten Sprache, Gesten, Blickrichtungen und Szenenobjekte wurde jeweils ein individueller probabilistischer Basisklassifizierer gelernt. Die Ausgaben dieser Klassifizierer werden mit der Methode Independent Opinion Pool kombiniert, um die Unsicherheit über die zu klassifizierende Intention zu reduzieren.</i> Für die vier Modalitäten Gesten, Blickrichtungen, Szenenobjekte und Sprache wurde jeweils ein Klassifizierer trainiert, der neun verschiedene atomare Intentionen eines Menschen erkennen und auseinanderhalten kann. Ein Beispiel für eine solche Intention ist das Erhalten eines bestimmten Gegenstands, z. B. eines Getränks, vom Roboter. Die einzelnen Klassifizierer wurden wie folgt umgesetzt:

- Gesten des rechten Arms, die mit einem Motion Tracking System erfasst werden, können mithilfe eines Gaussian Mixture Models (GMM) einer Intention zugeordnet werden.
- Mit einem Head-Mounted Eye Tracker erfasste Blickrichtungen werden mithilfe eines Support Vector Machine (SVM) Klassifizierers als Intentionen klassifiziert.
- Anhand von Szenenobjekten, also passiven Objekten in der Nähe des Menschen, die dennoch Hinweise über eine mögliche Intention geben können, werden mit einem Support Vector Machine (SVM) Klassifizierer menschliche Intentionen erkannt.
- Basierend auf einem mittels Keywords trainierten Convolutional Neural Network (CNN) können Intentionen aus menschlicher Sprache erkannt werden.

Alle Basisklassifizierer liefern als Ergebnis einer Klassifikation eine kategoriale Wahrscheinlichkeitsverteilung über alle möglichen Intentionen zurück. Somit kann die Unsicherheit jedes Klassifizierers über die aktuelle Klassifikation quantifiziert werden. Dies ist auch ein wichtiger Ausgangspunkt der aktiven Unterstützung der Verstehbarkeit der robotischen Aktion. Die Unsicherheitswerte können genutzt werden, um das Roboterverhalten zu moderieren. Beispielsweise kann der Nutzerin/dem Nutzer so erkennbar gemacht werden, wenn dem Roboter keine klare Einordnung der zu erkennenden Intention möglich ist.

Die Fusion der Ergebnisverteilungen der vier Basisklassifizierer erfolgt mit der Methode Independent Opinion Pool. Die von den Basisklassifizierern zurückgelieferten Wahrscheinlichkeitsverteilungen werden multipliziert und renormalisiert, um in Summe wieder zu 1 zu addieren. Bei übereinstimmenden Verteilungen, d. h. Verteilungen, die dieselbe Intention vorhersagen bei ggfs. unterschiedlicher jeweiliger Unsicherheit, ist die Unsicherheit der resultierenden kombinierten Verteilung dann geringer als die der Basisklassifizierer. Der Einfluss einer Verteilung auf das kombinierte Ergebnis ist dabei von ihrer Unsicherheit abhängig: je geringer diese ist, umso stärker beeinflusst sie das Gesamtergebnis.

Ausgewertet wurde das System in einem kollaborativen Mensch-Roboter-Szenario, in dem ein Roboterarm mit sieben Freiheitsgraden einen Menschen bei der Zubereitung einer Mahlzeit unterstützt. Dies geschieht vor allem durch die Übergabe angeforderter Objekte. Die Evaluation bestätigte, dass durch die Kombination der Daten mehrerer Modalitäten mit der vorgeschlagenen Methode die Genauigkeit der Intentionserkennung gesteigert werden konnte, sowie die Unsicherheit über die jeweiligen Klassifikationen reduziert werden konnte.

Normatives Bayesianisches Modell zur Kombination mehrerer Klassifizierer

Das oben beschriebene System für multimodale Intentionserkennung kombiniert die Ausgaben verschiedener Basisklassifizierer mit der Fusionsmethode Independent Opinion Pool. Unter der Annahme, dass die Ergebnisse der einzelnen Klassifizierer statistisch unabhängig voneinander sind und die a-priori Verteilung über die möglichen Klassen gleichverteilt ist, ist die Methode Independent Opinion Pool bayes-optimal und stellt daher die mathematisch genaue Fusionsmethode dar. Jedoch ist die Unabhängigkeit der einzelnen Basisklassifizierer in der Praxis meist nicht gegeben. Aus diesem Grund wurde ein bayesianisches normatives Modell zur Kombination mehrerer Klassifizierer entwickelt, welches die Korrelationen zwischen den Basisklassifizierern explizit modelliert und für deren Fusion berücksichtigen kann.

In diesem Modell werden die Ausgabe-Verteilungen jedes Basisklassifizierers mit einer Dirichlet-Verteilung modelliert, wodurch individuelle Eigenschaften jedes Klassifizierers wie Bias, Varianz und Unsicherheit für die Fusion berücksichtigt werden können. Um zusätzlich auch Korrelationen zwischen den kategorialen Ausgabe-Verteilungen jedes Klassifizierers modellieren zu können, wurde eine Erweiterung der Standard-Dirichlet-Verteilung entwickelt, eine korrelierte Dirichlet-Verteilung. Diese neue Verteilung ermöglicht eine Modellierung von positiv korrelierten Dirichlet-verteilten Zufallsvariablen. Abgeleitet wurde die korrelierte Dirichlet-Verteilung von einer bivariaten Beta-Verteilung, die auch im Rahmen des Projekts entwickelt wurde (siehe [6]).

Evaluationen auf simulierten sowie realen Daten von korrelierten Basisklassifizierern haben ergeben, dass die aus der Kombination der Klassifizierer resultierende Unsicherheitsreduktion

unter der Nutzung des normativen Fusionsmodells umso geringer wird, je größer die Korrelation der Basisklassifizierer ist. Im Extremfall einer Korrelation von $r=1$ reduziert die Fusion die Unsicherheit dementsprechend nicht mehr. Außerdem ist das vorgeschlagene Modell zur Fusion korrelierter Klassifizierer hinsichtlich Genauigkeit und Unsicherheit ähnlichen Modellen überlegen [7].

Gestenerkennung

Zur möglichst intuitiven Interaktion zwischen Mensch und Roboter und zur Erkennung verschiedener generischer Intentionen, wie dem Beginn einer Interaktion oder einer Ablehnung oder einem Abwehren des Roboters, wurde eine Gestenerkennung entwickelt. Die zu erkennenden Gesten umfassen im Speziellen die automatische Detektion von verschiedenen Ruf-Gesten wie ein Heranwinken, ein normales Winken oder eine Ruf-Geste, wie sie Gäste in einem Restaurant häufig tätigen, um eine Servicekraft herbei zu bitten. Zusätzlich zu diesen besonderen Gesten wurden vom Konsortium anhand von Beobachtungen im Lenzheim weitere Schlüsselgesten identifiziert, die in der Interaktion mit dem Roboter besonders hilfreich sein können. Die resultierenden fünf Schlüsselgesten sind:

- Ruf-Geste: ähnlich der Geste, mit der man in einem Restaurant Bedienstete ruft
- normales Winken: um Aufmerksamkeit zu erregen oder zu grüßen
- Heranwinken
- abwehrende Stopp-Geste
- ablehnende Geste: mit beiden Händen wird vor der Brust gewunken

Für die Erkennung dieser fünf Gesten wurde auf Basis der Daten einer Tiefenkamera und eines Neuronalen Netzwerkes, das eine menschliche Silhouette in Kamerabildern erkennen kann, eine Support Vector Machine als Gestenklassifizierer trainiert [A4]. Abbildung 4 zeigt den zugehörigen Verarbeitungsablauf. Das Anlernen der Gestenerkennung wird im folgenden Abschnitt (AP 4) beschrieben. Der Gestenklassifizierer wurde in Zusammenarbeit mit Franka Emika und der TU München im Rahmen der Schlussevaluation in das Gesamtsystem integriert.




Abbildung 4: Verarbeitungs-Pipeline zur Klassifikation von Gesten

Erkennung von Zustimmung und Ablehnung

Zusätzlich zur Arbeit an der Erkennung grundlegender Intentionen aus Gesten wurde an der Erkennung von Zustimmung und Ablehnung des Menschen gearbeitet. Dafür wurde einerseits Spracherkennung eingesetzt, die vom Industriepartner Franka Emika zur Verfügung gestellt wurde. Diese Spracherkennung wurde noch erweitert, sodass sie zusätzlich zum erkannten Inhalt einen Wert ausgibt (Confidence), der die Unsicherheit der Spracherkennung spiegelt. Zusätzlich wurde ein datenbasiertes Modell zur automatischen Erkennung von Kopfgesten wie Nicken und Kopfschütteln aus Kamerabildern entwickelt. Dazu wurden Video-Daten von Personen aufgenommen, die entweder genickt, den Kopf geschüttelt, zur Seite oder gerade in die Kamera geschaut haben. Auf diesen Daten wurde ein Support Vector Machine Modell gelernt, welches in

	der Lage ist, Nicken und Kopfschütteln automatisch zu erkennen. Zudem liefert es eine Wahrscheinlichkeit, und den Confidence-Wert, der zusätzlich die Unsicherheit des Modells ausdrückt. Zur Erkennung von Ablehnung oder Zustimmung wurden die Ausgaben der Spracherkennung und der kamera-basierten Erkennung von Nicken und Kopfschütteln entsprechend ihrer Unsicherheit kombiniert. Für die Fusion der jeweiligen Wahrscheinlichkeitsverteilungen wird die Methode Independent Opinion Pool angewandt.
AP 4	Fertigkeits- und Interaktionslernen
	Fertigkeitslernen Um es Laien zu ermöglichen, komplexe Fertigkeiten (Skills) anzutrainieren, müssen von Experten sogenannte Basisfertigkeiten (Actions) zur Verfügung gestellt werden. Hierfür hat die TU Darmstadt in Kooperation mit Franka Emika folgende fünf Basisfertigkeiten integriert und auf dem KoBo-Roboter der TU Darmstadt lauffähig gemacht: • GoTo (kartesisch) / Gehe zu Objekt: Dieser Befehl bringt den Endeffector des Roboters in eine vorgegebene kartesische Position. • GoTo (Gelenkwinkel) / Gehe zu fester Position: Dieser Befehl fährt vorgegebene Gelenkwinkel an. • ProMPs / Bewegung ausführen: Dieser Befehl führt anhand von Demonstrationen gelernte Probabilistic Movement Primitives (ProMPs) aus. • Grasp / Greifen: Dieser Befehl schließt den Greifer des Roboters bis eine vorgegebene Kraft erreicht wird und eignet sich daher zum Greifen unregelmäßiger Objekte. • Move Gripper / Greifer öffnen: Dieser Befehl fährt eine vorgegebene Sollposition an. Für den Laien wird eine vereinfachte Action zur Verfügung gestellt, die den Greifer vollständig öffnet. Die Skills werden ähnlich wie das in AP 2 entwickelte Intention for Interaction-Modul als Behavior Tree repräsentiert, wobei die Blattknoten durch die Actions gegeben sind. Dies ermöglicht eine einfache Integration und Kombination der getrennt entwickelten Module. Um es Laien zu ermöglichen, solche Behavior Trees zu erstellen, wurde ein Benutzerinterface erstellt. Hierbei wurden nur Skills betrachtet, die sich aus der direkten Aneinanderreihung einzelner Actions ergeben. Mithilfe des Benutzerinterfaces können nacheinander weitere Actions zu einem Skill hinzugefügt werden bis diese vollständig ist und gespeichert werden kann. Nachdem eine Action hinzugefügt wurde, müssen noch die gewünschten Parameter festgelegt werden (z. B. die Zielposition für eine GoTo-Action). Hierfür wird der Roboter automatisch in einen entsprechenden Betriebsmodus gesetzt. Dadurch können die Benutzer*innen z. B. eine ProMP spezifizieren durch Greifen des Roboterarms und viermaliges Führen der gewünschten Bewegung. Bei einer GoTo-Action wird nur eine einzelne Bewegung benötigt, deren Endposition relevant ist. Da die Actions auf verschiedene Positionen im Raum generalisierbar sein sollen, können sie relativ zu einer Objektposition aufgezeichnet werden. Das entsprechende Objekt, welches das Bezugssystem bildet, wird im Benutzerinterface ausgewählt. Generell sollen für Bewegungen zu festen Raumpositionen immer




Abbildung 5:
Skill-Learning Benutzer-Interface

Gelenkwinkel GoTos und für Bewegungen zu Objekten immer kartesische GoTos verwendet werden.

Um das Benutzerinterface zu evaluieren haben wir eine Studie durchgeführt. Zehn Proband*innen, die keine Erfahrung mit Robotern hatten, wurden gebeten, dem KoBo-Roboter der TU Darmstadt zu zeigen, wie eine Packung Kekse auf ein Tablett gelegt werden kann. Hierbei sollte KoBo die Packung zuerst mit dem linken Greifer greifen und hochheben und anschließend an den rechten Greifer übergeben. Mit diesem sollte die Packung auf dem Tablett platziert werden. Zum Schluss sollten beide Greifer das Tablett greifen. Dieses Experiment wurde in zwei Varianten durchgeführt: Bei der ersten Variante sollten GoTo-Befehle zum Lehren der Bewegungen genutzt werden während bei der zweiten Variante ProMPs gelehrt werden sollten. Im Experiment konnten die Nutzer*innen die gewünschten Aktionen häufig erfolgreich lehren, allerdings kam es insbesondere beim Lehren der GoTo-Actions zu Fehlern, z. B. indem ein falsches Bezugssystem gewählt wurde, wodurch die Action nicht generalisierte. Wurden ProMPs benutzt, traten Fehler lediglich während des Handwechsels auf, welches dennoch in der Mehrzahl der Fälle erfolgreich war. Bei einer anschließenden Befragung befand jeweils eine knappe Mehrheit der Proband*innen ProMPs für intuitiver und nützlicher, die GoTo-Actions allerdings für einfacher. Perspektivisch können diese Indikationen weiter systematisiert werden, um (erhofft) klare Gestaltungsvorgaben abzuleiten.

Eine gesonderte Herausforderung beim Lehren von Skills stellen koordinierte Bewegungen beider Roboterarme dar, da es dem Nutzer in der Regel nicht möglich ist, beide Armbewegungen gleichzeitig zu lehren. Hierfür haben wir zwei Ansätze getestet: Coordinated ProMPs und Simple ProMPs. Bei Coordinated ProMPs werden die Bewegungen sequentiell ausgeführt, allerdings wird beim Anlernen des zweiten Arms, die zuvor gelehrt Bewegung des ersten Arms ausgeführt. Dies ermöglicht das Training einer synchronisierten Bewegung beider Arme. Dieser Ansatz funktioniert jedoch nicht, wenn die Bewegungen nicht unabhängig voneinander ausgeführt werden können, z. B. beim Anheben eines Tablett. Hierfür können Simple ProMPs genutzt werden. Bei Simple ProMPs gehen wir davon aus, dass beide Arme mittels Objekten miteinander verbunden sind. Die ProMPs können daher gleichzeitig für beide Arme gelehrt werden.



Abbildung 6: Lehren von 2-armigen Skills

Beide Ansätze wurden in einem dritten Experiment mit denselben zehn Probanden evaluiert. Die Aufgabe war hierbei ähnlich wie bei den ersten beiden Experimenten, allerdings musste das Tablett diesmal gleichzeitig mit beiden Armen gegriffen werden (mittels einer Coordinated ProMP) und zum Schluss musste das Tablett beidarmig angehoben werden (mittels einer Simple ProMP). Unsere Studie bestätigte, dass es mit beiden Verfahren auch für Laien möglich ist beidarmige Skills zu lehren. Allerdings kam es z. B. gerade dann zu Fehlern, wenn bei den verschiedenen Demonstrationen derselben Bewegung der Greifer manchmal im Uhrzeigersinn und manchmal gegen den Uhrzeigersinn gedreht wurde. Obwohl solche unterschiedlichen Bewegungen für die Nutzer*innen wie die gleiche Bewegung wirken können, müssen sie vom Roboter dennoch unterschieden werden. Wir möchten daher in Zukunft solche Fehler automatisch erkennen, sodass KoBo darauf hinweisen kann. Die Nutzeroberfläche wurde weiterentwickelt und bietet jetzt eine HTML-basierte Schnittstelle, die Kompatibilität auch auf anderen Endgeräten neben PCs, wie z. B. Tablets gewährleistet.

Kooperatives Lernen interaktiver Handlungsstrategien

Eine wesentliche Anforderung in KoBo34 besteht in der Mensch-Maschine-Interaktion. So muss KoBo zum einen abhängig von Mensch-Maschine-Interaktionen entscheiden, welchen Skill er als nächstes ausführt und zum anderen bestehen viele Skills darin mit Menschen auf eine gewünschte Art zu interagieren. Während im Fertiglern nur nicht-interaktive Fertigkeiten betrachtet wurden, wird hier untersucht wie solche interaktiven Skills gelehrt werden können.

Beispiel: KoBo soll erkennen, wenn eine Person etwas trinken möchte und daraufhin ein Getränk reichen. Als Erstes muss KoBo erkennen, dass ein Mensch mit ihm interagieren möchte. Hierfür haben wir das in AP 2 entwickelte Modell zur Gestenerkennung genutzt, welches auch in Form eines Behavior Trees vorliegt. Dieses Modul lässt sich daher leicht als Sub-Skill in unserer Skill-Library integrieren, welche auch auf Behavior Trees aufbaut. Wie unter AP 2 beschrieben, erkennt KoBo anhand von Gesten dann eine Intention des Menschen und startet nach einer Nachfrage und einer daraufhin erfolgten Zustimmung des Menschen die tatsächliche Interaktion. Beispielsweise wird eine Flasche gegriffen und dem Menschen gereicht (siehe Abbildung 7). Zur Umsetzung derartiger Szenarien wurde ein System zum Lernen von interaktiven Handlungsstrategien entwickelt.




Abbildung 7: Interaktives Anreichen

Das System baut auf dem Framework von Probabilistic Interaction Movement Primitives (Interaction ProMPs) auf und integriert das Intentionserkennungsmodell sowie einen neuen Ansatz für eine erweiterbare Fertigkeitsbibliothek. Dazu wurden probabilistische Modelle zur Generierung von interaktiven Trajektorien erarbeitet. Es wurden mit Hilfe eines Motion Capturing Systems Armbewegungstrajektorien eines Menschen sowie Robotertrajektorien zusammen aufgezeichnet. Der Roboter wurde hierbei im Kinesthetic Teaching-Modus bewegt. Aus diesen gekoppelten Mensch-Roboter Trajektorien wurden Interaction ProMPs gelernt. Um die Erweiterbarkeit der Fertigkeitsbibliothek des Roboters zu ermöglichen, wurde ein neuer Ansatz entwickelt, der nicht wie bestehende Ansätze für Interaction Primitives davon ausgeht, dass alle Trainingsdaten vorhanden sind, sondern auch neue Trainingsbeispiele in die gelernte Fertigkeitsbibliothek integrieren und diese dadurch gegebenenfalls erweitern kann. Dazu nutzen wir die Methode des incremental Gaussian Mixture Model (iGMM). Mit einem Mixture of Experts-Ansatz werden die gelernten Bewegungsprimitive mit dem Intentionserkennungsmodell integriert. Die gelernte Fertigkeitsbibliothek ist erweiterbar angelegt und es ist auch möglich, gelernte Fähigkeiten durch neue Demonstrationen zu modifizieren.

Der beschriebene Ansatz wurde in einem Beispielszenario auf dem Entwicklungsroboter der TU Darmstadt (siehe Abbildung 2) implementiert und evaluiert. Die Ergebnisse wurden auf der International Conference on Humanoid Robots (HUMANOIDS) [1] und im International Journal for Humanoid Robotics [5] präsentiert bzw. veröffentlicht.

Interaktive Gestenerkennung:

Für das Intention for Interaction-Modul wurde an der TU Darmstadt ein Skeleton-Tracker entwickelt. Dieser verwendet die Software tf-pose um mittels RGB-D-Bildern (Bilder mit Tiefeninformation) die Gelenkwinkel des menschlichen Skeletts abzuleiten. Da es hierbei zu Falscherkennungen und Messfehlern kommen kann, verwenden wir einen Kalman-Filter, um konsistente, kontinuierliche Bewegungen zu erhalten. Außerdem entfernen wir einige Störeinflüsse, indem Pixel ab einer bestimmten Entfernung ignoriert werden. Die extrahierten Gelenkbewegungen werden anschließend mithilfe der Tiefeninformation der Kamera in den 3D-Raum projiziert.

Basierend auf den definierten Interaktionsgesten (siehe AP 2) wurde ein System zum interaktiven Lernen von Gesten entwickelt. Dieses System lernt auf Basis von Trainingsgesten in Form kurzer

Videsequenzen die vordefinierten Gesten voneinander zu unterscheiden. Hierbei wird zunächst ein tiefes Neuronales Netz genutzt, das aus den Kameradaten Positionsdaten des menschlichen Skeletts abschätzt (Skeleton Tracking). Danach werden mittels solcher Skelettdaten unter Verwendung einer Support Vector Machine die unterschiedlichen Gesten klassifiziert (Abbildung 4). Das Lernsystem ist dabei interaktiv gestaltet und bietet zwei Interaktionsmöglichkeiten. Nicht-Experten-Nutzer*innen haben die Möglichkeit eigene Trainingsdaten hinzuzufügen, was ein besseres Anpassen der Gestenerkennung auf einzelne Personen oder Situationen ermöglicht. Außerdem können Experten-Nutzer, iterativ Klassifizierungsparameter und Grenzwerte über eine graphische Nutzerschnittstelle anpassen (Abbildung 8).




Abbildung 8: Nutzungsoberfläche des interaktiven Lernsystems zur Gestenerkennung

Interaktiver Lernerfolg und Interaktionsmaß

Auch wenn KoBo selbstständig neue Fertigkeiten lernt, soll es dem Nutzer möglich sein den Roboter dabei zu unterstützen. Hierfür haben wir ein Konzept entwickelt, das es KoBo ermöglicht, verschiedene Arten von Feedback während des Lernvorgangs zu nutzen. Unser Konzept basiert auf dem Prinzip des Verstärkenden Lernens (Reinforcement Learning) welches sehr breite Anwendung in der Robotik findet. Weit weniger klar ist, welche Art des Feedbacks die Nutzer*innen bevorzugen und wie hilfreich die verschiedenen Arten von Feedback für den Lernprozess des Roboters sind. Daher erlaubt es unser Konzept verschiedene Arten von Feedback zu berücksichtigen, um sie dann mithilfe von Nutzungsstudien gezielt zu evaluieren. Konkret haben wir folgende Feedback-Kanäle (Input-Channels) betrachtet:

- Zustandsänderung: Hier setzen die Nutzer*innen den Roboter manuell in einen gewünschten Zustand. Indem der Roboter mit einer bestimmten Situation konfrontiert wird, kann er gezielt lernen diese besser zu meistern. Insbesondere erlaubt es die Zustandsänderung die Lernaufgabe des Roboters zu erleichtern, z. B. wenn der Startzustand dem Zielzustand ähnelt. Die Lehrmethode, welche die Schwierigkeit der Aufgabe sukzessive erhöht ist als Curriculum Learning bekannt und insbesondere auch in der Robotik hilfreich, um die Lerneffizienz zu steigern.

- Action Advice: Hier präsentiert der Roboter dem Nutzer seine nächste geplante Action bevor er diese ausführt. Der Nutzer hat dadurch die Gelegenheit diese bei Bedarf durch eine vom Nutzer bevorzugte Action zu ersetzen. Hierdurch können ungewünschte Actions verhindert werden sowie aus der Sicht der Nutzer*innen sinnvolle Actions untersucht werden. Es kann auch eine Action verhindert werden ohne eine andere vorzuschlagen. In diesem Fall muss dies der Roboter tun.
- Action Feedback: Nachdem eine Action ausgeführt wurde, kann diese von den Nutzer*innen als gut, neutral oder schlecht bewertet werden. Falls kein Feedback erfolgt, wird dies als „neutral“ gewertet. Im Vergleich zum Action Advice, müssen Nutzer*innen hier nicht obligatorisch Actions vorschlagen.
- Zwischen-Belohnung: Hier können Nutzer*innen im Vorfeld Zustände festlegen für deren Erreichen der Roboter eine zusätzliche „Belohnung“ erhält. Dieser Input-Channel ermöglicht es Teilziele festzulegen.

Um den Nutzen der verschiedenen Input-Channel zu evaluieren wurde ein bekannter Reinforcement Learning Ansatz namens Q-Learning erweitert, um das Feedback während des Lernvorgangs zu nutzen. Die Input-Channel „Action Advice“ und „Action Feedback“ haben wir bereits in einer Nutzerstudie mit 20 unerfahrenen Nutzer*innen evaluiert. In Experiment haben wir zwei Szenarien betrachtet.

Im ersten Szenario musste der Roboter lernen, Zitronensaft und Zucker in eine Schüssel zu schütten. In diesem Szenario wurden zwei verschiedene Experimente durchgeführt. Im ersten Experiment konnten Nutzer*innen Actions zurückweisen und Actions vorschlagen. Im zweiten Experiment können Actions zurückgewiesen oder durch „Action Feedback“ bewertet werden. Im ersten Experiment haben die Nutzer*innen hauptsächlich von der Möglichkeit Gebrauch gemacht, dem Roboter gute Actions vorzuschlagen. Im zweiten Experiment wurden häufiger Actions zurückgewiesen und die nicht zurückgewiesenen Actions positiv bewertet. In beiden Experimenten war das Lernen deutlich schneller als ohne Nutzung von Feedback. Der Nutzen des Feedbacks war dabei im ersten Experiment etwas größer.



Abbildung 9:
Experiment zu Feedback im Lernvorgang

Im zweiten Szenario wurde untersucht wie sich falsches Feedback auf das Lernverhalten des Roboters auswirkt. In diesem Szenario mussten Objekte (blau oder orange) anhand ihres Gewichts in zwei Kisten sortiert werden. Den Proband*innen wurde das Sortierkriterium allerdings nicht mitgeteilt und sie sind daher anfangs fälschlich davon ausgegangen, dass nach Farbe sortiert würde. Jedes Mal nachdem alle Objekte verteilt worden waren, bekamen die Versuchspersonen und der Roboter eine Belohnung (Reward), wodurch auch die jeweilige Versuchsperson das korrekte Kriterium lernen kann. Da in diesem Szenario vermehrt falsches Feedback auftritt, ist es hilfreich, wenn der Roboter aktiv einschätzt ob er Feedback benötigt. Anhand eines solchen Interaktionsmaßes kann sich der Roboter auch entscheiden das Feedback zu ignorieren. Für erste Untersuchungen in diese Richtung haben wir einen einfachen Self-Confidence-Wert betrachtet, der während des Lernvorgangs linear ansteigt. Je größer dieser Wert ist, desto wahrscheinlicher wird es, dass der Roboter Feedback der Versuchspersonen ignoriert. Im zweiten Szenario haben wir die gleichen zwei Experimente durchgeführt wie im ersten Szenario. Beide Input-Channel steigerten die Lerneffizienz im Vergleich zum Lernen ohne Feedback. Allerdings fiel der Vorteil aufgrund des falschen Feedbacks geringer aus. Den Einfluss des Self-Confidence-Wertes haben wir in einem Experiment mit simulierten Feedback der Nutzer*innen untersucht. Hier konnten wir zeigen, dass bei einem hohen Anteil von falschem Feedback das Lernen ohne Self-Confidence fehlschlagen kann. Wurde der Self-Confidence-Wert berücksichtigt war das Lernen auch bei hohem Anteil falschen Feedbacks erfolgreich.

	Partialintegration und Validierung Alle entwickelten Module wurden auf KoBo, dem Entwicklungsroboter an der TU Darmstadt integriert, welcher auch für die Nutzungsstudien verwendet wurde. Unser ProMP Motion Generator wurde mit dem Motion Generator von Franka Emika integriert, unsere Skill-Learning-Library mit den Behavior-Trees. Das von uns erweiterte Skeleton-Tracking wurde mit den Projektpartnern geteilt. Die gelernte Gestenerkennung wurde für die Abschlussevaluation auf dem Zielroboter integriert und in den Abschlusszenarien mit evaluiert. Das Fertigkeitlernen nutzt außerdem das von Franka Emika entwickelte Spracherkennungsmodul. Schließlich wurde unsere Gestenerkennung erweitert um eine von der TU München entwickelte Touch-Gesten-Erkennung, die es ermöglicht leichte Berührungen zu erkennen.
AP 1	Nutzereinbindung und Evaluation
	Die TU Darmstadt hat im Projektverlauf die Arbeiten des AP 1 unterstützt. In der ersten Phase des Projektes waren dies insbesondere Beiträge zur Definition geeigneter Szenarien im Rahmen von Bedarfs- und Machbarkeitsanalysen. Mitarbeiterinnen der TU Darmstadt haben dazu auch an Kurzhospitationen des im Alten- und Pflegeheim Lenzheim (Garmisch) teilgenommen. Dort konnten sie das reale Setting der angedachten technischen Projektinnovationen selbst erfahren, d. h. die Pflegesituation, die Organisation aber auch die Bewohner*innen und Bediensteten des Lenzheim. Basierend auf den Ergebnissen der Hospitation hat die TU Darmstadt die Bedarfsanalyse und die Definition der Evaluationsszenarien mit technischer Expertise unterstützt. Darüber hinaus konnte die TU Darmstadt zu Beginn 2020 (vor den Auswirkungen der Corona-Pandemie) zur Vorbereitung der Evaluation von Konzept- und Entwicklungsphase erste Tests und Beobachtungen im Lenzheim durchführen. Diese dienten der Vor-Ort-Begutachtung von generellen Möglichkeiten der Verprobung und der Datenaufnahme von menschlichen Verhaltensweisen zum Abgleich mit den konzeptuell vorgesehenen Interaktionsmustern zwischen Roboter und Mensch und den technischen Möglichkeiten. Sie arbeiteten auch AP 2 zu. Im weiteren Projektverlauf waren durch die pandemie-bedingten Einschränkungen keine weiteren Evaluationen für die TU Darmstadt im Lenzheim mehr möglich. An der TU Darmstadt konnten in dieser Phase jedoch zumindest Tests im Laborrahmen unter der Einhaltung von strengen Hygienemaßnahmen stattfinden. Diese Experimente und Tests konnten die geplante Nutzereinbindung und Evaluation im Sinne des Gesamtprojektes nur bedingt ersetzen, waren aber hinreichend um die wissenschaftlichen Arbeiten der TU Darmstadt in den Arbeitspaketen AP 2 und AP 4 zu unterstützen. In der Endphase des Projektes unterstütze die TU Darmstadt die Akzeptanzuntersuchungen sowie die video-basierte Analyse der finalen Projektevaluation durch Einbringen der kognitions-wissenschaftlichen Perspektive.
AP 3	Intelligente Interaktionsregelung
	Im Projektverlauf wurden die Konzepte zur intelligenten Interaktionsregelung der TU München nachvollzogen und im Sinne ihrer Auswirkungen auf die Interaktionskonzepte der Arbeitspakete AP 2 und AP 4 begleitend bewertet. Hier sind beispielhaft Interaktionsparadigmen zu nennen, die den Roboter nach Auftreten und Erkennen einer ungewollten oder gewollt-aufhaltenden Kollision Mensch-Maschine wieder seine Tätigkeit aufnehmen lassen (z. B. Tipp-Gesten). Die betreffenden Software Module der TU München wurden auf dem Roboter der TU Darmstadt integriert und für das interaktive Fertigkeitlernen genutzt.

AP 5	Technische Systemintegration und Test
	Die TU Darmstadt war durchgängig an der Integration und Tests des Gesamtsystems bzw. seiner Zwischenstufen und Komponenten beteiligt, zunächst im Rahmen technischer Integrationsmeetings mit den Projektpartnern. Aufgrund der Corona-Pandemie waren jedoch von ca. März 2020 bis Mitte 2021 technisch-integrative Arbeiten an der Zielhardware vor Ort (d. h. in München) nicht möglich. Daher wurde auch beschlossen, das TU Darmstadt Szenario „KoBo lernt“ separat in Darmstadt zu evaluieren, was aufgrund des hier vorhandenen KoBo Entwicklungsroboters möglich war. Insgesamt hat die TU Darmstadt u. a. die Entwicklung von Grundfertigkeiten unterstützt, hier wurde besonders an der Entwicklung eines Motion Generators mitgewirkt, ein kamerabasiertes Skeleton Tracking entwickelt (siehe auch AP4) und das vom Partner Franka Emika entwickelte Sprachmodul iterativ getestet. In der zweiten Jahreshälfte 2021 waren schließlich physische Integrationstreffen (dann in Garmisch) wieder möglich und dienten der Vorbereitung der finalen Evaluation. So konnte abschließend auch die inzwischen durch die TU Darmstadt entwickelte Gestenerkennung noch ins Zielsystem integriert werden.
AP 6	Projektmanagement
	Die TU Darmstadt war aktiv beteiligt an allen Projekt-übergreifenden Aktivitäten von KoBo34, den strategischen, vom BMBF organisierten Vernetzungstreffen des Förderprogramms, sowie an Veranstaltungen und Aktivitäten der Begleitforschung GINA der Förderlinie RA2 (Roboter für Assistenzfunktionen). Nachfolgend eine Liste der Tätigkeiten der TU Darmstadt im Rahmen des AP 6 und seiner Unterthemen „Organisation von Konsortialtreffen“ und „Einbindung des Begleitprojekts“ bzw. Vernetzungsveranstaltungen des Fördergebers: • Projekt-Kickoff am 16./17. Juli 2018 in Rosenheim, Beteiligung • KoBo34-Lenkungstreffen am 14./15. November 2018 in München, Beteiligung • Beteiligung am Start der Begleitforschung GINA, dem BMBF-Vernetzungstreffen „Roboter für Assistenzfunktionen: Interaktionsstrategien & Zukunftsforum Assistenzrobotik“ am 28./29. November 2018 in Stuttgart, KoBo34 Projektvorstellung • Organisation und Ausrichtung des 1. KoBo34-Meilensteintreffens 02./03. April 2019 in Darmstadt und Unterstützung der GINA-Projektbefragungen • Beteiligung am GINA-Workshop „Intentions- und Kontexterkenkung in der multimodalen Mensch-Roboter-Interaktion“ 15./16. Juli 2019 in Oberpfaffenhofen • Beteiligung am Status- und Vernetzungstreffen der Bekanntmachungen ARA1 und RA2 von BMBF und GINA am 28./29. November 2019 in Berlin • KoBo34-Lenkungstreffen am 17. Oktober in München, Beteiligung • 2. KoBo34-Meilensteintreffen am 23./24. Januar 2020 in München, Beteiligung • KoBo34-Lenkungstreffen (virtuell) am 19. Juni 2020, Beteiligung • Beteiligung an der Digitalen GINA Arbeitskonferenz am 22./23. September 2020 • Beteiligung an der (virtuellen) Abschluss- und Vernetzungsveranstaltung der BMBF-Fördermaßnahmen Roboter für Assistenzfunktion, 05./06. Oktober 2020 • KoBo34-Lenkungstreffen (virtuell) am 14.07.2021, Beteiligung • Abschlussveranstaltung (virtuell) der ersten Phase der BMBF-Fördermaßnahme „Roboter für Assistenzfunktionen: Interaktion in der Praxis (RA3) am 23. August 2021, Teilnahme • 3. KoBo34-Meilensteintreffen (hybrid) am 11.10.2021, Beteiligung • 4. KoBo34-Meilensteintreffen (hybrid) am 29.03.2022, Beteiligung

2.2 Die wichtigsten Positionen des zahlenmäßigen Nachweises

Das Budget des Teilprojekts deckt sich zum allergrößten Anteil mit den Personalkosten der Projektmitarbeitenden. Von den zu Projektende nachgewiesenen Kosten entfielen 84% auf wissenschaftliche Mitarbeitende, 6% auf wissenschaftliche Hilfskräfte. 9% entfielen zudem auf Investitionskosten vorwiegend in Form des im Projekt eingesetzten Entwicklungsroboters, sowie auch eines für die Humanexperimente verwendeten Eye Trackers. Aufgrund der Corona-Pandemie konnte ein Großteil der geplanten Reisen nicht stattfinden, weshalb bei Projektende entsprechend nur 2% des eingesetzten Budgets auf Reisen entfielen. Frei gewordene Mittel wurden für das Projektpersonal eingesetzt und haben u. a. die 6-monatige kostenneutrale Verlängerung der Laufzeit des Teilprojektes (bei allerdings deutlich verringertem Personaleinwand) unterstützt. Die Verwendung der Fördermittel ist durch die bearbeiteten Projektthemen und die erzielten Ergebnisse dargelegt.

2.3 Notwendigkeit und Angemessenheit der geleisteten Arbeit

Perspektiven der Anwendbarkeit und Verwertbarkeit der in KoBo34 angestrebten Umsetzung eines Service-Roboters im Pflegeumfeld, wurden wesentlich mitbestimmt durch ein Interaktionsdesign bzw. der entsprechenden Verhaltenssteuerung des Roboters, die an den potenziellen Nutzer*innen orientiert waren. In diesem Bereich gab es zu Projektstart keine „Standardlösungen“, viele Forschungsfragen waren für einen geeigneten Ansatz noch zu klären. Diese hätten jedoch nur bruchstückhaft vom Unternehmenspartner allein in Angriff genommen werden können. Ein Verbundansatz wie in KoBo34 vom BMBF gefördert, war dazu der sinnvolle und notwendige Zugang. Während Franka Emika jenseits der Projektförderung das Risiko der Hardwareentwicklung übernommen hat, konnten die wissenschaftlichen Risiken durch den Einbezug der Forschungspartner breiter verteilt und abgesichert werden.

Im Rahmen des Teilvorhabens der TU Darmstadt hat die Projektförderung erlaubt, eine frühe und durchgängige Einbindung potenzieller Nutzer*innen eines solchen Systems zu unterstützen, ohne zugleich den wissenschaftlichen Suchraum für Lösungen zu Projektbeginn zu stark einzuschränken. Die erarbeiteten und hier skizzierten Lösungsansätze haben explorative und interdisziplinäre Forschungsarbeit erfordert. Seitens der TU Darmstadt waren hierzu durchgängig Expertise aus den Bereichen der Robotik, des maschinellen Lernens und der Cognitive Science im Projekt engagiert. Den zu Projektbeginn methodisch und prinzipiell unsicheren (wissenschaftlichen) Endergebnissen standen damit die Chancen auf wissenschaftlich fundiert abgeglichenen, sowie in das Gesamtkonzept von KoBo34 integrierte Lösungsansätze gegenüber und rechtfertigen die risikoorientierte öffentliche Forschungsförderung. Der explorative Gesamtansatz zwischen enger Orientierung am gewählten Einsatzfeld und dennoch notwendiger Grundlagenforschung, begründet dabei zugleich die dargestellten Arbeitsaufwände als notwendig im Sinne der Zielerreichung.

2.4 Darstellung des voraussichtlichen Nutzens

Die Arbeiten der TU Darmstadt im Rahmen des KoBo34 Verbundprojektes beruhten auf einigen wesentlichen motivierenden Grundannahmen. Zu diesen gehörten vor allem die Grundbedingung der gegenseitigen Verstehbarkeit des jeweiligen Handelns als Basis für eine erfolgreiche Mensch-Roboter-Interaktion und die Notwendigkeit von robotischen Lernmechanismen, die auch von Laien genutzt werden können. Aufgrund der Einbindung der Rummelsberger Diakonie und des Pflegeheims Lenzheim konnten im Projektverlauf diese zentralen Grundannahmen im konkreten Anwendungsbereich mittelbar überprüft und bestätigt werden. In diesem Zusammenhang waren zudem die von verschiedenen Projektpartnern (so auch der TU Darmstadt) durchgeführten Hospitationen im Lenzheim von kaum zu überschätzendem Wert, da hierdurch eine Sensibilisierung aller Projektbeteiligter für die Erwartungen von Bewohner*innen und Pflegekräften an Assistenzroboter geschaffen wurde.

In den abschließenden Evaluationen hat sich bestätigt, dass der gegenseitigen Verstehbarkeit eine herausgehobene Rolle zukommt. Die im Rahmen der Intentionserkennung erarbeiteten Ansätze und Lösungen leisten hierzu einen doppelten Beitrag. Sie erhöhen die Verstehbarkeit des menschlichen Handelns für den Roboter und zugleich durch die Erhöhung der Transparenz über Unsicherheit und Genauigkeit dieser Schlussfolgerungen potenziell auch die Verstehbarkeit der Reaktionen des Roboters für den Menschen. Diese Ergebnisse sind dabei nicht auf den konkreten Anwendungsfall beschränkt, sondern können zukünftig als Basis in weiteren Projekten verwendet und weiterentwickelt werden. Die Gestenerkennung (AP 2) und das bayesianische Modell zur Kombination mehrerer Klassifizierer (AP 2) generalisieren gut in der großen Klasse

der möglichen Anwendungen der Assistenzrobotik im nicht-industriellen Umfeld. Anschließende Forschungsfragen können u. a. die Nutzung von Theory-of-Mind Ansätzen höher Ordnung adressieren (z. B.: kann der Roboter erschließen, wie der Mensch das Handeln des Roboters einschätzt?).

In den Nutzungsstudien der TU Darmstadt zum kooperativen Fertiglern konnte schließlich festgestellt werden, dass das entwickelte System, wie erhofft, auch Anwender*innen ohne Robotik-Expertise ermöglicht Robotern neue Fertigkeiten beizubringen. Es wurden hierbei auch die Potenziale der weiteren Verbesserung für zukünftige Anwendungen herausgearbeitet: u. a. die deutlichere Kommunikation des Lernzustandes des Roboters und eine intuitivere Struktur in der Interface Gestaltung. Die gewonnenen Erkenntnisse können dabei helfen zukünftige Assistenzroboter zu entwickeln, die sich noch flexibler an neue Anwendungen anpassen lassen, Endanwender stärker einbinden und eine Individualisierung von Aufgabenabläufen ermöglichen.

2.5 Fortschritt auf dem Gebiet des Vorhabens bei anderen Stellen

Im Rahmen des wissenschaftlichen Projektvorgehens wurden generell internationale Forschungsansätze und Forschungsergebnisse, welche die Themengebiete der TU Darmstadt in KoBo34 betrafen, verfolgt und in unserer Arbeit und den wissenschaftlichen Publikationen berücksichtigt. Die Referenzen in den unter Abschnitt 2.6 aufgeführten Veröffentlichungen und Arbeiten geben daher jeweils auch ein Bild der Forschungs- und Entwicklungs-Arbeiten Dritter, welche für unsere Arbeit wichtig waren.

2.6 Erfolgte oder geplante Veröffentlichung des Ergebnisses

Die wissenschaftlich-technischen Kernergebnisse des Teilvorhabens „Intentionserkennung und Interaktionslernen in der Mensch-Roboter-Interaktion“ sind zum einen während des Projektes durch Konferenz- und Journalbeiträge in den wissenschaftlichen Diskurs eingebracht und veröffentlicht worden [1, 3, 4, 5], zum anderen aber auch in populären Darstellungen [2], Presseberichten [R1, R2, R3] und im politischen Diskurs [R4] der nicht-wissenschaftlichen Öffentlichkeit näher gebracht worden. Darüber hinaus wurde das Teilvorhaben durch eine Reihe von Abschlussarbeiten unterstützt (eine Bachelor-, drei Master-Arbeiten, sowie eine Promotion), die ebenfalls im wissenschaftlichen Diskurs zugänglich sind [A1, A2, A3, A4, A5]. Im Projektnachgang stehen weitere wissenschaftliche Veröffentlichungen aus, u. a. auf Basis der Preprint-Veröffentlichungen [6, 7].

Konferenz- und Journalbeiträge, Zeitschriften

- [1] Koert, D.; Trick, S.; Ewerton, M.; Lutter, M.; Peters, J. (2018): Online Learning of an Open-Ended Skill Library for Collaborative Tasks. Proceedings of the IEEE-RAS 18th International Conference on Humanoid Robots (HUMANOIDS), November 2018, Beijing, China.
- [2] Balfanz, D. (2018). „KoBo lernt helfen. Forscher entwickeln Roboter, der ältere Menschen im Alltag unterstützt.“, hoch3, Technische Universität Darmstadt, Dezember 2018.
- [3] Trick, S.; Koert, D.; Peters, J.; Rothkopf, C. (2019). Multimodal Uncertainty Reduction for Intention Recognition in Human-Robot Interaction, Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), November 2019, Macao, China.
- [4] Koert, D.; Pajarinen, J.; Schotschneider, A.; Trick, S.; Rothkopf, C.; Peters, J. (2019). Learning Intention Aware Online Adaptation of Movement Primitives, IEEE Robotics and Automation Letters (RA-L), with presentation at the IEEE International Conference on Intelligent Robots and Systems (IROS), November 2019, Macao, China.
- [5] Koert, D.; Trick, S.; Ewerton, M.; Lutter, M.; Peters, J. (2020). Incremental Learning of an Open-Ended Collaborative Skill Library, International Journal of Humanoid Robotics Vol. 17, No. 1 (2020) 2050001 (23 pages).

Preprint-Veröffentlichungen

- [6] Trick, S.; Jäkel, F.; Rothkopf, C. A. (2021). A Bivariate Beta Distribution with Arbitrary Beta Marginals and its Generalization to a Correlated Dirichlet Distribution. arXiv preprint arXiv:2104.08069.
- [7] Trick, S.; Rothkopf, C. A. (2021). Bayesian Classifier Fusion with an Explicit Model of Correlation. arXiv preprint arXiv:2106.01770.

Abschlußarbeiten

- [A1] Trick, S. (2018): Multimodal Uncertainty Reduction for Intention Recognition in a Human-Robot Environment. Master's Thesis, Advisors: C. A. Rothkopf, J. Peters, D. Koert. Technische Universität Darmstadt, 2018.
- [A2] Knaust, M. (2019): Intuitive Imitation Learning for one-handed and bimanual tasks using ProMPs. Master's Thesis, Advisors: J. Adamy, J. Peters, D. Koert. Technische Universität Darmstadt, 2019.
- [A3] Koert, D. (2020): Interactive Machine Learning for Assistive Robots. Doctoral Thesis, Advisors: J. Peters, H. B. Amor. Technische Universität Darmstadt, 2020
- [A4] Schramm, M. (2020): Development of an Interactive Gesture Recognition System for an Assistive Robot. Bachelor's Thesis, Advisors: J. Peters, D. Koert. Technische Universität Darmstadt, 2020.
- [A5] Scherf, L. (2021): Learning to segment human sequential behavior to detect the intention for interaction. Master's Thesis, Advisors: C. Rothkopf, S. Trick. Technische Universität Darmstadt, 2021.

Resonanz in lokalen Medien und Politik (Auswahl)

- [R1] 13.03.2019, Frankfurter Rundschau: „TU Darmstadt: Wo Roboter und Mensch gemeinsam lernen“
- [R2] 12.05.2019, Darmstädter Echo: „Darmstädter Forscher entwickeln Roboter für die Pflege“
- [R3] 27.12.2019, Main-Spitze: „Roboter in der Pflege: Mensch, Maschine!“
- [R4] 21.10.2020, Hessischer Landtag, Antwort auf die eine Kleine Anfrage zum Thema Digitaler Teilhabe, Initiativen und Projekten zur Förderung digitaler Teilhabe und neuer Technologien (z.B. Robotik) an hessischen Hochschulen