Bundesministerium
für Forschung, Technologie
und Raumfahrt

TECHNISCHE
UNIVERSITÄT
DARMSTADT

Schlussbericht

Förderkennzeichen: 16/S21093

Vorhabenbezeichnung: Aristotle: Sehen, Berühren und Manipulieren: Roboterlernen für geschickte bimanuelle Robotermanipulation durch Sehen und Berühren

Laufzeit des Vorhabens: 01.10.2021 bis 30.09.2025

Berichtszeitraum: 01.10.2021 bis 30.09.2025

Zuwendungsempfänger: Technische Universität Darmstadt

Prof. Jan Peters, Ph.D. / M.Sc. Tim Schneider / 30.03.2026

Inhaltsverzeichnis

1. Ergebnisse 1

1.1. Wissenschaftlich-technische Ergebnisse 1

Erlernen taktiler Representationen und aktiver Wahrnehmung 5

Simulation taktiler Sensorik 8

Integration von taktiler Wahrnehmung und robotischer Manipulation 10

1.2. Publikationsliste 18

2. Wichtigste Positionen des zahlenmäßigen Nachweises 19

3. Angemessenheit der geleisteten Projektarbeiten 19

4. Voraussichtlicher Nutzen 19

5. FuE-Ergebnisse von dritter Seite 19

1. Ergebnisse

1.1. Wissenschaftlich-technische Ergebnisse

	Die Forschung im Rahmen des Aristotle Projekts fokussierte sich während der Projektlaufzeit vor allen Dingen auf die aktive taktile Wahrnehmung (WP1), das Erstellen und Durchführen von Benchmarks (WP3), das Erlernen robotischer Manipulationsfähigkeiten (WP4 + WP5), sowie Projekte an der Schnittstelle dieser Bereiche. Im Folgenden werden die aggregierten Ergebnisse in diesen Bereichen dargelegt.
	Erlernen robotischer Manipulationsfähigkeiten
	Ein Kernaspekt des Aristotle Projekts bestand darin, Robotern das autonome Erlernen komplexer Manipulationsaufgaben zu ermöglichen. Dies umfasst sowohl Ansätze des modellbasierten Reinforcement Learnings (Model-Based Reinforcement Learning), um fehlende Umgebungsmodelle durch zielgerichtete Exploration aufzubauen, als auch die Konstruktion modularer Strukturen durch bi-manuelle Robotik. Dabei wurde insbesondere erforscht, wie Roboter Aufgaben auch unter großer Unsicherheit, beispielsweise beim Greifen und Platzieren ohne millimetergenaue Objektlokalisierung, zuverlässig bewältigen können. **Erlernen Robotischer Manipulationsfähigkeiten durch Model-Based Reinforcement Learning**

	(WP4) Eine zentrale Herausforderung bei der Durchführung von Manipulationsaufgaben durch Roboter ist, dass normalerweise kein akkurates Model der Umgebung vorliegt. Dadurch ist es dem Roboter nicht möglich genaue Vorhersagen über die Auswirkungen seiner Aktionen zu treffen, was das Vorausplanen in solchen Szenarios bedeutend erschwert. Jedoch ist Vorausplanung für komplexe Aufgaben elementar, da jede Aktion katastrophale Konsequenzen haben kann. So kann z.B. beim Zusammenbauen modularer Strukturen, das ungeschickte Platzieren eines einzelnen Moduls bereits zum Einsturz der Struktur führen. Eine Möglichkeit mit diesem Problem umzugehen ist, ein Modell der Umgebung aus Daten zu erlernen. Datenpunkte sind in diesem Fall Tupel aus initialen Zuständen, Aktionen des Roboters und beobachteten Konsequenzen. Ein erlerntes Modell hätte folglich die Fähigkeit, gegeben eines initialen Zustands und einer Aktion die resultierende Konsequenz vorherzusagen und ermöglicht somit dem Roboter seine Aktionen vorauszuplanen. Hier ergibt sich jedoch das Problem, dass diese Art von Daten extrem rar und teuer sind, da die Lebenszeit eines Roboters begrenzt ist und dieser bei exzessiver Nutzung Wartungs- und Reparaturarbeiten benötigt. Folglich muss sichergestellt werden, dass die Daten, die der Roboter sammelt, so hilfreich wie möglich für das Erlernen eines Modells sind. Die Forschung des IAS im Rahmen des WP4 adressiert dieses Problem aus einer informationstheoretischen Perspektive. Es wurde eine neuartige "Active Exploration" (AE) Methode entwickelt, die vor jeder Aktion des Roboters den Informationsgewinn dieser Aktion quantifiziert und diesen in die Bewertung der Aktion einfließen lässt. Im Gegensatz zu herkömmlichen Methoden des Reinforcement Learning, die üblicherweise Aktionen lediglich nach ihrem erwarteten Nutzen für das Erreichen eines Ziels auswählen, präferiert diese Methode Aktionen, die nützliches Wissen für das Erlernen des Modells liefern. Dieser Methode ist es somit möglich Aufgaben zu lösen, die eine systematische Erkundung der Umgebung erfordern, wozu klassische Reinforcement Learning Methoden nicht in der Lage sind. Die AE Methode wurde an drei Manipulationsaufgaben getestet, die so gestaltet wurden, dass sie möglichst schwer zu erkunden sind (siehe Abbildung 1). Während die Baseline-Methoden

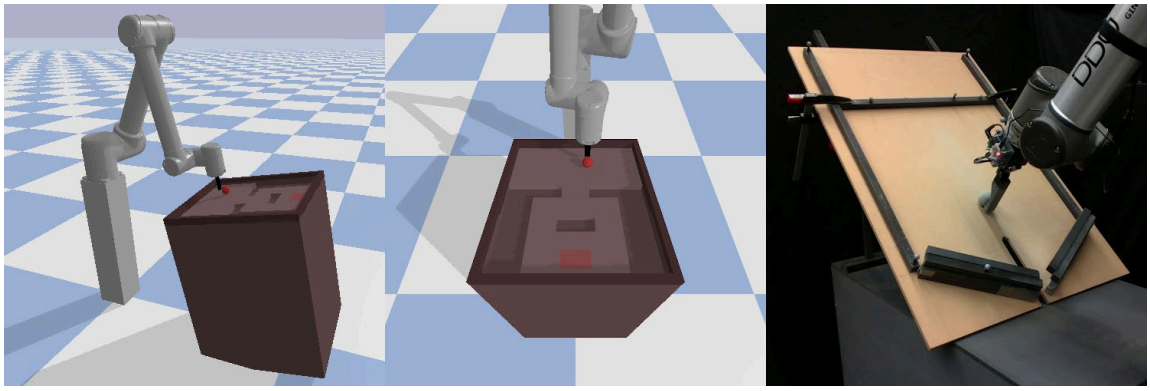

Abbildung 1: Auswahl an Manipulationsaufgaben an denen die AE Methode getestet wurde. Das Ziel in dieser Aufgabe ist, den Ball in die rote Zielzone zu balancieren. Jedoch kennt der Roboter dieses Ziel nicht und muss es durch strukturierte Exploration erst finden. Dies macht diese Aufgabe extrem herausfordernd und führt dazu, dass klassische Reinforcement Learning Methoden diese nicht lösen können.

aufgrund ihrer limitierten Erkundungsfähigkeiten in keinem Fall in der Lage waren diese Manipulationsaufgaben zu lösen, ist die AE Methode in der Lage, alle drei Aufgaben zuverlässig zu lösen. Somit wurde im Kontext dieser Manipulationsaufgaben gezeigt, dass durch das aktive Sammeln von Daten zur Informationsmaximierung, bessere Modelle gelernt werden können als durch ungerichtete oder zufällige Erkundung möglich ist.

Eine bisherige Limitation der AE Methode (und Reinforcement Learning Methoden im allgemeinen) liegt in der Skalierung zu komplexeren, höherdimensionalen Problemen. Um komplexere, höherdimensionale Sensorik, wie z.B. taktile Sensoren, zu modellieren, werden komplexere Modelle benötigt, die mehr Daten zum Lernen brauchen. Wird das Modell zu datenhungrig, lässt sich unter Umständen selbst mit effizienten Erkundungsverfahren wie der AE Methode die Menge an benötigten Daten weit genug reduzieren, um die Methode auf einem realen System einzusetzen. Diesem Problem könnte man mit induktiver Verzerrung auf Modellebene begegnen, indem man die Komplexität des Modells durch zusätzliche Annahmen über dessen Struktur reduziert.

Diese Arbeit wurde unter dem Titel "Active Exploration for Robotic Manipulation" in verschiedenen Versionen auf der 5th Multi-disciplinary Conference on Reinforcement Learning and Decision Making (RLDM 2022), dem 2nd ELLIS Doctoral Symposium 2022, und der 2022 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS 2022) präsentiert und hat dort viel positive Resonanz erhalten [p1].

Konstruktion modularer Strukturen durch einen bi-manuellen Roboter (WP3)

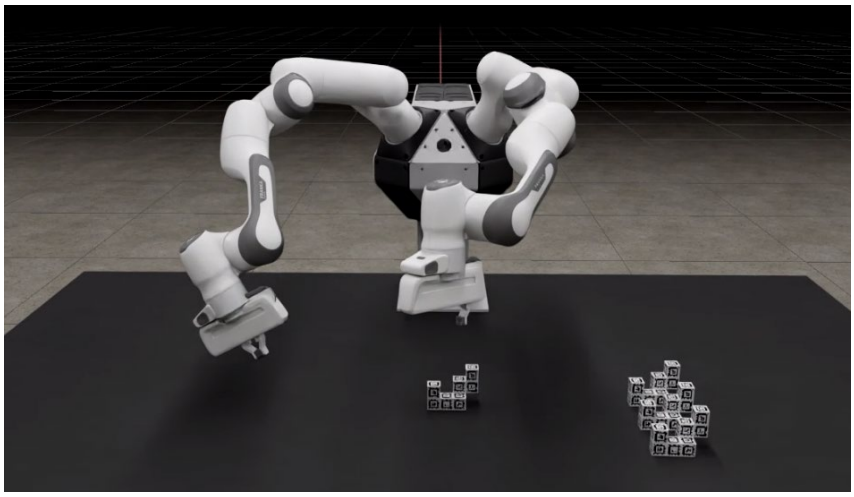

Abbildung 2: Bi-manuelle Konstruktion modularer Strukturen durch einen Roboter. Die verwendeten Bausteine sind mit AprilTags [1] markiert, um sie lokalisieren zu können.

Das Ziel dieses Projekts ist die Konstruktion modularer Strukturen durch einen bi-manuellen Roboter. Hierbei gibt es drei zentrale Herausforderungen, die adressiert werden müssen: das Lokalisieren und Verfolgen der Bauteile, die übergeordnete Planung der Bauteilplatzierung und die tatsächliche Platzierung der Bauteile. Im Kontext von Aristotle wurde sich hauptsächlich mit dem ersten Problem befasst, der Lokalisierung und Verfolgung einzelner Bauteile, da diese eine Voraussetzung für das Bearbeiten der anderen beiden Herausforderungen ist.In vielen Manipulationsaufgaben können kommerzielle Trackingsysteme, wie Optitrack oder Vicon, eingesetzt werden, um Objekte in der Szene zu lokalisieren. Dies ist jedoch bei der Konstruktion modularer Strukturen nicht möglich, da diese Systeme das Platzieren 3-dimensionaler Marker an den zu lokalisierenden Objekten erfordern. Eine Alternative ist die Lokalisierung durch Apriltags, die flach auf Bauteile aufgeklebt oder -gedruckt, und schließlich durch reguläre Kameras getrackt werden. Diese Lokalisierung ist in der Höhe und Breite recht genau, allerdings kann die Tiefe der Marker häufig nicht genau abgeschätzt werden. Die in diesem Projekt entwickelte Methode wirkt dem Problem der Tiefenabschätzung entgegen, indem Sie die Tracking-Informationen mehrerer Kameras aggregiert. Durch geschickte Platzierung der Kameras kann sichergestellt werden, dass jedes Objekt aus mehreren Perspektiven gesehen wird und somit Fehler, die die einzelnen Kameras in der Tiefenabschätzung machen durch andere Kameras ausgeglichen werden können. Vorläufige Ergebnisse suggerieren, dass durch diese Methode der Tracking-Fehler von mehreren Zentimetern auf wenige Millimeter reduziert wird.

Autonome Konstruktion modularer Strukturen in Abwesenheit von genauer Objektlokalisierung (WP3)

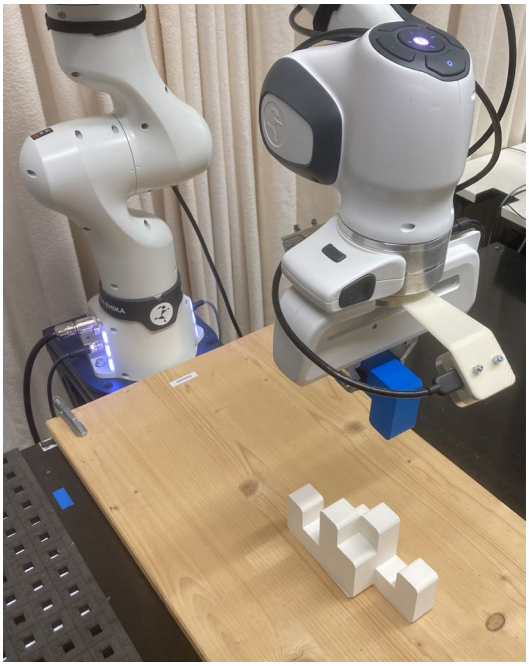

Abbildung 3: Experimentaufbau für das Erlernen der Platzierung von Bauteilen.

Eine offene Herausforderung in der Arbeit an der autonomen Konstruktion war jedoch, dass eine genaue Lokalisierung der Bauteile in der Szene nicht immer möglich ist und somit Bauteile aufgrund geringer Toleranzen nicht immer erfolgreich platziert werden konnten.

In darauffolgenden Arbeiten wurde nun ein System entwickelt, dass es erlaubt Bauteile auch in Abwesenheit genauer Lokalisierung zu platzieren. Der Fokus liegt hierbei auf der zuverlässigen Platzierung einzelner Bauteile. Wie in Abbildung 3 zu sehen ist, besteht das System aus einem Roboterarm, einem Greifer und zweier Tiefenkameras, die an dem Greifer platziert sind. Durch die Platzierung der Kameras an dem Greifer wird verhindert, dass der Roboter diese mit seinem Arm abdeckt, wie das z.B. bei statisch montierten Kameras oft der Fall ist.

Das Erlernen der Platzierung erfolgt durch eine adaptierte und verbesserte Variante von InsertionNet 2.0 [2], welches durch einen datengetriebenen Ansatz die Platzierung von Bauteilen in einer Szene erlernt. Der zentrale Vorteil dieser Methode ist, dass sie, nachdem das Objekt gegriffen wurde, keine weiteren Lokalisierungsinformationen braucht, da sie selbst lernt, die Position des Objekts aus den Tiefenbildern der Kamera zu schätzen.

Erlernen taktiler Representationen und aktiver Wahrnehmung

Eine zentrale Herausforderung bei der Verwendung (visueller) taktiler Sensoren ist, dass diese

	nur Dinge wahrnehmen können, mit denen sie sich in Kontakt befinden. Im Gegensatz zu regulären Kameras, mit denen man eine ganze Szene auf einmal wahrnehmen kann, müssen taktile Sensoren bewusst an Dingen platziert werden, um diese wahrzunehmen. Der Agent muss also aktiv entscheiden, welche Informationen er als nächstes akquiriert will und seine mit taktilen Sensoren ausgestatteten Endeffektoren dementsprechend aktuieren. Diese aktive Informationsakquise steht im Kontrast zu klassischen Methoden der Zustandsschätzung, in der der Agent passiv mit Messwerten versorgt wird und nicht aktiv handelt, um seine Zustandsunsicherheit zu reduzieren. Im Rahmen der Forschung an WP1 wurde sich zunächst mit drei Problemen der aktiven taktilen Wahrnehmung beschäftigt: der Wiedererkennung von Texturen, der Extraktion Form-Repräsentationen und der Schätzung von Posen. **Wiedererkennung von Texturen mittels taktiler Sensoren (WP1)** In der ersten Problemstellung geht es im Detail um die Frage, ob Roboter in der Lage sind, eine gegebene Texturprobe in einem Satz von Vergleichstexturproben wiederzuerkennen. Hierzu muss der Agent nicht nur lernen, abstrakte Repräsentationen aus der taktilen Wahrnehmung von Texturenproben zu extrahieren, sondern muss auch entscheiden, welche Probe erneut berührt werden muss, um mehr über diese zu lernen. Es wurden hier mehrere Ansätze verfolgt, die auf Basis der Unsicherheit des Agenten entscheiden, welche Proben den größten Informationsgewinn bringen und daher erneut berührt werden sollten. In einer Erkundungsstudie mit menschlichen Teilnehmern wurde festgestellt, dass die Wiedererkennungsgenauigkeit dieser Methode (ca. 90 %) die Genauigkeit der Versuchspersonen (ca. 67 %) signifikant übersteigt. Diese Ergebnisse suggerieren, dass visuelle taktile Sensoren in Kombination mit Methoden der Abschätzung des maximalen Informationsgewinns bei der Wiedererkennung von Texturen übermenschliche Leistungen

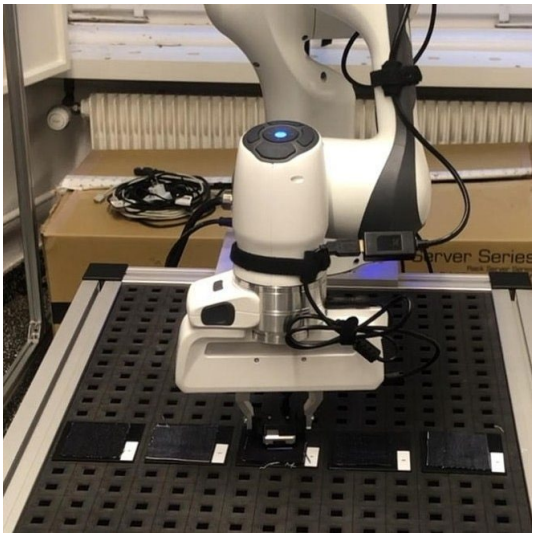

Abbildung 4: Versuchsaufbau für die Texturerkennung mittels eines taktilen Sensors. Der Roboter hält den nach unten gerichteten Sensor in seinem Greifer.

erzielen können. Diese Arbeit wurde zur Veröffentlichung in der *International Conference on Learning Representations (ICLR) 2024* akzeptiert.

Extraktion von Form-Repräsentationen aus taktilen Daten (WP1)

In der zweiten Problemstellung wird sich mit der Frage befasst, ob die Formen von Objekten aus taktilen Daten rekonstruiert werden können. Diese Fähigkeit ist für autonome Agenten unabdingbar, da nicht davon ausgegangen werden kann, dass für alle Objekte, die dieser manipuliert, bereits ein Modell (z.B. ein CAD Modell) vorliegt. Im Rahmen der Forschung an dieser Problemstellung wird eine Methode entwickelt, die die Kanten der zu rekonstruierenden Objekte erkennt und diese in eine 3D Punktewolke transformiert. Diese 3D Punktewolke kann dann zum Abgleich gegen eine Datenbank oder direkt als Repräsentation der 3D Form des Objekts verwendet werden. Die Herausforderung ist auch hier zu entscheiden, wie das Objekt berührt werden muss, um den Informationsgewinn zu maximieren.

Posenschätzung aus Visuellen und Taktilen Daten (WP1)

Eine zentrale Applikation taktiler Sensoren ist das Schätzen von Objektposen während der Manipulation. Typischerweise erfolgt diese Schätzung anhand von Kameradaten, die jedoch unzuverlässig werden, wenn der Roboter mit seinem Greifer Teile des Objekts verdeckt. Da taktile Daten alleine jedoch ebenfalls oft lokale Beschränkungen haben, wurden visuelle und taktile Daten vereint, um eine robuste und akkurate Posenschätzung zu ermöglichen, z.B. mithilfe des _Iterative Closest Point_ (ICP) Algorithmus. Getestet wurde diese Methodik an einem

bimanuellen TIAGo Roboter für das Stapeln von Dosen, bei dem es auf höchste Genauigkeit

Abbildung 5: Beispielanwendung für den Posenschätzungsalgorithmus. Ein TIAGo Roboter muss Dosen stapeln, wobei visuelle und taktile Daten genutzt werden um Posen extrem exakt zu schätzen.

ankommt.

Simulation taktiler Sensorik

Für das erfolgreiche Trainieren von Algorithmen des maschinellen Lernens ist eine akkurate und recheneffiziente physikalische Simulation unerlässlich, da das Sammeln von Interaktionsdaten in der realen Welt extrem zeit- und ressourcenintensiv ist. Standard-Simulatoren reichen jedoch oft nicht aus, um die komplexe Kontaktmechanik von weichen taktilen Sensoren akkurat abzubilden. Aus diesem Grund wurde ein Schwerpunkt auf die Entwicklung neuer Simulationsumgebungen gelegt, die die physikalische Realität der taktilen Interaktionen präzise erfassen und zur Skalierbarkeit für interaktives Robotiklernen hochgradig beschleunigt werden konnten.

Simulation taktiler Sensoren in IsaacSim (TacEx) (WP1)

Ein wichtiger Schritt zum Erreichen von WP1 ist das Aufsetzen eines Simulators, der taktile Sensoren akkurat und deren physikalische Interaktion mit der Umgebung simulieren kann. Eine akkurate Simulation taktiler Sensoren vereinfacht das Training für Reinforcement Learning Algorithmen enorm. Die anfängliche Wahl fiel auf IsaacSim [5], unter Verwendung einer

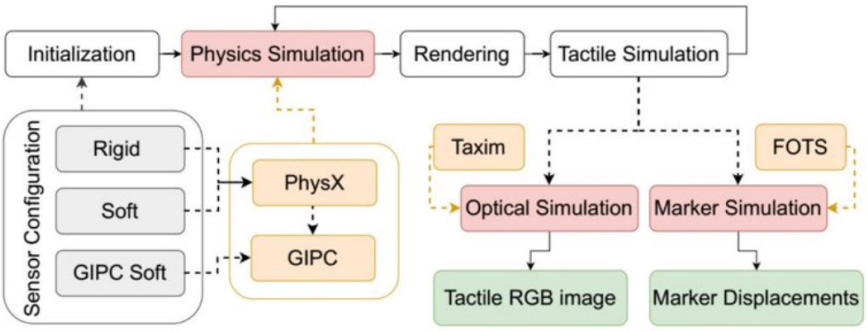

Abbildung 6: Schematische Darstellung der TacEx Pipeline

Erweiterung auf Basis von "Taxim" [6], um Visualisierung und weiche Körper zu kombinieren.

Jedoch wurde festgestellt, dass die Fähigkeiten von IsaacSim, weiche Körper zu simulieren, unzureichend für die Simulation taktiler Sensoren waren (aufgrund von Defiziten im Finite-Elemente-Modell, unter anderem bei der Haftreibung). Daher wurde sich mit der Entwicklung und Integration eines genaueren und effizienten FEM Simulators mitsamt taktilem Renderer in IssacSim beschäftigt. Dieser Simulator wurde unter dem Namen *TacEx* entwickelt und auf der 1st German Robotics Conference 2025 präsentiert [p5].

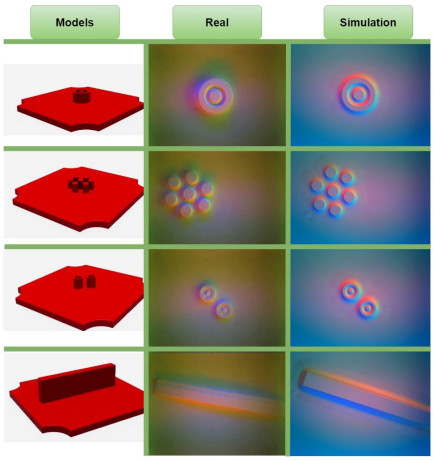

Abbildung 8: Vergleich simulierter und echter taktiler Sensordaten für verschiedene Stimuli.

Echtzeitsimulation deformierbarer taktiler Sensoren und Objekte mittels Graph Neural

Abbildung 7: Akkurate Simulation eines deformierbaren Objekts

Networks (WP1)

	Wie bereits bei TacEx eingeführt, stellt die Simulation weicher Körper für taktile Sensoren eine enorme Herausforderung an Rechenkapazität und Genauigkeit dar. Um die rechenintensive Finite-Elemente-Methode (FEM) effizient zu beschleunigen (um Faktoren von 10^2 bis 10^4), wurde ein Framework auf Basis von Graph Neural Networks (GNNs) entwickelt. Dieses integriert spezifische physikalische "Inductive Biases", insbesondere durch detaillierte Tetraeder-Features zur exakten lokalen Stress-Vorhersage sowie globale Graph-Features für die netzwerkweite Informationsverteilung. In Vergleichen reduzierte dieses Modell die Vorhersagefehler für Verformungen und Spannungsfelder um bis zu 45% gegenüber vorherigen graphenbasierten Ansätzen. Diese Arbeit (akzeptiert bei RoboSoft 2026) ermöglicht so zukünftig echtzeitfähigen Einsatz taktiler und deformierbarer Simulation bei interaktiven robotischen Lernverfahren. Diese Arbeit wurde in Kollaboration mit den französischen Partnern durchgeführt und bei RoboSoft 2026 akzeptiert [p9].
	Integration von taktiler Wahrnehmung und robotischer Manipulation
	Ein essentieller Schritt auf dem Weg zu geschickter taktiler Manipulation ist die Integration von taktiler Wahrnehmung in robotische Regelkreise. Es muss erforscht werden, wie taktile Informationen effektiv in die Entscheidungsfindung von Robotern einbezogen werden können, um die Performanz bei Manipulationsaufgaben zu verbessern oder diese überhaupt erst zu ermöglichen. Fünf der durchgeführten Projekte beschäftigen sich daher spezifisch mit der Schnittstelle und Integration von taktiler Wahrnehmung und robotischer Manipulation. **Erlernen von Explorationsstrategien für die aktive taktile Wahrnehmung (APPLE) (WP1, WP3, WP4)** Wie bereits zuvor beschrieben, können taktile Sensoren nur Informationen über die Umgebung liefern, wenn sie mit dieser in Kontakt sind. Daher müssen Roboter mit taktilen Sensoren aktiv entscheiden, welche Informationen sie als nächstes akquirieren wollen und ihre Endeffektoren dementsprechend aktuieren. Dieses Problem wird als aktives Explorationsproblem bezeichnet. Vorangegangene Ansätze zur aktiven taktilen Wahrnehmung adressieren das Explorationsproblem häufig, indem sie ein prädiktives Modell schätzen, das die Unsicherheit des Agenten quantifiziert. Ein zentrales Problem dieser Ansätze ist jedoch, dass diese Modelle häufig nicht auf hochdimensionale Bilddaten wie sie der "GelSight Mini" [3] liefert, skalieren. In dieser Arbeit wurde ein neuartiger Ansatz entwickelt, der ohne ein prädiktives Modell auskommt: *Active Perception Policy Learning* (APPLE). Statt ein explizites Modell der Welt und der Unsicherheit zu erlernen, wird über Reinforcement Learning direkt ein Verhalten trainiert,

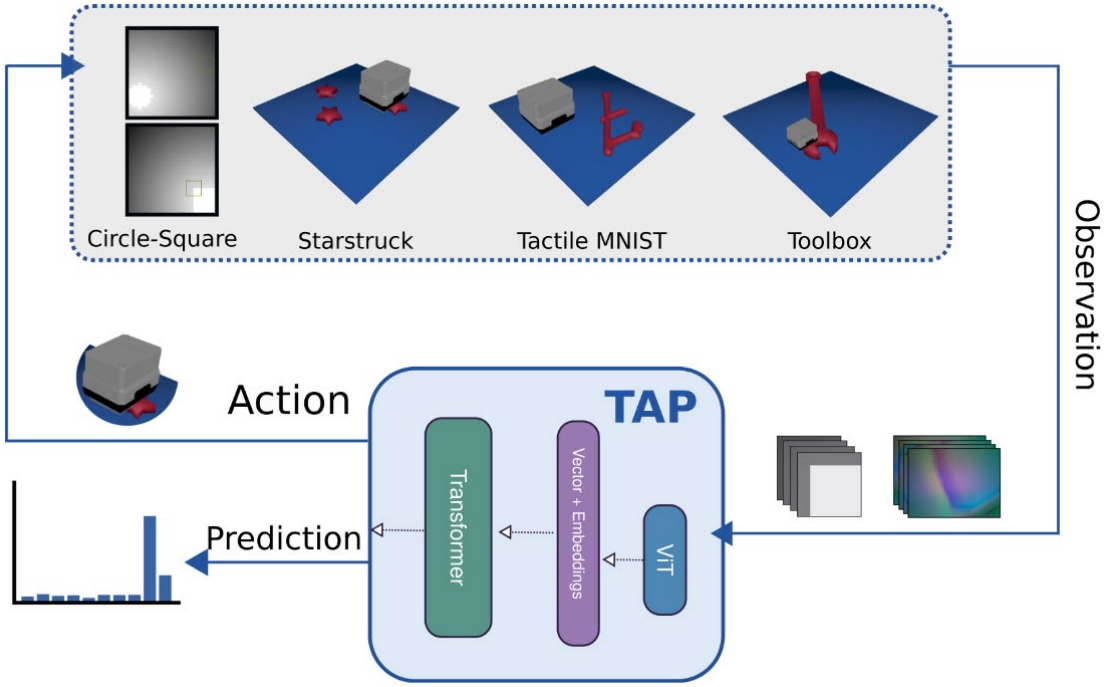

Abbildung 9: Schematische Darstellung des APPLE Algorithmus.

das auf maximalen Informationsgewinn abzielt. Die Unsicherheit des Agenten wird dabei nicht direkt geschätzt, sondern spiegelt sich indirekt im erlernten Verhalten wider. Da es in der Regel einfacher ist, ein geeignetes Verhalten zu erlernen als eine präzise Repräsentation einer komplexen Umgebung samt Unsicherheitsabschätzung, ist dieser Ansatz besser skalierbar. Eine schematische Darstellung von APPLE kann Abbildung 5 entnommen werden.

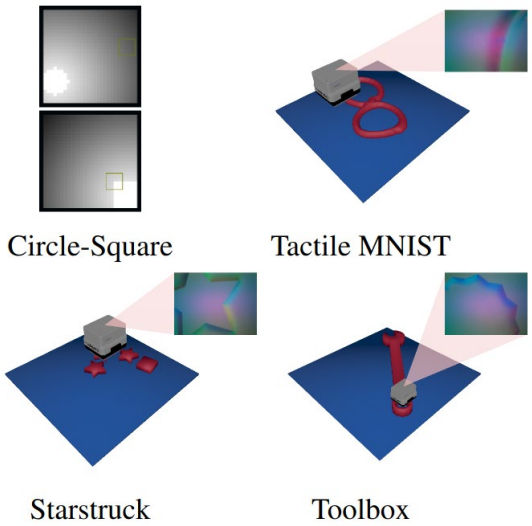

Abbildung 10: Explorationsprobleme aus dem Active Perception Gym Benchmark und dem Tactile MNIST Benchmark. Der Agent nutzt den GelSight Mini Sensor, um effektiv die Objekte zu explorieren.

Um APPLE zu evaluieren, wurde ein umfassendes Simulationsbenchmark entwickelt: die *Active*

	Perception Gym Basissoftware [p2] sowie der *Tactile MNIST Benchmark* [p3]. Zudem wurde mit dem Tactile MNIST Benchmark ein Datensatz mit über 150.000 taktilen Messungen (gesammelt von einem Roboterarm) und simulierten Daten via CycleGAN [4] veröffentlicht. Durch diese Benchmarks konnte gezeigt werden, dass APPLE die Performanz des momentanen Stands der Technik signifikant überschreitet. Diese grundlegende Arbeit zu APPLE wurde auf der ICLR 2026 akzeptiert [p10], sowie vorher auf der 1st German Robotics Conference (GRC 2025) veröffentlicht [p4]. Der Tactile MNIST Benchmark wird im Mai bei NeurIPS 2026 eingereicht.

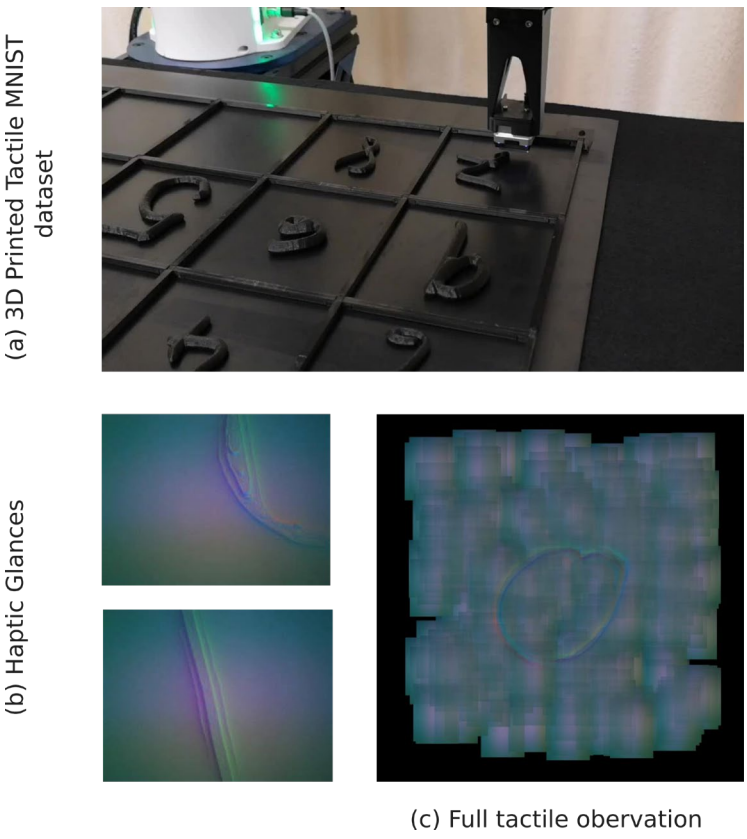

Abbildung 11: Tactile MNIST Datensatz. Links: 3D-gedruckte Ziffern werden autonom von einem Roboterarm berührt. Rechts: Die taktilen Messungen, die dabei entstehen.

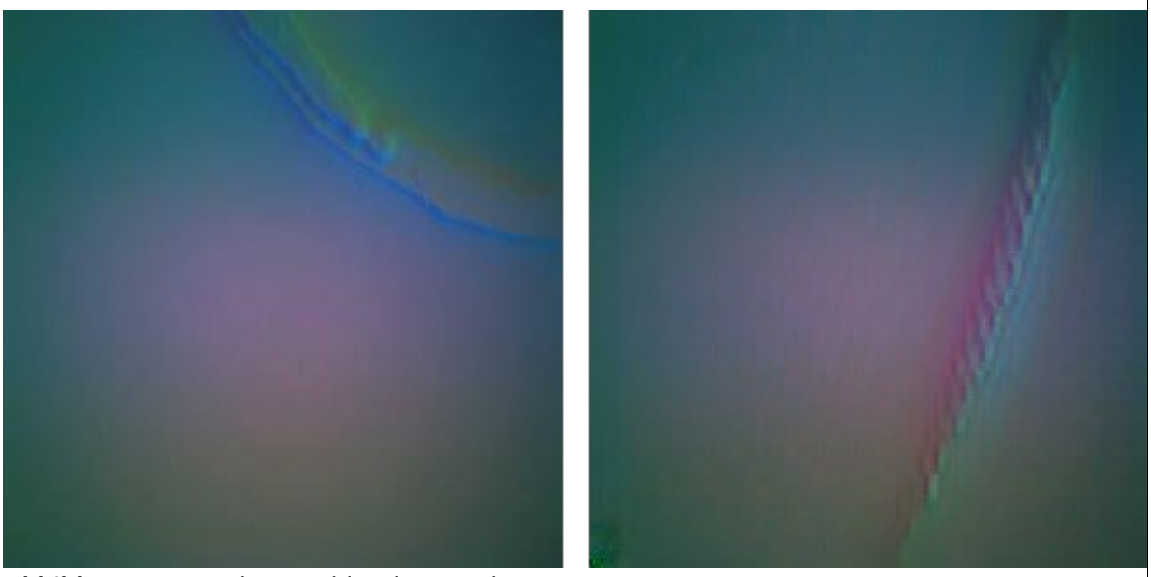

Abbildung 12: Simulierte Bilder des Tactile-MNIST Datensatzes.

Erlernen geschickter robotischer Manipulationsfähigkeiten auf Basis von taktiler und visueller Wahrnehmung durch Model-Based Reinforcement Learning (MBRL) (WP1, WP4)

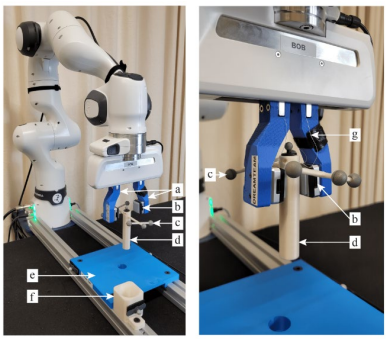

Abbildung 13: Plattform für die Zylinder-Einführungs-Aufgabe zum Erlernen von taktilen Manipulationsfähigkeiten und deren Auswertung.

Zentrale Herausforderungen beim Einsatz visueller taktiler Sensoren in der robotischen Manipulation sind, dass die Daten hochdimensional und schwer interpretierbar sind.

Diese Herausforderungen können durch den Einsatz von Model-Based Reinforcement Learning (MBRL) adressiert werden. In dieser Arbeit wurde ein System entwickelt, das es einem Roboter ermöglicht, durch den Einsatz von MBRL geschickte Manipulationsfähigkeiten zu erlernen. Dazu wurde eine Platform entwickelt, in der ein Franka Roboterarm [p3], mit einem GelSight Mini [1] Sensor ausgestattet, einen Zylinder in ein Loch einführen muss (siehe Abbildung 6). Die Platform ist vollautonom und braucht nur minimale Betreuung durch den Menschen. Mittels dieser Plattform konnte bisher gezeigt werden, dass der MBRL-Algorithmus *Dreamer-v3* in der Lage ist, die Aufgabe zu erlernen und zuverlässig auszuführen.

In einer Erweiterung wurde die Zylindereinführungsaufgabe erschwert, indem die Lochneigung variabel gemacht wurde, d.h. der Agent musste zusätzlich die Ausrichtung des Lochs ertasten. Die Analysen zeigten, dass taktile Daten signifikant zur Robustheit bei Manipulationsaufgaben unter sehr geringer Toleranz beitragen und insbesondere bei Low-Tolerance-Aufgaben enorm relevant sind. Diese Ergebnisse zur Interaktion von Vision und taktilem Feedback wurden bei der *ICRA@40* (2024) [p6], der *GRC 2025* [p7] sowie bei einem *ICRA 2024 Workshop* vorgestellt.

In Zukunft werden weitere Algorithmen getestet und verglichen, um die Leistungsfähigkeit von RL bei der taktilen robotischen Manipulation zu evaluieren. Im Fokus steht hier momentan der an der TU Darmstadt entwickelte CrossQ Algorithmus[7].

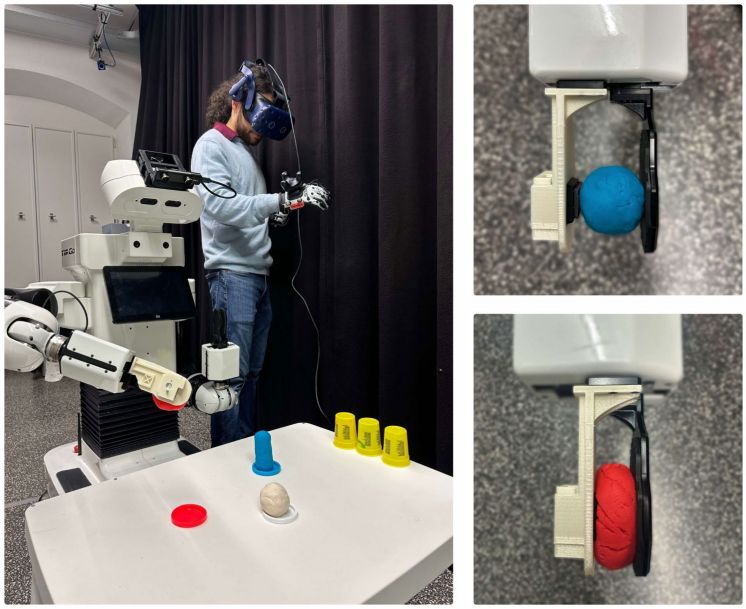

Abbildung 14: Teleoperationsplattform mit taktilen Sensoren und haptischem Feedback.

Integration von taktiler Wahrnehmung in bi-manuelle Teleoperation (WP1, WP3)

Ein Feld, das besonders von taktiler Wahrnehmung profitieren kann, ist die Teleoperation. Hierbei regelt ein menschlicher Operator einen Roboter, der an einem anderen Ort ist. Oft fehlt das feinmotorische taktile Feedback. In dieser Arbeit wurde ein System entwickelt, das es dem Operator erlaubt, taktiles Feedback durch VR-Handschuhe samt Vibrationsmotoren zu erhalten, was in einer messbaren Verbesserung der Geschicklichkeit des Operators resultierte. Diese Arbeit (basierend auf einem Tiago-Roboter) wurde bei einem ICRA 2024 Workshop akzeptiert.

Erlernen geschickter dynamischer Manipulationsfähigkeiten mittels ereignisbasierter visuo-taktiler Sensorik (WP1, WP3)

Ein weiteres Anwendungsfeld für visuo-taktile Sensorik ist die dynamische Manipulation, die präzise zeitliche und räumliche Interaktionskontrolle erfordert.

Im ersten Projekt wurde untersucht, inwiefern schnelle, kontaktintensive und dynamische Aufgaben wie das Anzünden eines Streichholzes vorteilhaft erlernt werden können. Hierzu wurde eine "Tactile-Conditioned Diffusion Policy" (basierend auf Flow-Matching) entwickelt. Durch die Integration lokaler Beobachtungen eines ereignisbasierten taktilen Sensors sowie Bildern einer Handgelenkskamera konnte der Roboter die Aufgabe anhand von nur 20 menschlichen Demonstrationen robust erlernen. Die Resultate unterstreichen, dass taktile Sensorik für den

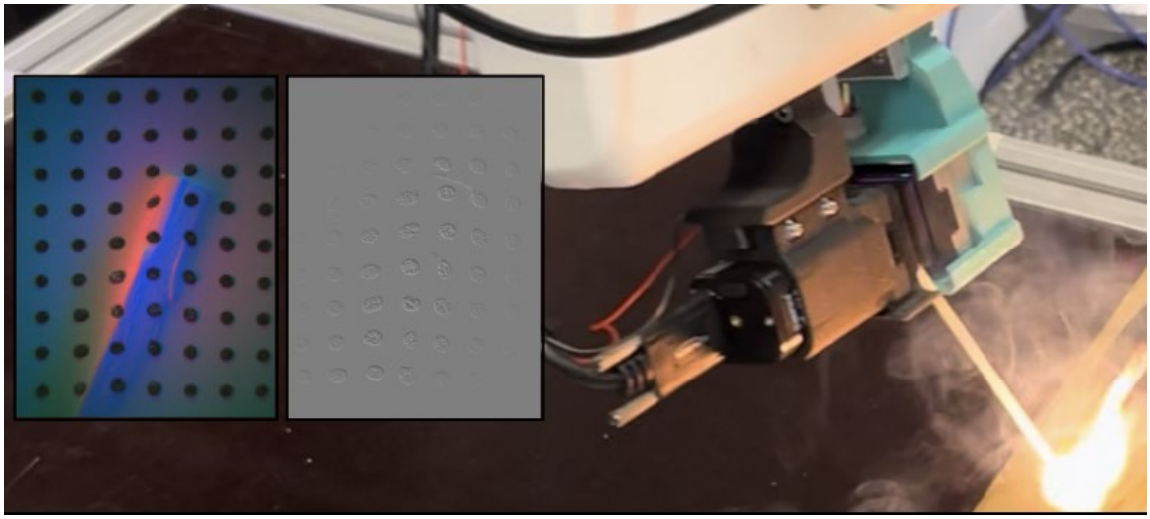

Abbildung 15: Ereignisbasierte taktile Sensorik ermöglicht das hochdynamische, vorsichtige Anzünden eines Streichholzes, ohne dass das dieses abbricht.

Erfolg der dynamischen Manipulation, etwa beim Ausgleich variierender Greifposen und Orientierungen der Reibefläche, unabdingbar ist. Diese Arbeit wurde beim Journal "IEEE robotics and automation letters" (RAL) akzeptiert und wird auf ICRA 2026 präsentiert werden [p8].

In einem weiteren Projekt wurde die ereignisbasierte taktile Sensorik genutzt, um die hochfrequente Balancierung eines Stabes ("Pole Balancing") allein durch taktilen Kontakt (also blind) zu ermöglichen. Das Problem wurde als Regression der 3D-Orientierung auf der Einheitskugel formuliert. Um die hochdimensionalen und spärlichen Signale effizient zu verarbeiten, wurde ein "Statistical Multi-Quad"-Encoding eingeführt. Die systematische Evaluierung verschiedener Architekturen zeigte, dass Temporal Convolutional Networks (TCNs) eine präzise Orientierungsschätzung (durchschnittlicher Fehler von rund 2,23°) erreichen. Dies demonstriert, dass hochfrequente ereignisbasierte taktile Daten als alleinige Modalität für präzise Zustandsschätzungen in sehr reaktiven Aufgaben ausreichen. Im nächsten Schritt dieses Projekts, wird diese Schätzmethode nun in einen Roboter integriert, um die Balancieraufgabe in Echtzeit zu lösen.

Erlernen von Wartungs- und landwirtschaftlichen Fähigkeiten durch visuo-taktile Sensorik von Demonstrationen (WP1, WP3, WP5)

Die Integration fortschrittlicher taktiler und visueller Modelle ermöglicht auch den Transfer auf komplexe Wartungs- und landwirtschaftliche Fähigkeiten, in denen visuelle Störfaktoren und variierende Interaktionskräfte dominieren.

Um kontaktintensive Aufgaben zu meistern, die spezifische Greifkräfte erfordern, wurde das FARM-Framework (Force-Aware Robotic Manipulation) entwickelt. Dieses Imitationslern-

Framework integriert hochdimensionale taktile Daten des GelSight Mini Sensors in einen nachgebauten "Universal Manipulation Interface" (UMI) Greifer, um taktil-konditionierte Kraftsignale abzuleiten. Die dadurch erlernte Policy steuert simultan Roboterpose, Greiferöffnungsweite und Greifkraft. FARM bewies überlegene Performanz bei Greifarbeiten mit völlig unterschiedlichen Kraftanforderungen und sicherte konsistente und dynamische Kraftanpassung durch seinen kraftbasierten Aktionsraum. Diese Arbeit wurde bei ICRA 2026 akzeptiert und wird dort im Juni vorgestellt [p11].

Ein weiteres zentrales Problem im landwirtschaftlichen Einsatz ist die visuelle Komplexität und Verrauschtheit bei Feldarbeiten (etwa beim Jäten von Unkraut). In einem speziellen Versuchsszenario wurde hierbei erforscht, inwiefern induktive Verzerrungen für die visuelle Aufbereitung helfen, den massiven Bedarf an abstrakten Trainingsdaten bei Diffusion Policies zu senken. Die Studie evaluierte dabei das Verwenden räumlicher Keypoints anstelle von End-to-End Bildfeatures. Die Resultate zeigten, dass durch das Reduzieren irrelevanter Hintergrundinformationen ein zuverlässiges Steuerungsverhalten beim Jäten schon aus minimalistischen 3 Demonstrationen erlernt werden konnte, da sich das Netzwerk strikt auf das Objekt konzentrieren kann (im Gegensatz zur Baseline, welche bei weniger als 21 Demonstrationen versagte). Dies rückt ein flexibles und adaptierbares Verhalten für datensparsame Agrarrobotik in greifbare Nähe.

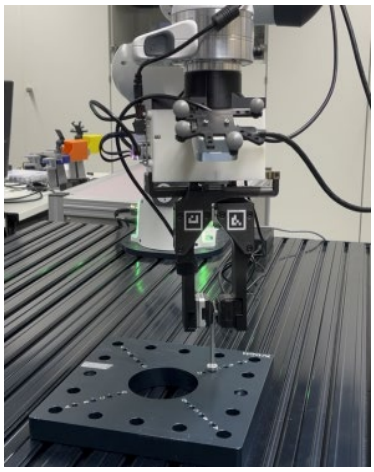

Abbildung 16: Nach nur 20 Demonstrationen führt der Roboter autonom eine typische Wartungsaufgabe durch: das Anziehen einer Schraube, wobei er die erforderlichen Kräfte durch taktile Sensorik lernt und anpasst.

Referenzen

[1] Olson, E. (2011). AprilTag: A robust and flexible visual fiducial system. ICRA 2011.

[2] Spector, O., Tchuiev, V., & Di Castro, D. "Insertionnet 2.0: Minimal contact multi-step insertion using multimodal multiview sensory input." ICRA 2022.

[3] GelSight Mini (2023, January 3). GelSight.

[4] Zhu, J.-Y., et al. "Unpaired image-to-image translation using cycle-consistent adversarial networks." ICCV 2017.

[5] Liang, J., et al. (2018). GPU-Accelerated Robotic Simulation for Distributed Reinforcement Learning. arXiv.

[6] Si, Z., & Yuan, W. (2022). Taxim: An example-based simulation model for gelsight tactile sensors. IEEE RAL.

[7] Bhatt, A., Palenicek, D., Belousov, B., Argus, M., Amiranashvili, A., Brox, T., & Peters, J. (2025) CrossQ: Batch Normalization in Deep Reinforcement Learning for Greater Sample Efficiency and Simplicity. In The Twelfth International Conference on Learning Representations.

1.2. Publikationsliste

[p1] Schneider, T., Belousov, B., Chalvatzaki, G., Romeres, D., Jha, D. K., & Peters, J. (2022). Active Exploration for Robotic Manipulation. 2022 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS).

[p2] Schneider, T. (2025). active-perception-gym: Extension of gymnasium for active perception tasks. GitHub. https://github.com/TimSchneider42/active-perception-gym

[p3] Schneider, T., Duret, G., de Farias, C., Calandra, R., Chen, L., & Peters, J. (2025). Tactile mnist: Benchmarking active tactile perception. arXiv preprint arXiv:2506.06361. (NeurIPS 2026 planned)

[p4] Schneider, T., De Farias, C., Calandra, R., Chen, L. & Peters, J. “Active Perception for Tactile Sensing: A Task-Agnostic Attention-Based Approach”, GRC 2025.

[p5] Nguyen, D. H., et al. (2025). TacEx: GelSight tactile simulation in Isaac Sim. GRC 2025.

[p6] Lenz, J., Gruner, T., Palenicek, D., Schneider, T., Peters, J. (2024). Analysing the Interplay of Vision and Touch for Dexterous Insertion Tasks. ICRA@40.

[p7] Lenz, J., Gruner, T., Palenicek, D., Schneider, T., & Peters, J. (2025). Analysing the Interplay of Vision and Touch for Dexterous Insertion Tasks. GRC 2025.

[p8] Funk, N., Chen, C., Schneider, T., Chalvatzaki, G., Calandra, R., & Peters, J. (2026). On the importance of tactile sensing for imitation learning: A case study on robotic match lighting. IEEE RAL (accepted)

[p9] Durent, G., Heller, F., Mazurak, D., Kshirsagaer, A., Schneider, T., Zara, F., Peters, J., & Chen, L. (2026). Real-Time Simulation of Deformable Tactile Sensors and Objects in Robotic Grasping using Graph Neural Networks with Inductive Biases. 9th IEEE-RAS International Conference on Soft Robotics (RoboSoft)

[p10] Schneider, T., de Farias, C., Calandra, R., Chen, L., & Peters, J. (2026) Apple: Toward General Active Perception via Reinforcement Learning. In The Twelfth International Conference on Learning Representations.

[p11] Helmut, E., Funk, N., Schneider, T., de Farias, C., & Peters, J. (2025). Tactile-Conditioned Diffusion Policy for Force-Aware Robotic Manipulation. ICRA 2026 (accepted).

2. Wichtigste Positionen des zahlenmäßigen Nachweises

TODO

3. Notwendigkeit und Angemessenheit der geleisteten Projektarbeiten

Zur Erreichung der Ziele von ARISTOTLE waren alle geleisteten Projektarbeiten notwendig und angemessen.

4. Voraussichtlicher Nutzen

Die TU Darmstadt verfolgt im Projekt als universitärer Forschungspartner keine unmittelbaren, eigenständigen kommerziellen Ziele. Die Ergebnisse dieses Projektes haben jedoch großen wissenschaftlichen Wert für die Forschung an der TU Darmstadt und darüber hinaus. Angestoßen durch die Arbeit im Kontext des ARISTOTLE Projekts sind zur Zeit mehrere Forschungsprojekte im Gange, die die gewonnenen Erkenntnisse weiter ausbauen und vertiefen werden. So wird z.B. gerade an einer Erweiterung von FARM [p99] gearbeitet, die bei ICRA 2027 eingereicht wird. Ein weiteres Projekt, dass im Kontext von ARISTOTLE entstanden ist und jetzt fortgeführt wird ist das MBRL Projekt zur taktilen Wahrnehmung, dass neben seinen momentanen Publikationen [p6, p7] noch in erweiterter Form zu ICRA 2027 eingereicht werden soll.

5. FuE-Ergebnisse von dritter Seite

Es sind keine Ergebnisse von dritter Seite bekannt geworden, die die Durchführung dieses Projekts beeinflusst haben.