

# Sichere Mensch-Maschine-Kollaboration

## Deep Reinforcement Learning

Im Zeitalter zunehmender Automatisierung und Digitalisierung, Industrie 4.0, Produktindividualisierung und globaler Vernetzung müssen auch Mensch und Maschine immer enger zusammenarbeiten, um die optimale Produktivität der Produktionsprozesse zu garantieren. Je nach Anwendungsbereich können Mensch und Roboter unterschiedlich eng zusammenarbeiten. Auch wenn der Begriff „Mensch-Roboter-Kollaboration (MRK)“ geläufig ist, kann das „K“ in MRK für verschiedene Ausprägungen der Zusammenarbeit stehen.

Michael Kempf

Bei der Mensch-Roboter-Kooperation arbeiten Mensch und Roboter im gleichen Arbeitsraum. Sie bearbeiten zeitversetzt unterschiedliche Aufgaben eines Prozesses. Es findet keine direkte Interaktion statt.

Bei der Kollaboration interagieren Mensch und Roboter in einem gemeinsamen Arbeitsraum miteinander. Beispielsweise reicht der Roboter dem Menschen etwas an oder beide führen gleichzeitig unterschiedliche Aufgaben am selben Bauteil durch.

### Herausforderungen bei der Mensch-Roboter-Kollaboration

Bei der Kollaboration von Mensch und Roboter muss gewährleistet sein, dass jede Interaktion absolut sicher ist, das heißt der Mensch zu keiner Zeit einer Gefährdung ausgesetzt ist. Mit der steigenden Effizienz moderner Methoden aus dem Bereich der

Künstlichen Intelligenz (KI), insbesondere im Teilgebiet des Maschinellen Lernens, werden diese Verfahren auch vermehrt im Umfeld der Produktion eingesetzt. Deep-Reinforcement-Lernalgorithmen versetzen Roboter in die Lage, Sicherheitsstrategien innerhalb einer Simulationsumgebung nach dem Prinzip der Belohnung und Bestrafung zu lernen. Wegen ihres enormen Potenzials für die Mensch-Maschine Kollaboration wird in diesem Bereich derzeit viel Forschung betrieben.

### Maschinelles Lernen durch Belohnung

Deep Reinforcement Learning ist eine Methode aus dem Bereich des Maschinellen Lernens, bei der ein Agent selbständig eine Strategie erlernt, um erhaltene Belohnungen zu maximieren. Dabei wird dem Agenten nicht vorgegeben, welche Aktion in welcher Situation die beste ist, sondern er er-

hält zu bestimmten Zeitpunkten eine Belohnung, die auch negativ sein kann (Bestrafung). Anhand dieser Belohnungen wird versucht, eine Nutzenfunktion zu maximieren, die beschreibt, welchen Wert ein bestimmter Zustand oder eine Aktion hat.

Die Begriffe „Agent“, „Beobachtung“, „Umgebung“, „Aktion“ und „Belohnung“ sind hierbei von zentraler Bedeutung. Sie lassen sich folgendermaßen definieren (Bild 1): Der Agent entscheidet, welche Aktionen auszuführen sind, auf Basis der Belohnung und den Beobachtungen. Der Roboter ist hierbei der Agent.

Eine Beobachtung ist eine Information aus der Umgebung, die an den Agenten übermittelt wird. Die Geschwindigkeit des Greifers, die Position des Greifers oder die Position des Hindernisses sind Beispiele für Beobachtungen.

Die Umgebung wird durch die Aktionen des Agenten beeinflusst und generiert Beobachtungen sowie eine Belohnung für den Agenten. Alle relevanten Informationen aus dem Anwendungsbereich bilden die Umgebung.

Eine Aktion wird vom Agenten ausgeführt und ändert den Zustand der Umgebung. Beispielsweise ist die Bewegung des Greifers eine Aktion.

Die Belohnung wird dem Agenten rückgemeldet und besagt, wie gut der Agent in diesem Schritt ist. Die Belohnung wird an

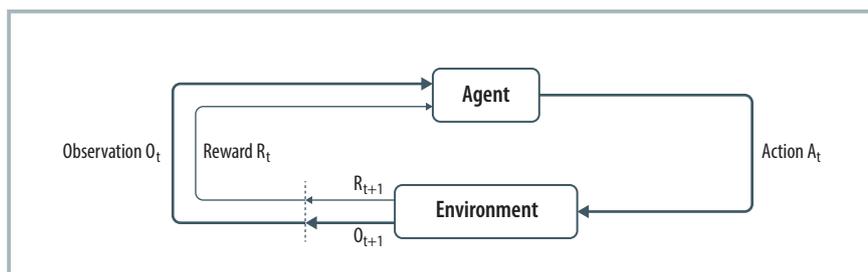


Bild 1. Die Interaktionen zwischen dem Agent und der Umgebung bei einem Reinforcement-Learning-

Ansatz Quelle: Zhongyi Ye, © Hanser

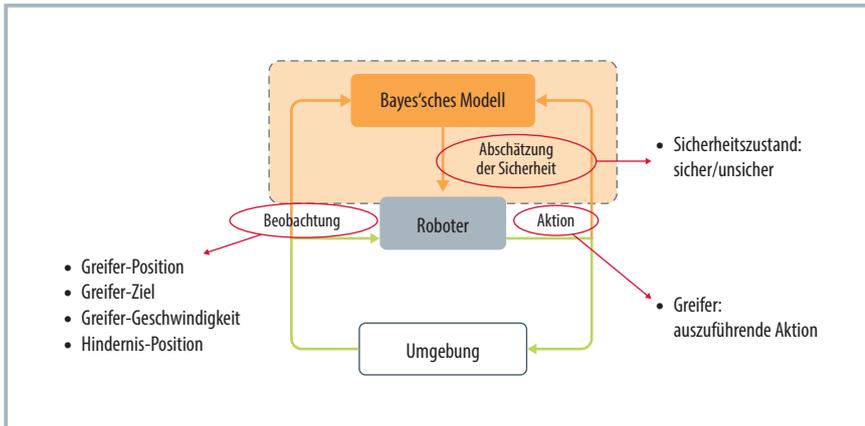


Bild 2. Validierung des Reinforcement-Lernverfahrens mit Hilfe Bayes'scher Modelle

Quelle: Zhongyi Ye, © Hanser

den Agenten übermittelt. Es sei noch ausdrücklich darauf hingewiesen, dass der Reinforcement-Learning-Ansatz zur Kollisionsvermeidung nur in einer Simulationsumgebung stattfindet.

### Bayes'sche Modelle validieren Lernverfahren

Der Reinforcement-Lernalgorithmus gehört der Klasse der Künstlichen Neuronale Netze (KNN) an. Da solche Netze zu den Black-Box-Algorithmen gehören, ist es wichtig, deren Ergebnisse in geeigneter Form zu bestätigen bzw. zu validieren.

Bayes'sche Netze stellen einen Formalismus zum Schließen bei unsicherem Wissen dar. Sie bestehen aus einem gerichteten azyklischen Graph, in dem die Knoten Variablen und die Kanten Abhängigkeiten zwischen diesen Knoten repräsentieren. Diese Abhängigkeiten werden mit Wahrscheinlichkeitswerten quantifiziert.

Bayes'sche Netze mit einem Vorgängerknoten, der Wurzel, sowie Nachfolgerkno-

ten werden zur Klassifikation benutzt. Man nennt sie deshalb auch Bayes'sche Klassifikatoren. Hierbei stellen die Wurzel die Klassifikationsvariable und die Nachfolger die Attribute dar. Im vorliegenden Anwendungsfall soll versucht werden, zu bewerten, ob die aktuelle Aktion des Roboters sicher oder unsicher ist. Es wird also bewertet, wie wahrscheinlich das Risiko einer Kollision des Roboters mit einem Hindernis ist.

In Bild 2 ist das Prinzip der Validierung des Lernverfahrens dargestellt. Es wird klassifiziert, ob durch die aktuell nächste geplante Aktion des Roboters mit hoher Wahrscheinlichkeit ein sicherer Zustand gewährleistet ist. Die Attribute sind hierbei alle Beobachtungen, die vom Roboter auszuführende Aktion sowie weitere Größen aus der Umgebung.

Es wurden drei Bayes'sche Modelle zur Validierung benutzt: der sogenannte naive Bayes'sche Klassifikator, der Tree Augmented Naive (TAN) Bayes'sche Klassifikator und ein Bayes'sches neuronales Netz. Diese

werden im Folgenden bewertet und miteinander verglichen. Bild 3 zeigt beispielhaft den naiven Bayes'schen Klassifikator und das Bayes'sche neuronale Netz.

### Ergebnisse und deren Bewertung

Die verschiedenen Modelle wurden mit Hilfe verschiedener Performance-Metriken bewertet und verglichen. Tabelle 1 ist zu entnehmen, dass das Bayes'sche neuronale Netz die höchste Genauigkeit erzielt, allerdings über zwanzig Minuten für das Lernen des Modells benötigt. Die beiden Bayes'schen Klassifikatoren lassen sich in weniger als einer Sekunde bzw. in wenigen Sekunden lernen, sind jedoch in der Vorhersagegenauigkeit schwächer als das neuronale Netz.

Tabelle 1 zeigt die Ergebnisse für ein statisches Hindernis. Da sich der Mensch bei seinen Tätigkeiten im Allgemeinen bewegt, sind die Aussagen nur von be- »»

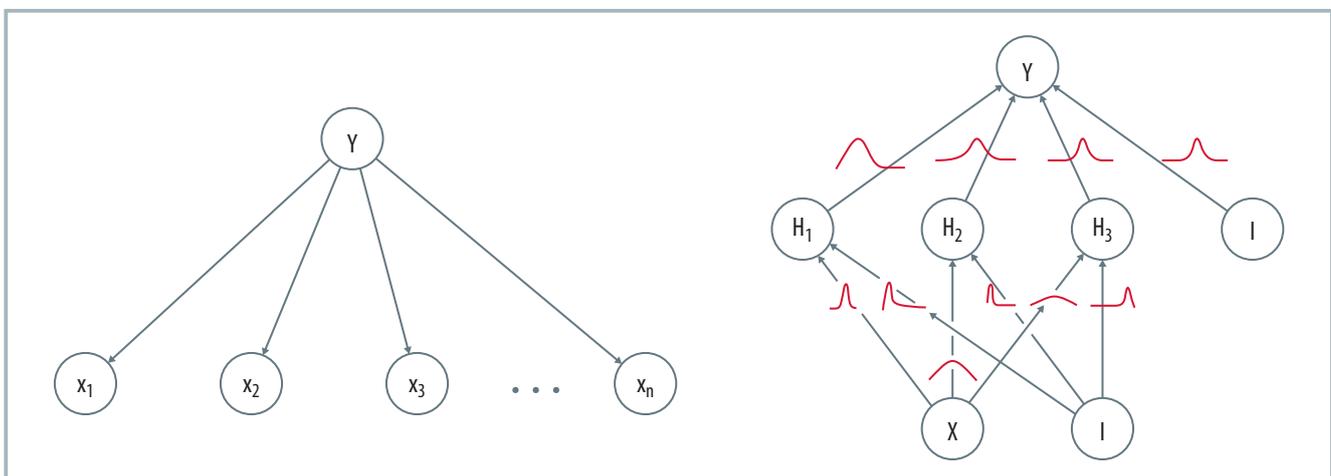


Bild 3. Der naive Bayes'sche Klassifikator (links) sowie das Bayes'sche neuronale Netz (rechts) Quelle: Zhongyi Ye, © Hanser

### INFORMATION & SERVICE

#### AUTOR

Michael Kempf ist wissenschaftlicher Mitarbeiter am Fraunhofer-Institut für Produktionstechnik und Automatisierung IPA, Stuttgart, in der Gruppe für Qualitäts- und Zuverlässigkeitsmanagement. Seine Forschungsschwerpunkte sind statistische Methoden in den Bereichen Prozessoptimierung, Zuverlässigkeitsanalyse und Risikominimierung. Sein Spezialgebiet sind die Bayes'schen Modelle.

#### KONTAKT

Michael Kempf  
T 0711 970-1836, F 0711 970-3606  
michael.kempf@ipa.fraunhofer.de

grenztem Nutzen. Tabelle 2 vergleicht die Ergebnisse mit denen bei einem dynamischen Hindernis, was der realen Situation sehr viel näher kommt.

Es zeigt sich, dass die Ergebnisse bei dem dynamischen Hindernis nur unwesentlich schlechter sind.

### Weitere Forschungen erforderlich

Bis die oben beschriebenen Ansätze eine kollisionsfreie Zusammenarbeit zwischen Mensch und Maschine garantieren können, bedarf es noch Forschungsarbeit.

Der Reinforcement-Learning-Ansatz funktioniert bisher nur in der Simulation und noch nicht an einem realen Roboter.

Modell	Trainingszeit	Genauigkeit (statisch)
naive Bayes	0,3931 s	75,2 %
TAN	37,382 s	76,48 %
BNN	1372,42 s	85 %

Tabelle 1. Ergebnisse der drei Validierungsmodelle für ein statisches Hindernis

Quelle: Zhongyi Ye, © Hanser

Die entwickelten Methoden zur Validierung geben bisher lediglich eine Sicherheitswahrscheinlichkeit für einen risikolosen Zustand an und müssen deshalb wei-

Modell	Genauigkeit (statisch)	Genauigkeit (dynamisch)
naive Bayes	75,2 %	74,38 %
TAN	76,48 %	73,62 %
BNN	85 %	83 %

Tabelle 2. Ergebnisse der drei Validierungsmodelle für ein dynamisches Hindernis

Quelle: Zhongyi Ye, © Hanser

terentwickelt werden. Die Forschungsansätze sind auf jeden Fall ein Schritt in die richtige Richtung und sollten weiterverfolgt und optimiert werden. ■

## 1. DGQ-Thementag Digitalisierung – wohin geht die Zukunft der Qualitätssicherung?

„Ist die klassische Qualitätssicherung ein analoges Auslaufmodell?“ lautete das Motto des DGQ-Thementags Digitalisierung, der am 12. November 2020 seine Premiere feierte. Aufgrund der aktuellen Pandemie-Situation entschied man sich dafür, die Veranstaltung online durchzuführen. Und das mit Erfolg: Die Organisatoren konnten sich über knapp 250 Teilnehmer freuen, die sich mit Fragen, Kommentaren und Diskussionsbeiträgen in das Programm einbrachten.

„DIE DGQ BIETET MITTLERWEILE zahlreiche gut besuchte Webinare an. Eine Online-Veranstaltung dieser Größe haben wir bislang jedoch noch nicht durchgeführt. Deswegen freuen wir uns besonders, dass so viele Qualitätsbegeisterte unserer Einladung zum Thementag gefolgt sind,“ resümierte Timo Hillenbrand, Projektleiter des DGQ-Thementags Digitalisierung.

Das Herzstück der Veranstaltung bildete eine Podiumsdiskussion. Experten aus Wissenschaft und Praxis diskutierten über die Frage, ob die Künstliche Intelligenz (KI) in Zukunft den Menschen



als Hauptakteur in der Qualitätssicherung (QS) ersetzt wird. Obwohl diese Fragestellung im Rahmen der Veranstaltung nicht erschöpfend behandelt werden konnte, kristallisierte sich doch ein Ergebnis heraus: Die Digitalisierung und im Speziellen die KI wird den Menschen nicht ersetzen, sondern vielmehr bei seinen Aufgaben unterstützen. Gleichzeitig entwickeln sich – nach Ansicht von Experten und Teilnehmern – hierdurch neue Aufgabenschwerpunkte für Mitarbeiter in QM und QS.

### Ansprechender Themen-Mix

Neben der Podiumsdiskussion fanden verschiedene Impuls-Webinare zu Themen wie Predictive Quality, digitales Lieferkettenmanagement oder Einsatz von Smart Glasses im Produktionsprozess statt. Dabei konnten sich die Teilnehmer durch Fragen und Beiträge mit in die Diskussion einbringen. Hierdurch entstand ein ansprechender Mix aus fachlichem Input und Praxisbezug. Entsprechend positiv fiel das Feedback aus: Vielen der Anwesenden gab der DGQ-Thementag Digitalisierung hilfreiche Unterstützung bei ihren nächsten Schritten auf dem Weg zu einer Digitalisierung von QM und QS.

Gestützt auf diese positiven Feedbacks und Erfahrungen plant die DGQ, auch in Zukunft ihr Angebot an digitalen (Groß-)Veranstaltungen weiter auszubauen. „Die positiven Rückmeldungen der Teilnehmer sowie die Qualität und Inhaltsdichte des DGQ-Thementags Digitalisierung haben gezeigt, dass digitale Veranstaltungen ein enormes Potenzial bieten, um viele Menschen zu einem Thema zusammenzubringen und gemeinsam an Ideen und Lösungen zu arbeiten,“ erklärte Dr. Antje Becker, Geschäftsführerin der DGQ. „Aus diesem Grund werden wir auch als DGQ hier weitere Schritte gehen und die Nutzung digitaler Formate in unserem Netzwerk weiter ausbauen.“

Man darf also mit Spannung auf die kommenden Entwicklungen blicken. Wer sich bis dahin über die aktuellen digitalen Angebote der Deutschen Gesellschaft für Qualität informieren möchte, findet im Internet unter [www.dgq.de](http://www.dgq.de) weitere Informationen und Anregungen.