

Von (Quanten)-Optik bis Schwerelosforschung

Optimierung von Experimenten durch Maschinelles Lernen

Große Forschungsverbünde wie das Quantum Valley Lower Saxony (QVLS) oder das Exzellenzcluster QuantumFrontiers bringen viele verschiedene Forschungsbereiche zusammen und ermöglichen einen engen Austausch unterschiedlicher Forschungsdisziplinen.

Die folgenden Beispiele demonstrieren den alltäglichen Umgang mit Methoden des maschinellen Lernens (Machine Learning) im Kontext zweier ausgewählter Forschungsbereiche.



Quantenkontrolle, wie sie in der Arbeitsgruppe „Quantum Control“ am Institut für Gravitationsphysik Forschungsthema ist, bedeutet, komplexe Systeme, die Rauschen am oder unterhalb der Quantengrenze aufweisen, kontinuierlich zu messen und zu stabilisieren. Die Arbeitsgruppe beschäftigt sich dabei vornehmlich mit quantenoptischen Experimenten. Bei der täglichen Arbeit im Optiklabor gibt es viele Aufgaben, bei denen mit sehr viel Geduld, Ruhe und Fingerspitzengefühl viele kleine Schraubchen gedreht werden müssen, um ein optimales Ergebnis zu erhalten (siehe Abb. 1). Ein Beispiel

dafür ist es, einen Laserstrahl mit Hilfe von Spiegeln sehr präzise durch ein Experiment zu lenken. Es wäre dafür eine große Hilfe, wenn eine Maschine die beste Lösung für den Strahlengang herausfinden und dann die entsprechenden Schraubchen drehen könnte.

Wenn Aufgaben mühsam, aber klar beschreibbar sind, ist eine mögliche Lösung, ein konventionelles Automatisierungsprogramm zu schreiben. In solch einem Programm wird einer Maschine genau vorgegeben, welche Schritte sie der Reihe nach verfolgen soll, um ein bestimmtes Ziel

zu erreichen. Es gibt jedoch auch Probleme, bei denen unklar ist, welcher Weg ideal ist. Zum Beispiel ist manchmal unbekannt, welche Schraubchen gedreht werden sollten. Auch kommt es vor, dass so viele Stellschrauben vorhanden sind, dass es nicht überschaubar ist, wie stark der einzelne Einfluss ist und wie diese zusammenspielen. In solch einem Fall ist es interessant und gegebenenfalls nützlich, sich mit Machine Learning zu beschäftigen.

Die Machine Learning Methode, die der Regelung der quantenoptischen Experimente am besten entspricht, ist das

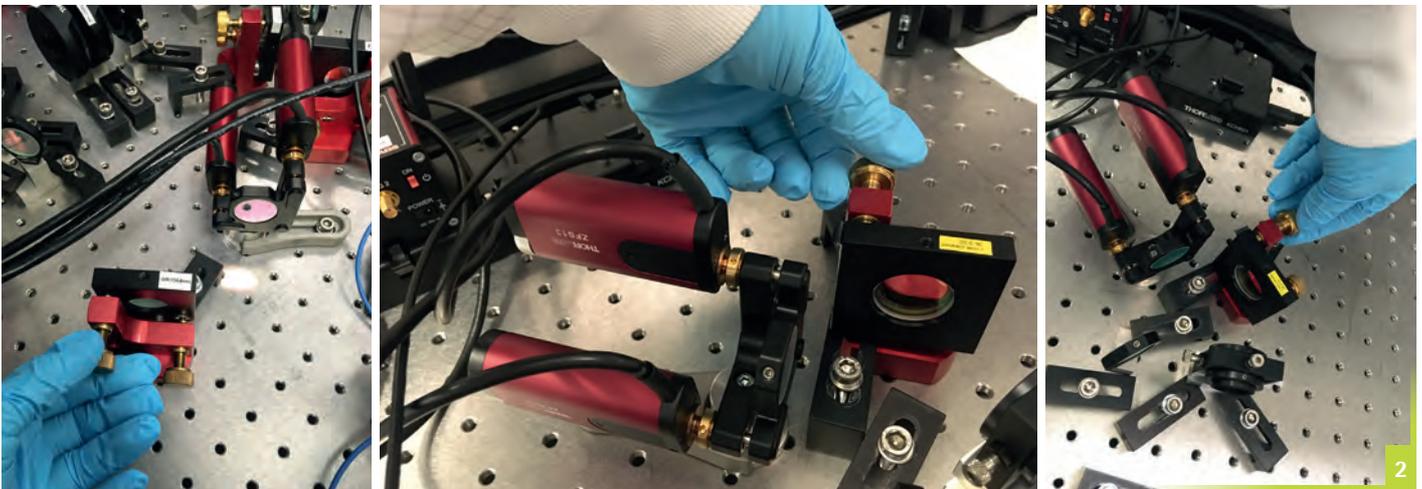
Abbildung 1
Bei optischen Experimenten gibt es unzählige kleine Stellschrauben zu drehen. Wenn eine Maschine lernen würde, sie richtig einzustellen, wäre das von großer Hilfe.
Quelle: Lea Richtmann

sogenannte Reinforcement Learning. Dabei interagiert ein „Agent“ (das Computerprogramm) mit einem „Environment“ (dem Experiment). Der Agent führt Aktionen aus (dreht zum Beispiel mit Motoren an Stellschrauben, *siehe Abb. 2*) und das Environment meldet dem Agenten zurück, wie die Aktionen den Zustand des Experiments verändert haben (zum Beispiel wie die Spiegel nach dem Drehen der

liegen, dass Reinforcement Learning für komplexe Probleme eine vielversprechende Methode ist. Trotzdem gibt es im experimentellen Bereich (das heißt in Situationen, in denen der Agent nicht nur auf einer Simulation trainiert wird, sondern tatsächlich Aktuatoren wie Schraubchen bewegt) noch sehr wenige Anwendungen. Ziel dieser Forschung ist es, zum Schließen dieser hochinteressanten An-

außerdem hohe zeitliche und finanzielle Kosten mit sich. Aktuell wird daher erforscht, wie das Reinforcement Learning so gestaltet werden kann, dass es mit den vielen experimentellen Herausforderungen im Labor umgehen kann.

Dafür wurde eine Aufgabe identifiziert, deren Probleme besser überschaubar sind, als bei einem komplizierten quantenoptischen Aufbau:



Stellschrauben ausgerichtet sind). Eine Belohnung erhält der Agent, wenn sich dadurch das Ergebnis verbessert hat (wenn zum Beispiel nun mehr Licht an der richtigen Stelle ankommt). Der Agent wird nun trainiert, eine Lösung zu finden, die das gewünschte Ergebnis erzielt. Das Training besteht darin, ihn immer wieder mit dem Experiment interagieren zu lassen. Er weiß dabei gar nicht, was das Ziel ist. Zu Beginn führt er komplett zufällig Aktionen aus. Durch die Belohnung lernt er mit der Zeit eine Strategie, die zum gewünschten Ergebnis führt. Besonders interessant ist, dass es auf diese Weise auch möglich ist, dass der Agent einen Weg findet, den sich ein Mensch nicht ausgedacht hätte.

Die Regelung der Experimente ist häufig sehr aufwändig. Es scheint auf der Hand zu

wendungslücke beizutragen und das Potenzial des maschinellen Lernens in der experimentellen Quantenoptik stärker nutzbar zu machen.

Einer der Gründe, warum es noch nicht viele experimentelle Anwendungen des Machine Learnings (zumindest nicht in der Optik) gibt, ist, dass die reale Welt bekanntlich nicht ideal ist: Motoren laufen nicht perfekt, im Labor gibt es Schwankungen zum Beispiel der Temperatur, die nicht genau beschrieben werden können, experimentelle Komponenten können degradieren oder sogar ausfallen, wenn sie zu häufig verwendet werden, Sensoren messen nicht perfekt, um nur ein paar Nicht-Idealitäten zu nennen. Das Trainieren eines Machine Learning Algorithmus auf einem Experiment ist daher ziemlich schwierig und bringt

Einem Agenten wird versucht beizubringen, Spiegel so zu bewegen, dass das Laserlicht exakt an bestimmte Orte gesteuert werden kann. Bei den durchgeführten Versuchen wird zum Beispiel festgestellt, dass die Motoren abhängig von der Richtung, in der sie sich bewegen, sich unterschiedlich präzise verhalten. Das Computerprogramm wird dann angepasst, um das zu berücksichtigen. Die hier gewonnenen Erkenntnisse können dann zukünftig genutzt werden, um quantenoptische Experimente zu optimieren, sowie gleichzeitig Zeit im Labor zu sparen und die Stabilität von Experimenten zu erhöhen.

Auch wenn das experimentelle Machine Learning viele Herausforderungen bietet, ist schon jetzt abzusehen, dass damit Experimentator*innen

Abbildung 2
Spiegelhalter wie sie typischerweise in einem Optiklabor verwendet werden. Die Schraubchen, die beim oberen Halter von Hand gedreht werden können, sind beim Halter links durch rote Motoren ersetzt worden.

Quelle: Lea Richtmann

langwierige Arbeit abgenommen und damit der Arbeitsalltag verbessert werden kann. Es wäre wünschenswert, wenn wir die dadurch verbesserten Möglichkeiten, unsere Forschung mit Hilfe von Machine Learning noch effizienter zu gestalten, dazu nutzen, den eng getakteten wissenschaftlichen Arbeitsalltag zum Wohle entspannter Kreativität zu entschleunigen.

Das nächste Beispiel eines interdisziplinären Forschungsansatzes zeigt eine enge Kooperation zweier Institute der Fakultät für Maschinenbau mit dem Ziel Semi-Supervised Machine Learning Ansätze für zukünftige Herausforderungen unter anderem in der Quantenforschung zu nutzen. Hier arbeiten das Institut für Mikroproduktionstechnik (IMPT) sowie das Institut für Transport- und Automatisierungstechnik (ITA) zusammen, diese Methoden zum Einsatz zu bringen.

Der Schwerpunkt der Forschungsaktivitäten am IMPT untergliedert sich thematisch in den Bereich „Quantentechnologien“ für die Erforschung mikro- und nanotechnolo-

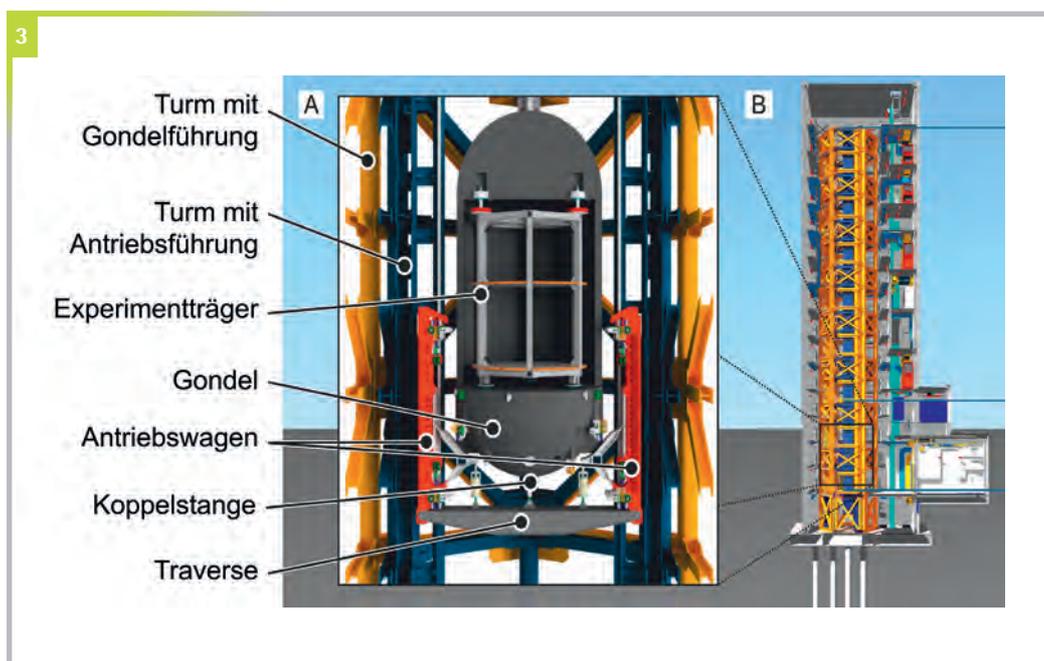
gisch gefertigter Quantensysteme und optischer Systeme sowie in den Bereich der „Mikro- und Nanointegration“. Letzterer beschäftigt sich mit innovativen Sensor- und Aktortechnologien, Sensorsystemen, der Magnetik, Aufbau- und Verbindungstechnik und Mikrotribologie. Die Entwicklungsstufen reichen vom Schichtsystem auf Chiplevel bis zum funktionsfertigen, eingebetteten und vernetzten System. Innerhalb der Embedded Systems Gruppe werden unter anderem KI-Anwendungen mit der dazugehörigen Messdatenerfassung und -aufbereitung für beispielsweise intelligente Sensorknoten erforscht und entwickelt.

Das ITA beschäftigt sich am HITec mit maschinenbaulichen und, im Speziellen, produktionstechnischen Fragen, die im Weltraum angewendet werden sollen. Dazu wird der Einstein-Elevator genutzt, der eine neuartige Fallturmanlage der dritten Generation darstellt (siehe Abb. 3). Mit diesem ist es möglich, Mikrogravitation (Schwerelosigkeit, 10^{-6} g) und Gravitationsbedingungen zwischen 0,1 g und 5 g zu simulieren.

Um die Gesamtanlage Einstein-Elevator und damit auch die Qualität der simulierten Gravitation, die für die hochpräzisen Quantenexperimente notwendig ist, zu überwachen, werden mehrere Sensoren und Messeinheiten verwendet. Insbesondere schleichende Veränderungen, die durch Alterung und beginnenden Verschleiß entstehen, sollen detektiert werden, um die Qualität der Versuche auch in Zukunft zu gewährleisten. Dazu eignet sich vor allem der Beschleunigungssensor, der sich außerhalb an der Gondel des Einstein-Elevators befindet. Dieser zeichnet nicht nur Beschleunigungen, sondern auch Schwingungen der Umgebung auf.

Die Frequenzen aller aufgenommenen Schwingungen lassen sich durch eine Transformation der Beschleunigungsdaten der Sensoren abbilden. Mit der Kurzzeit-Fourier-Transformation (FFT) ist es möglich, die Frequenzen im zeitlichen Verlauf darzustellen. Aus Datenpunkten der Sensoren entstehen somit Bilder/Spektrogramme, die für die Anwendung von Neuronalen Netzen genutzt werden können (siehe Abb. 4).

Abbildung 3
Aufbau des Einstein-Elevators
Quelle: Christoph Lotz

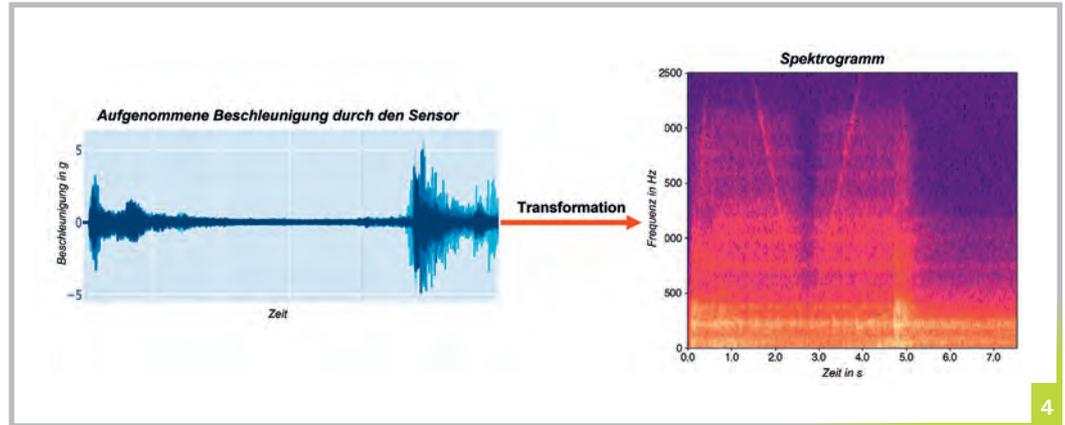


In einer neuartigen Anlage wie dem Einstein-Elevator ist davon auszugehen, dass die bereits aufgenommenen Daten keinen Verschleiß beinhalten. Durch eine solche Voreinteilung der Daten ist eine Einordnung des Ansatzes im Semi-Supervised Machine Learning möglich. Langfristig werden jedoch Verschleiß oder andere Veränderungen im System auftreten. Um im schlimmsten Fall einen Totalausfall der Anlage zu vermeiden, sollen als erstes Ziel etwaige Veränderungen durch das Neuronale Netz detektiert und beobachtet werden. Langfristig sollen auch die Ursachen identifiziert werden können.

Als erster Überwachungsansatz wurde daher ein Convolutional Autoencoder (CAE) entwickelt. Ziel des CAEs ist es, jedes Eingangsbild aus dem optimalen Zustand bestmöglich nachzukonstruieren. Weisen die Bilder Unterschiede auf, ist davon auszugehen, dass Anomalien im Datensatz (beispielsweise Verschleiß) vorhanden sind. In diesem Zusammenhang wurden bereits erste erfolgreiche Untersuchungen vom ITA und dem IMPT durchgeführt. Hierfür wurden zunächst künstliche Spektrogramme erzeugt, die im Gegensatz zu den Originalspektrogrammen Anomalien beinhalten. Diese konnten erfolgreich detektiert werden.

Auch Veränderungen, die durch die Beschallung des Einstein-Elevators mithilfe einer Lautsprecheranlage erzeugt wurden, konnten mithilfe des CAEs detektiert werden (siehe Abb. 5). Wie in den beiden Abbildungen zu sehen ist, wurden die anomalen Daten durch das Neuronale Netz nicht rekonstruiert, wodurch der Rekonstruktionsfehler im Vergleich zu den normalen Daten größer war. Dies ist im Differenzbild erkennbar (siehe Abb. 5 unten).

Kurzfristig sollen weitere Versuche erfolgen und das Condition-Monitoring Modell durch verschiedene Ansätze, wie beispielsweise der Data Augmentation, verbessert werden. Des Weiteren sollen die aus diesen Versuchen resultierende Erfahrung und Expertise auch für zukünftige Projekte, die einen Bezug zur KI benötigen, angewendet werden. Für das IMPT helfen die gesammelten Erkenntnisse, um eine effizientere Datenauswertung, -analyse sowie -aufbereitung selbst hergestellter Sensorik und entwickelter Sensorsysteme durchführen zu können. So ist Sensorik beispielsweise vereinfacht kalibrierbar und



4

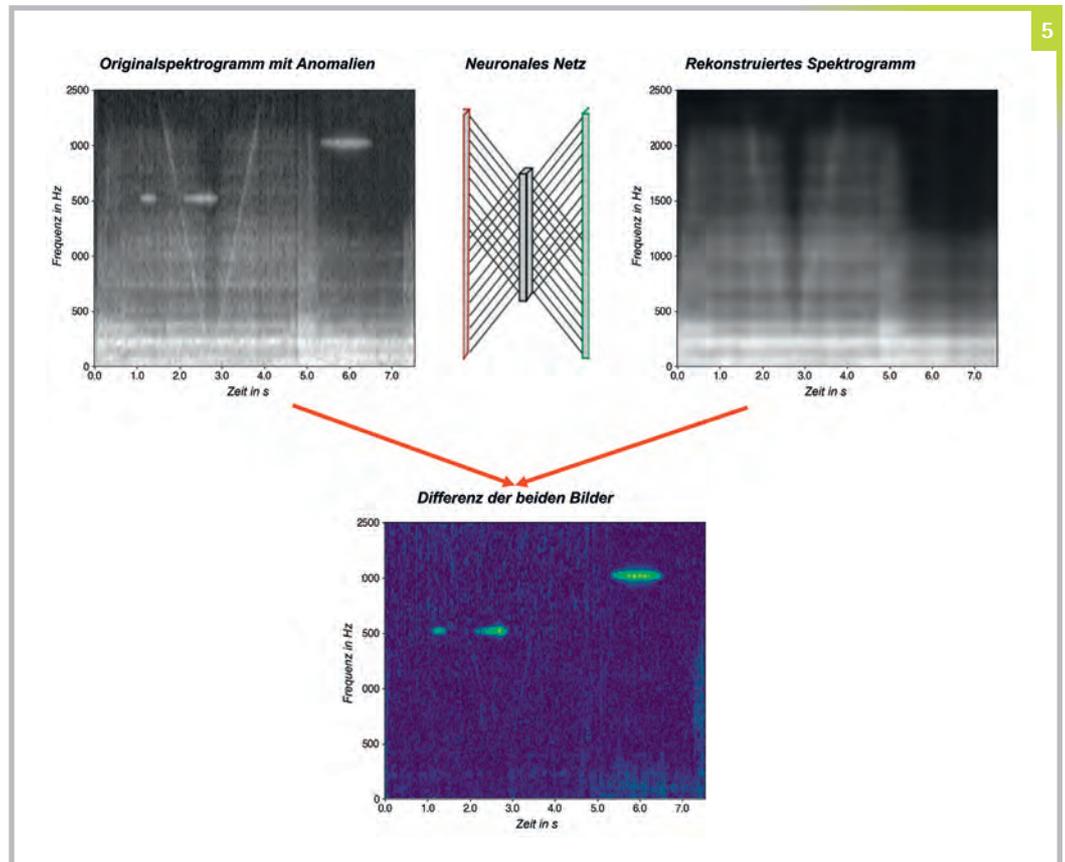
zukünftig eine Signaldrift vereinfacht erkennen- und kompensierbar.

Neuartige Ansätze und Techniken des maschinellen Lernens beginnen erst seit Kurzem den Arbeitsalltag zu durchdringen; aber schon jetzt zeigen sichtbare Resultate, dass die tägliche Arbeit

im Labor von den neuen Entwicklungen profitiert. Künftige Entwicklungen dieses spannenden Forschungszweiges werden weitere Projekte ermutigen, Algorithmen des Maschinellen Lernens in den Arbeitsalltag einzusetzen – natürlich da, wo es sinnvoll ist und die Arbeitsabläufe davon profitieren.

Abbildung 4
Die aufgenommenen Beschleunigungen werden transformiert, sodass die unterschiedlichen Frequenzen und ihre Intensitäten sichtbar werden.
Quelle: Emre Tahtali

Abbildung 5
Anomalien werden vom neuronalen Netz nicht rekonstruiert. Im Differenz-Bild sind diese hervorgehoben.
Quelle: Emre Tahtali



5

Auf dem Bild zu sehen sind, von links nach rechts: Marco Adamscheck, M.Sc., Dr. Alexander Wanner, Prof. Dr. Michèle Heurs, Emre Tahtali, M.Sc., Dr.-Ing. Daniel Klaas, Lea Richtmann, M.Sc., Dr.-Ing. Christoph Lotz.
Foto: Jan Raffel/ITA



Emre Tahtali

ist seit 2022 Wissenschaftlicher Mitarbeiter des Instituts für Transport- und Automatisierungstechnik (ITA) in der Gruppe Production in Space. Seine Arbeitsschwerpunkte liegen im Bereich der Simulation von Gravitationen kosmischer Kleinkörper und des Condition-Monitorings am Einstein-Elevator. Kontakt: emre.tahtali@ita.uni-hannover.de

Dr.-Ing. Christoph Lotz

wurde 2021 promoviert und leitet seit 2022 die Arbeitsgruppe Production in Space im ITA. Seine Schwerpunkte sind Produktionsverfahren unter verschiedenen Gravitationsbedingungen, neuartige Sensorsysteme, die Lehre im Bereich von Space Technologies sowie das Management der Projekte im Einstein-Elevator. Kontakt: christoph.lotz@ita.uni-hannover.de

Lea Richtmann

ist seit 2022 Wissenschaftliche Mitarbeiterin des Instituts für Gravitationsphysik in der Gruppe Quantum Control. Sie forscht an der Anwendung von Machine Learning Techniken, insbesondere Reinforcement Learning, für die experimentelle Quantenoptik. Kontakt: lea.richtmann@aei.uni-hannover.de

Dr.-Ing. Daniel Klaas

ist seit 2022 Gruppenleiter der Arbeitsgruppe „Embedded Systems“ am IMPT. Zu seinen Forschungsschwerpunkten zählen unter anderem die Entwicklung eingebetteter Sensorsysteme, Edge-KI-Anwendungen, die Datenanalyse und -verarbeitung sowie neuartige Sensortechnologien. Kontakt: klaas@impt.uni-hannover.de

Dr. Alexander Wanner

ist seit 2013 als Geschäftsführer der QUEST-Leibniz-Forschungsschule unter anderem für den Betrieb des HITec-Gebäudes verantwortlich, war in der ersten Förderphase Geschäftsführer des Sonderforschungsbereichs 1227 DQ-mat (2016-2020) und ist seit 2019 für die Koordination des Exzellenzclusters 2123 QuantumFrontiers zuständig. Kontakt: alexander.wanner@quest.uni-hannover.de

Prof. Dr. Michèle Heurs

ist Professorin am Institut für Gravitationsphysik und leitet dort die Arbeitsgruppe „Quantum Control“, die sich mit Systemen beschäftigt, die Rauschen am oder unterhalb des Quantenlimits aufweisen. Sie ist PI bei den Exzellenzclustern „QuantumFrontiers“ und „PhoenixD“ und Direktorin der QUEST Leibniz Forschungsschule. Kontakt: michele.heurs@aei.uni-hannover.de

Marco Adamscheck

ist seit 2023 wissenschaftlicher Mitarbeiter am Institut für Mikroproduktionstechnik in der Gruppe „Embedded Systems“. Seine Arbeitsschwerpunkt liegen im Bereich eingebetteter Sensorsysteme, Edge-KI-Anwendungen, Datenanalyse und -verarbeitung, Energy Harvesting sowie Magnetismus. Kontakt: adamscheck@impt.uni-hannover.de