

Industrielles Transfer-Lernen

Von der Wissenschaft in die Praxis

Benjamin Maschler, Institut für Automatisierungstechnik und Softwaresysteme, Universität Stuttgart

Hasan Tercan*, Lehrstuhl für Technologien und Management der Digitalen Transformation, Bergische Universität Wuppertal

Christian Bitter*, Lehrstuhl für Technologien und Management der Digitalen Transformation, Bergische Universität Wuppertal

Hannes Vietz*, Institut für Automatisierungstechnik und Softwaresysteme, Universität Stuttgart

Tobias Meisen, Lehrstuhl für Technologien und Management der Digitalen Transformation, Bergische Universität Wuppertal

Michael Weyrich, Institut für Automatisierungstechnik und Softwaresysteme, Universität Stuttgart

*Diese Autoren haben zu gleichen Teilen zu diesem Artikel beigetragen.

Kurzfassung: Trotz hoher Lösungspotentiale des maschinellen Lernens für gängige Probleme der Automatisierungstechnik, finden sich in der Praxis wenig Anwendungsbeispiele. Um der Ursache hierfür auf den Grund zu gehen, zeigen die Autoren anhand von vier beispielhaften Anwendungsfällen die Hürden für konventionelles maschinelles Lernen auf und benennen Lösungsansätze mittels industriellem Transfer-Lernen. Zum großflächigen Einsatz derartiger Ansätze, fehlt es an Voraussetzungen, deren Schaffung jedoch anders als beim konventionellen maschinellen Lernen grundsätzlich möglich ist. Der Artikel schließt mit einer Betrachtung dieser Voraussetzungen und macht Vorschläge, wie sie zu erfüllen sind.

Transfer-Lernen / Kontinuierliches Lernen / Industrielle Anwendung

Industrial Transfer Learning

Abstract: Despite the high solution potential of machine learning for common problems in automation technology, there are few examples of its application in practice. In order to find the reason for this phenomenon, the authors identify the hurdles for conventional machine learning using four exemplary use cases and name possible solutions via industrial transfer learning. There is a deficiency regarding preconditions for the large-scale use of such approaches, but unlike in conventional machine learning, it is principally possible to establish those. The article concludes with a discussion of these prerequisites and makes suggestions as to how they could be fulfilled.

Transfer Learning / Continual Learning / Industrial Application

In den letzten Jahren haben datengetriebene Methoden der künstlichen Intelligenz (KI) beeindruckende Erfolge erzielen können: Von der meisterhaften Beherrschung immer komplexerer Spiele über übermenschliche Spracherkennungs- und -synthese-Leistungen bis hin zur Bild- und Objekterkennung, bspw. von einzelnen Personen in großen Menschenmengen, scheint kaum etwas nicht automatisierbar. Auch für industrielle Anwendungsfälle wurden in wissenschaftlichen Veröffentlichungen immer neue, bahnbrechende Fortschritte vermeldet. Man könnte meinen, die autonome Fabrik sei zum Greifen nahe.

In der industriellen Praxis findet diese Entwicklung jedoch wenig Widerhall. Die produktive Nutzung von KI beschränkt sich bisher häufig auf Nischen und viele der theoretisch möglichen Anwendungen werden bisher nicht in der Breite realisiert.

Ziel dieses Beitrags ist es daher, Gründe für die zögerliche Nutzung von datengetriebener künstlicher Intelligenz zu beschreiben und mögliche Lösungsansätze auf Basis von Industrial Transfer Learning aufzuzeigen. Die dazu verwendeten, anwendungsnahen Beispiele sollen eine Übertragung in die Praxis erleichtern.

1 Herausforderungen: KI-basierte Produktionsautomatisierung

Das Grundprinzip datenbasierter KI ist es, mittels mathematischer Verfahren automatisiert Muster in Datensätzen zu erkennen. Diese Muster können dann als abstraktes Modell verstanden und genutzt werden, bspw. um das Systemverhalten unter veränderten Umgebungsbedingungen simulativ zu „erproben“. Zentrale Voraussetzung für die Nutzbarkeit eines solchen Modells ist, dass dessen Vorhersagen präzise genug sind. Dies hängt zu einem wesentlichen Teil von den verwendeten Daten ab, die bspw. ausreichend vielfältig sein müssen, so dass ein Algorithmus beschreibende und allgemein gültige Muster in ihnen finden kann.

Aktuelle Arbeiten basieren sehr häufig auf künstlichen neuronalen Netzen, die ausgehend von der Annahme, eines repräsentativen großen Datensatz eines Anwendungsfalls, trainiert werden. Diese Annahme ist jedoch in der industriellen Produktion oft nicht gültig:

Zum einen ist die Beschaffung einer ausreichenden Datenbasis problematisch (siehe Bild 1, Buchstabe A). Die in der industriellen Produktion genutzten Anlagen und Prozesse zeichnen sich durch eine hohe Vielfalt bei kleiner Stückzahl aus. Es stehen damit typischerweise nur wenige Quellen für einen Datensatz zur Verfügung. Diese Zahl wird weiter reduziert durch geringe Kooperationsbereitschaft, bspw. aus rechtlichen oder wettbewerblichen Gründen, sowie sicherheitstechnische Bedenken und technische Inkompatibilitäten [1]. Hinzu kommt, dass die minimal benötigte Datenmenge meist nicht bekannt ist.

Zum anderen zeichnen sich eine Vielzahl industrieller Prozesse durch eine hohe Dynamik aus (siehe Bild 1, Buchstabe B). Gründe dafür sind u.a. sinkende Stückzahlen und damit verbunden häufigere Produktwechsel, Anlagenverschleiß, wechselnde Umgebungsbedingungen oder auch Rohstoff- bzw. Halbezeugeigenschaften. Einmal erstellte, zu diesem Zeitpunkt ausreichend gute Datensätze verlieren also gemeinsam mit den damit trainierten Algorithmen mit der Zeit ihre Gültigkeit, weil der betrachtete Prozess sich von ihnen weg entwickelt [2, 3]. Ab wann sich

Prozess und Datensatz zu sehr unterscheiden, ist ebenfalls meistens nicht bekannt.

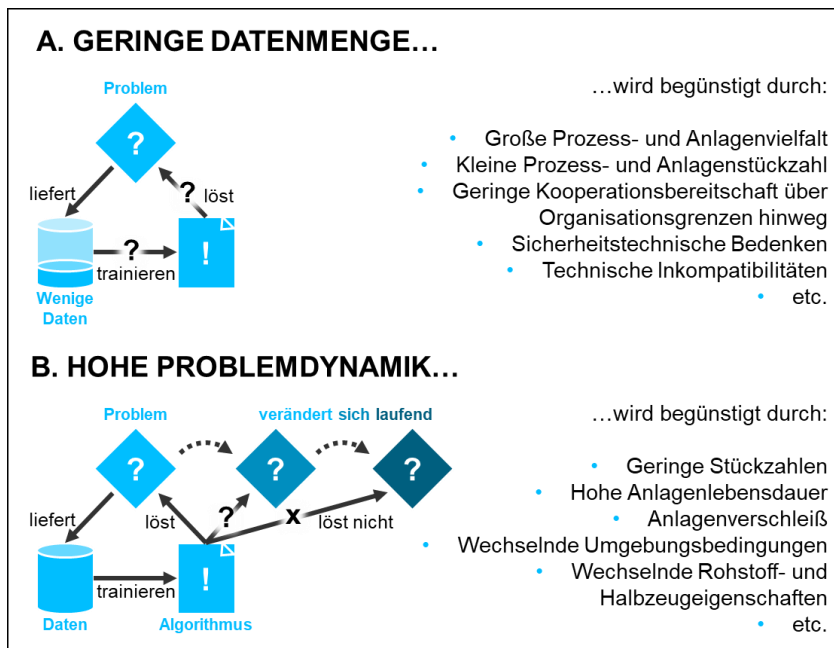


Bild 1: Herausforderungen für datenbasierte KI-Ansätze in der Produktionsautomatisierung

Diese Herausforderungen erschweren eine breitere, praktische Nutzung von datenbasierten KI-Ansätzen in der Produktionsautomatisierung. Die nachfolgenden Beispiele dienen der detaillierten Veranschaulichung dieser Problematiken.

1.1 Szenario 1: Selbstlernende Roboter

Die Automatisierung von Fügeprozessen durch Roboter erfordert eine präzise Führung von Bauteilen entlang einer Trajektorie. Reinforcement Learning bietet das Potential, Regelstrategien für dynamische Umgebungen, in denen beispielsweise die Position der Bauteile stark variiert, zu erlernen [4, 5]. Reinforcement Learning ist ein Lernparadigma des maschinellen Lernens, welches zum Ziel hat, einen KI-Agenten zur Lösung einer bestimmten Problemstellung zu trainieren. Unter einem KI-Agenten ist in diesem Kontext ein lernendes System zu verstehen (z.B. in Form eines künstlichen neuronalen Netzes), welches selbständig eine Lösungsstrategie erlernt, ohne vorher explizit dafür programmiert worden zu sein. Das Training des Agenten erfolgt dabei in Trial-and-Error Manier durch das Ausprobieren verschiedenster Lösungsmöglichkeiten.

Eine zentrale Herausforderung im Einsatz solcher Agenten ist daher, dass diese Erfahrungen sammeln müssen, um ein Verständnis der Aufgabe aufzubauen und anschließend hieraus Lösungswege abzuleiten. Die benötigte Erfahrung, in Form von tausenden von Iterationen, sind zeit- und kostenintensiv, sodass ein Training an realen Robotern meist nicht durchführbar ist. Darüber hinaus muss ein Reinforcement Learning Agent auch negative Erfahrungen sammeln können, was im Kontext der Robotik Kollisionen mit potentieller Beschädigung von Hardware bedeutet.

Um sowohl Zeit zu sparen als auch Sach- und ggf. Personenschäden zu vermeiden, bieten Simulationen eine kostengünstige Alternative zur

Sammlung von Erfahrungen. Eine große Herausforderung hierbei ist jedoch, dass sich Simulationen aufgrund von Abweichungen zu realen Prozessen (der sogenannten Simulation-to-Reality-Lücke) nur bedingt für das Training von Agenten eignen (siehe Bild 2).

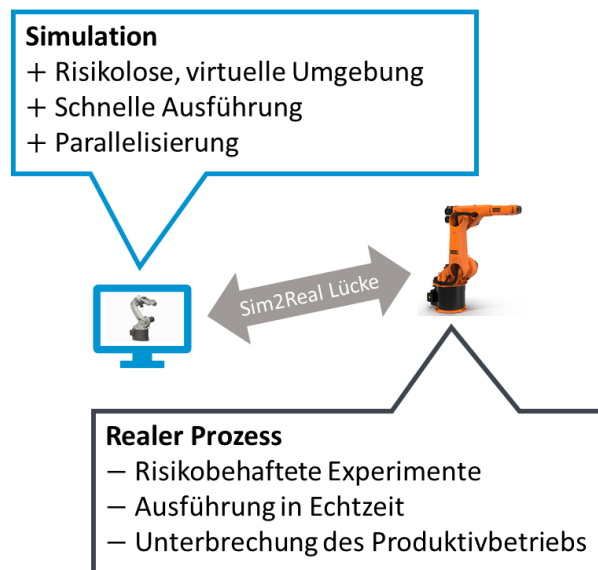


Bild 2: Vorteile von Simulationen für die Entwicklung von Reinforcement Learning Agenten gegenüber einem Training im realen Prozess.

1.2 Szenario 2: Verschleißvorhersage

Der rechtzeitige, also weder zu späte noch zu frühe, Austausch verschlissener Komponenten kann Ausfälle vermeiden und entsprechend Ausgaben reduzieren, erfordert jedoch eine präzise Vorhersage des optimalen Zeitpunkts. Datengetriebenes maschinelles Lernen bietet das Potential, auf die jeweils vorliegenden Einsatzbedingungen angepasste Verschleißvorhersagen für Predictive Maintenance zu ermöglichen, ohne dass man die physikalischen Zusammenhänge verstehen und modellieren muss.

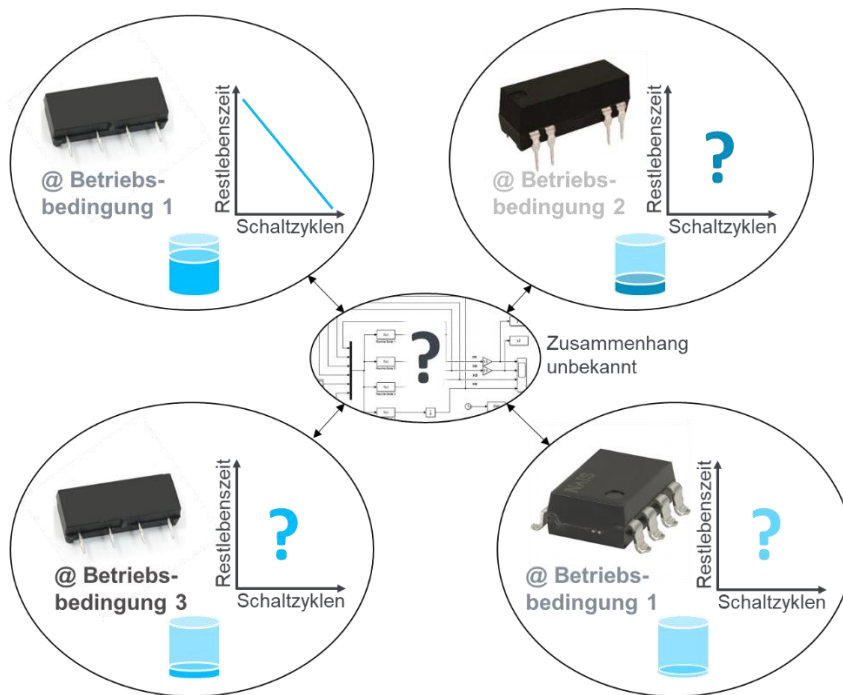


Bild 3: Fehlen ausreichend spezifischer physikalischer Modelle als Problem der datenbasierten Verschleißvorhersage

Voraussetzung dafür sind große Mengen vielfältiger, passgenauer und gelabelter Trainingsdaten, die somit möglichst für die vorliegenden Einsatzbedingungen auch Komponentenausfälle enthalten sollten. Diese Bedingungen sind in der Praxis jedoch schwer zu erfüllen: Aufgrund der hohen Kosten werden Ausfälle gerne vollständig vermieden und die Vielfalt an bspw. Anlagen, Herstellern und Einsatzbedingungen erschwert die Findung ähnlicher Szenarien selbst bei Standardkomponenten mit sehr hohen Stückzahlen (siehe Bild 3).

1.3 Szenario 3: Visuelle Objektdetektion

Für autonom agierende, fahrerlose Transportsysteme ist die korrekte Wahrnehmung der Umgebung essentiell. Insbesondere wenn sie ein gleichberechtigter Teil eines komplexen Produktionsumfeldes sind und nicht nur Zug-artig in ausgewiesenen Flächen operieren. Durch datengetriebenes maschinelles Lernen können Kameradaten dazu verwendet werden, ihre Umgebungen wahrzunehmen. Angefangen von einfacher Hindernisdetektion bis zur Lokalisierung und Trajektorienplanung existiert eine Vielzahl von Anwendungen, die auf visueller Objekterkennung basieren.

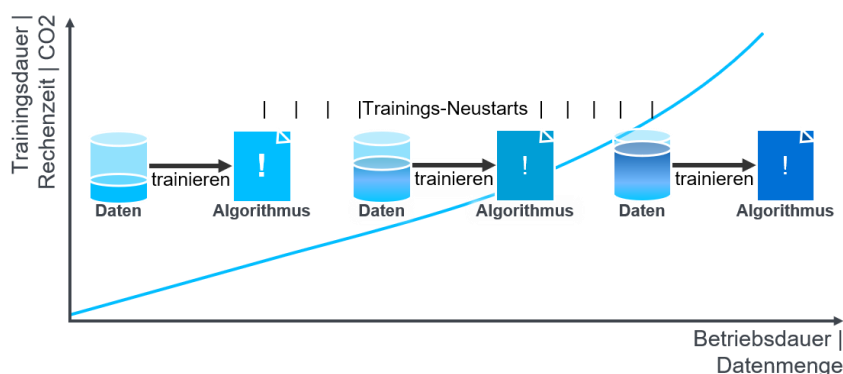


Bild 4: Über die Zeit stark ansteigender Trainingsaufwand als Problem der visuellen Objektdetektion

Moderne Produktionsumgebungen sind jedoch im stetigen Wandel. Eine trainierte KI muss sich der verändernden Umgebung anpassen und immer neu trainiert werden, um zuverlässig zu funktionieren. Durch die wachsende Datenmenge und neuen Trainingsdurchläufe steigen die Trainingskosten und der Energiebedarf über den Lebenszyklus einer KI immer weiter an (siehe Bild 4).

1.4 Szenario: Qualitätsvorhersage in der Fertigung

Die Vorhersage der finalen Produktqualität noch während der Produktion kann Ausschuss verringern oder über einen frühzeitigen Produktionsabbruch zumindest Zeit und Kosten sparen. Datengetriebenes Deep Learning bietet das Potential, auf die jeweils vorliegenden Einsatzbedingungen angepasste Qualitätsvorhersagen zu ermöglichen, ohne die physikalischen Zusammenhänge zu verstehen und modellieren zu müssen. Grundlage hierfür ist das Training neuronaler Netze auf einer repräsentativen Datenbasis bestehend aus historischen Prozess- und Qualitätsdaten.

Eine große Herausforderung besteht darin, dass Fertigungsprozesse kontinuierlichen Veränderungen unterliegen, wie z. B. der Herstellung neuer Produkte, sodass zuvor trainierte Modelle nicht mehr ausreichend genaue Vorhersagen liefern können. Infolgedessen müssen die Modelle stets auf neuen, im realen Umfeld sehr kostspieligen Beobachtungen trainiert werden, sobald sich die Prozesse ändern. Darüber hinaus tendieren künstliche neuronale Netze dazu, altes Wissen beim Lernen neuer Sachverhalte zu vergessen – ein Phänomen, welches Forscher auch „Catastrophic Forgetting“ nennen.

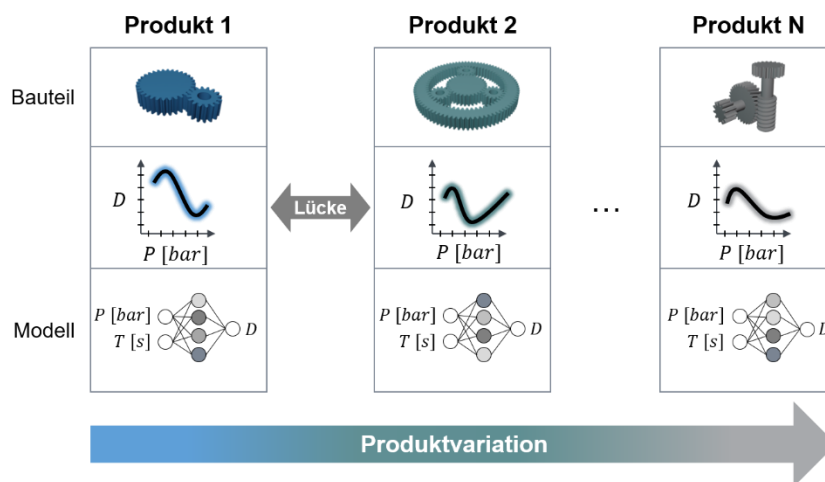


Bild 5: Predictive Quality im Spritzguss auf Basis der Maschinenparameter Druck und Zeit

2 Lösungsansätze: Wissenstransfer in der Produktion

Ein allgemeiner Lösungsansatz für die in Kapitel 1 beschriebenen Probleme datenbasierten KI in der Automatisierungstechnik ist der (Teil-)Aufgaben übergreifende Wissenstransfer. Hierdurch kann über verschiedene Szenarien hinweg ein vollständig(-er)-es Modell des zu lösenden Problems erstellt und immer wieder dynamisch ohne

vollständiges Neutrainieren angepasst werden. Tabelle 1 gibt einen Überblick über in diesem Zusammenhang relevante Begrifflichkeiten.

In der Wissenschaft wird diesbezüglich grundsätzlich zwischen zwei Lösungsfamilien unterschieden: Transfer Learning, das lediglich auf das bessere Lösen eines neuen Zielproblems abzielt, und Continual Learning, dass das Lösen eines neuen Zielproblems unter Beibehaltung der Lösungsfähigkeit bereits erlernter Quellprobleme zum Gegenstand hat (siehe Bild 6). In der Praxis stellt sich diese theoretische Unterteilung jedoch vielfach als unpassend heraus, da sowohl die Generalisierungsfähigkeiten des Continual Learnings als auch die Spezialisierungsfähigkeiten des Transfer Learnings notwendig sind, um aus verschiedenen Teilproblemen Allgemeingültiges heraus zu extrahieren und anschließend auf den vorliegenden Anwendungsfall anzupassen [6]. Der Überbegriff des Industrial Transfer Learnings soll dies auch sprachlich repräsentieren.

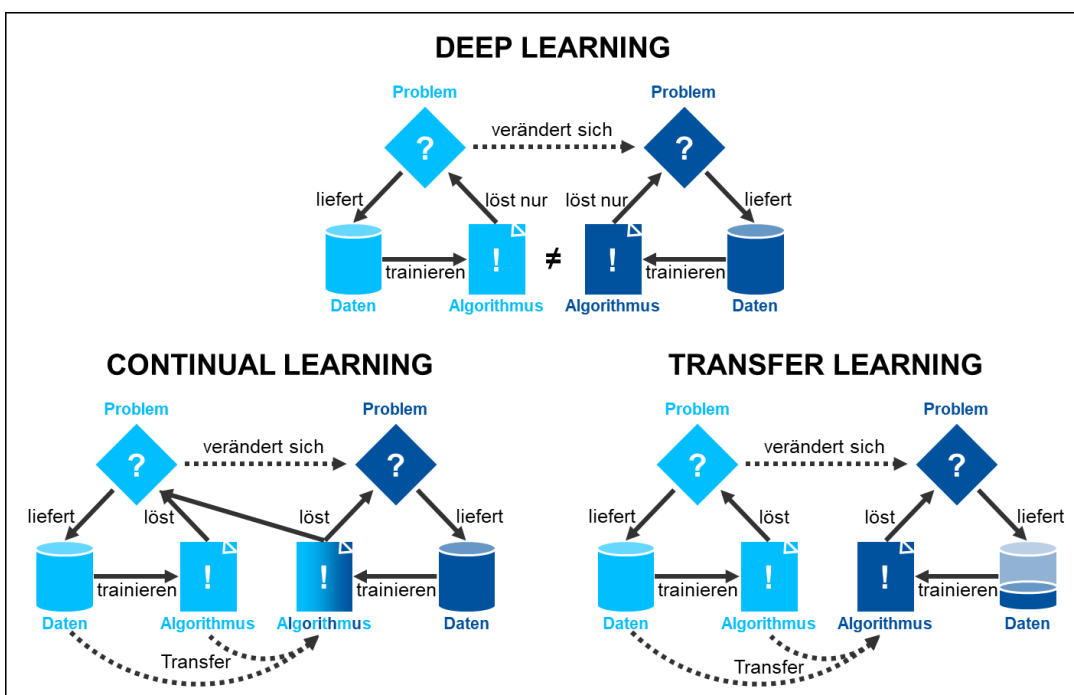


Bild 6: Schematische Gegenüberstellung verschiedener Lernverfahren mit und ohne Wissenstransfer

Weitere Konzepte des kooperativen, maschinellen Lernens wie Federated Learning oder Few bzw. One Shot Learning werden in diesem Kontext zwar immer wieder genannt, beschäftigen sich jedoch primär mit anderen Fragestellungen. Dies bedeutet nicht, dass sie prinzipiell nicht zur Lösung der vorgenannten Probleme geeignet seien, sondern lediglich, dass sich die damit bezeichneten Methoden in Bezug auf diese Probleme ebenfalls als Transfer oder Continual Learning interpretieren lassen.

Sowohl Transfer als auch Continual Learning sind nicht grundsätzlich auf Deep-Learning-Methoden beschränkt. Aufgrund des erheblichen Potentials von Deep Learning sowie dessen besonderer Empfindlichkeit gegenüber den in Kapitel 1 beschriebenen Problemen werden wir uns im Folgenden jedoch auf Deep Learning basierte Ansätze beschränken.

Tabelle 1: Wissenstransfer-Glossar

Begriff	Beschreibung
Continual Learning (deut.: Kontinuierliches Lernen)	Lern-Algorithmus nutzt Wissenstransfer von Quell-Problem(e) auf Ziel-Problem, um anschließend Quell- und Ziel-Probleme besser lösen zu können.
Federated Learning (deut.: Föderales Lernen)	Lern-Algorithmus nutzt Wissenstransfer zwischen dezentralen Clients und zentralem Server, um gemeinsam verschiedene Varianten eines Problems zu lösen ohne die zugrunde liegenden Daten auszutauschen.
Few Shot Learning (deut.: Lernen mit wenigen Versuchen)	Sammelbegriff für Lern-Algorithmen, deren Ziel es ist die Menge an benötigten Trainingsdaten zu minimieren. Methodiken des Continual- und Transfer-Learnings werden häufig dazu verwendet.
Industrial Transfer Learning (deut.: Industrielles Transfer-Lernen)	Lern-Algorithmus nutzt Wissenstransfer von Quell-Problem(e) auf Ziel-Problem, um Lernaufgaben im industriellen Kontext robuster, genauer oder dateneffizienter lösen zu können. Es kann dabei sowohl Continual als auch Transfer Learning zum Einsatz kommen.
Lern-Algorithmus	In Software abgebildetes, mathematisches Verfahren, das aus Daten zielgerichtet allgemeine(-re) Zusammenhänge zur Lösung eines konkreten Problems ableiten kann.
Problem	Lernaufgabe, die sich durch Format und Art von Ein- und Ausgangsdaten sowie die Ein- und Ausgang verbindenden Zusammenhänge charakterisiert.
Quell-Problem	Problem, das dem Lernalgorithmus bereits bekannt ist und von ihm gelöst werden kann.
Transfer Learning (deut.: Transfer-Lernen)	Lern-Algorithmus nutzt Wissenstransfer von Quell-Problem(e) auf Ziel-Problem, um anschließend Ziel- Problem besser lösen zu können.
Wissenstransfer	Austausch von verknüpften Informationen hoher Komplexität, wobei die Form abstrakt, d.h. nicht menschlich nachvollziehbar, sein kann.
Ziel-Problem	Problem, das dem Lernalgorithmus bisher unbekannt ist und von ihm noch nicht gelöst werden kann.

2.1 Szenario 1: Selbstlernende Roboter

Die Überbrückung der Simulation-to-Reality Lücke, also der Abweichungen einer Simulation von dem realen Prozess, ist die grundlegende Herausforderung im Einsatz von simulativ vortrainierten KI-Agenten. In vielen Fällen ist der naheliegende Lösungsansatz in Form einer Verbesserung der Simulation durch Prozessexperten nicht umsetzbar. Eine Alternative und eine deutlich effizientere Herangehensweise bietet das sogenannte Domain Randomization [7]. Hierbei werden Parameter der Simulation zufällig geändert und die entstehenden Simulationsumgebungen anschließend für das Training verwendet. Obwohl die generierten Simulationen von dem realen Prozess sehr stark abweichen können, führt das Training auf einer Verteilung von Simulationen zu einer erhöhten Robustheit eines KI-Agenten gegenüber Parameterabweichungen. So ist es möglich, einen KI-Agenten auf einen realen Prozess zu übertragen, auch wenn die exakten Bedingungen des realen Prozesses im Training nicht gesehen wurden (siehe Bild 7).

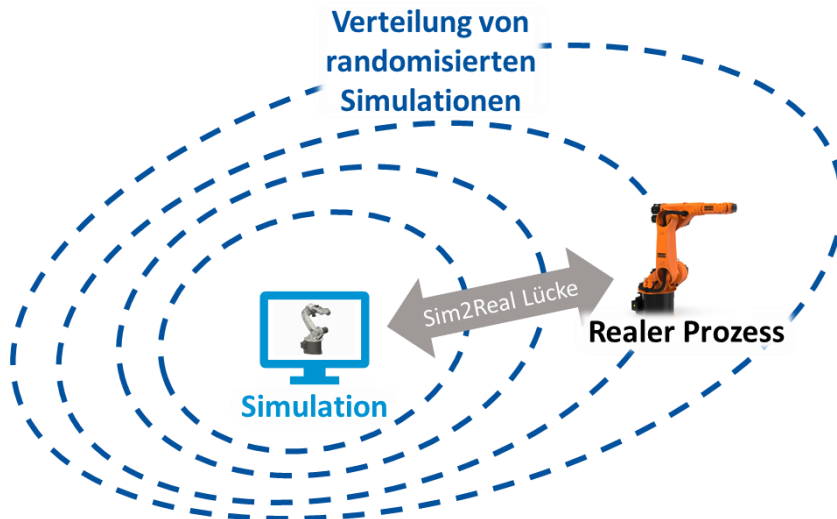


Bild 7: Überwindung der Simulation-to-Reality Lücke mit Domain Randomization

Wie in [8] gezeigt wurde, beschränkt sich das benötigte Prozesswissen für die erfolgreiche Anwendung von Domain Randomization auf die qualitative Auswahl der zu variierenden Parameter. Zudem erlauben die gesenkten Anforderungen an die Genauigkeit neben einer schnelleren Entwicklung geeigneter Simulationsumgebungen auch eine Effizienzsteigerung im Training von KI-Agenten durch erhöhte Simulationsgeschwindigkeiten.

2.2 Szenario 2: Verschleißvorhersage

In einer ersten Implementierung von Continual-Learning-Ansätzen für die Verschleißvorhersage wurde in [9] eine Regularisierungsmethode auf einem Turbinendatensatz angewandt. Regularisierungsmethoden zeichnen sich dadurch aus, dass sie beim Lernen des Ziel-Problems eine Veränderung von für die Lösung des Quell-Problems besonders wichtigen Parametern erschweren. Dadurch wird der Lern-Algorithmus gezwungen, Parametersätze zu suchen, die beide Probleme lösen können. Aus mathematischen Gründen ist der Wechsel von einem Regressions- zu einem Klassifizierungsproblem notwendig, sodass statt einer konkreten Restlebensdauer (bspw. „728 Stunden“) eine Zustandsklasse (bspw. „kritisch“) prädiziert wird. In der Studie konnte die grundsätzliche Anwendbarkeit von Regularisierungsmethoden für Verschleißvorhersage-Probleme belegt werden (siehe Bild 8).

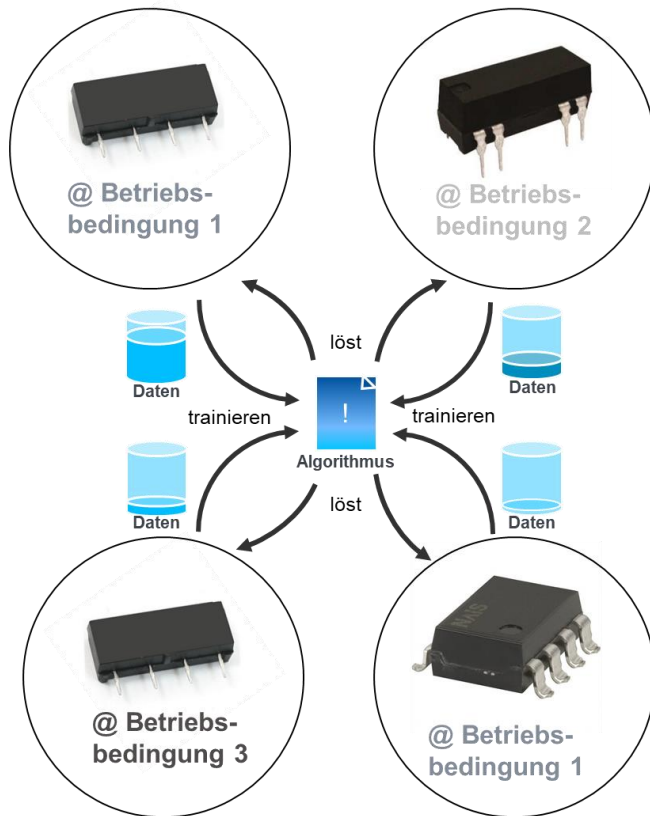


Bild 8: Szenarienübergreifendes Lernen für effiziente datenbasierte Verschleißvorhersage auf kleinen Datensätzen

In [3] wurden darauf aufbauend mehrere unterschiedliche Regularisierungsmethoden anhand der Verschleißvorhersage von Lithium-Ionen-Akkus verglichen. Der Anwendungsfall zeichnet sich durch eine hohe Varianz möglicher Nutzungsszenarien und ein immer noch unzureichendes Verständnis der konkreten physikalischen (Verschleiß-)Prozesse aus. In der Studie konnte belegt werden, dass Regularisierungsmethoden eine deutliche Steigerung der Vorhersagegenauigkeit erreichen, wobei jedoch die Ähnlichkeit und Reihenfolge der einzelnen (Teil-)Probleme einen erheblichen Einfluss haben.

In einer noch laufenden Studie wird ein anderer Ansatz zur Verschleißvorhersage von Kugellagern verwendet: Die in [10] vorgestellte Transfer-Learning-Architektur orientiert sich an der erfolgreichen Strategie von Bilderkennungsalgorithmen. Eine nicht-problemspezifische Merkmalerkennung reduziert die Daten auf das Wesentlichste. Anschließend werden über eine auf Clustering basierte Ähnlichkeitserkennung vergleichbare Quell-Probleme identifiziert, von denen die Parameter des Lernalgorithmus oder Trainingsdaten übernommen werden können, um den Lernprozess zu beschleunigen oder trotz geringer Datenmengen überhaupt erfolgreich abzuschließen. Vorläufige Ergebnisse deuten auf eine breite Anwendbarkeit des beschriebenen Ansatzes hin.

2.3 Szenario 3: Visuelle Objektdetektion

In [9] wurde aufgezeigt, dass Continual Learning nicht nur mit speziell für diesen Zweck kreierten Daten funktioniert, sondern auch mit praktisch relevanten Industriedaten im Bereich der

Verschleißvorhersage ein Weiterlernen ermöglicht. Anders als in der visuellen Objektdetektion bleibt jedoch die Struktur des KI-Modells in der Verschleißvorhersage über dessen Lebenszyklus gleich. So soll beispielsweise immer die verbleibende Lebensdauer bestimmt werden, unabhängig davon wie oft das KI-Modell weiter trainiert wurde. Die Struktur eines KI-Modells der visuellen Objektdetektion verändert sich allerdings, wenn bspw. ein neues Objekt dazugelernt wird. Auch die Art der Daten unterscheidet sich: Bei der Verschleißvorhersage werden Zeitreihendaten genutzt, wogegen die Objektdetektion meist auf einem einzelnen Kamerabild durchgeführt wird. Regularisierungsmethoden funktionieren unabhängig von der Art der Daten, allerdings nicht unabhängig von der Struktur des KI-Modells.

Ein vielversprechender Lösungsvorschlag für die visuelle Objektdetektion ist Learning Without Forgetting (LwF) [11], bei dem das KI-Modell während des weiteren Trainings durch eine Regularisierung dazu gezwungen wird, einen Kompromiss zwischen dem Neulernen und dem Behalten von früher Gelerntem zu finden. Die mit akademischen Testdatensätzen durchgeführte Studie erzielte vielversprechende Ergebnisse und konnte ebenfalls eine Einsparung von Berechnungszeiten berichten, ohne diese genauer zu Quantifizieren. In einer sich derzeit in der Durchführung befindlichen Studie wird untersucht, inwieweit Regularisierungsmethoden wie LwF geeignet sind, in einem industriellen Einsatzumfeld messbar zu einer Einsparung von Rechen- und Speicherressourcen und damit Kosten beizutragen.

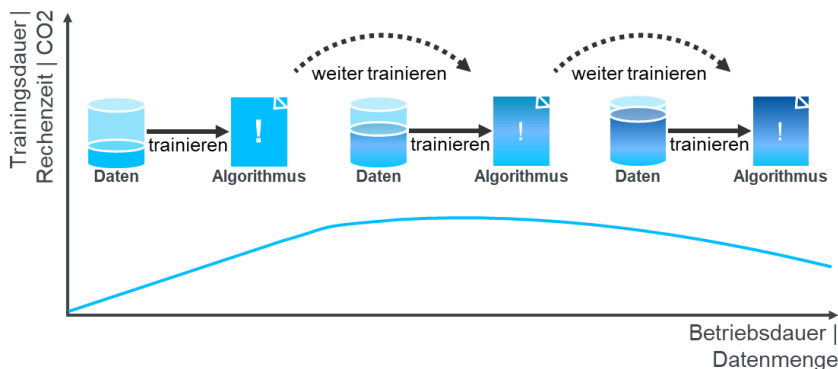


Bild 9: Continual Learning ermöglicht ein effizientes Weitertraining mit den neuen Daten, anstatt erneut mit allen Daten zu trainieren

2.4 Szenario 4: Predictive Quality im Spritzguss

Der Einsatz von Continual Learning Verfahren in Predictive Quality Anwendungen ermöglicht es, einen Lern-Algorithmus kontinuierlich für neu auftretende Prozessvariationen nutzen zu können [2, 12]. In [13] wird dies für den Einsatz künstlicher neuronaler Netze zur Prozessauslegung im Spritzguss experimentell untersucht. Im Anwendungsfall ist es das Ziel, ein neuronales Netz zur Regression der Deformation von Kunststoffbauteilen auf Basis verschiedener Maschinenparameter, u.a. von Druck und Zeit, zu trainieren und für Qualitätsvorhersagen zu nutzen. Eine zentrale Herausforderung für das Modelltraining ist, dass sich die Zusammenhänge in den Prozessdaten mit jeder neuen gefertigten Bauteilvariation ändern.

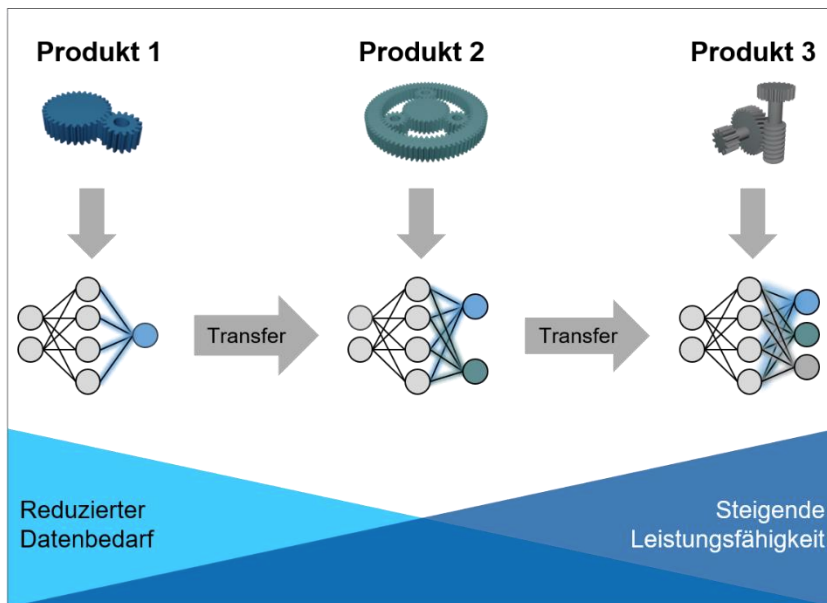


Bild 10: Continual Learning eines künstlichen neuronalen Netzes zur Qualitätsabschätzung im Spritzguss

Als Lösungsvorschlag wird eine Kombination aus Continual Learning (Regularisierungsmethode) und Transfer Learning (Transfer von Netzstrukturen) eingesetzt, mit der es möglich ist, das neuronale Netz über mehrere Bauteilvariationen daten- und ressourceneffizient zu trainieren. Die Untersuchungen zeigen einerseits, dass das Netz beim Erlernen neuer Variationen sein bisheriges Wissen nicht vergisst („Lernen ohne zu Vergessen“). Andererseits sorgt der Wissenstransfer dafür, dass das Training des Netzes mit der Zeit immer dateneffizienter geschieht, sodass hierfür weniger kostspielige Prozessdaten benötigt werden. Die gewonnenen Ergebnisse bestätigen das große Potenzial, neuronale Netze für Qualitätsvorhersagen in der Produktion nachhaltig und effizient über Prozessveränderungen hinweg trainieren zu können (siehe Bild 10).

3 Insights: Von der Wissenschaft in die Praxis

Auch Industrial Transfer Learning ist aktuell von einem großflächigen Einsatz in der industriellen Praxis weit entfernt. Damit dies nicht so bleibt, sondern die zuvor beschriebenen Potentiale tatsächlich realisiert werden können, sind aus Sicht der Autoren verschiedene Maßnahmen nötig:

In der wissenschaftlichen Auseinandersetzung wäre eine bessere Vergleichbarkeit der publizierten Ansätze, beispielsweise durch einheitliche, aber realitätsnahe Benchmark-Datensätze, wünschenswert. Dies würde die Übertragbarkeit von Ergebnissen über die Grenzen einzelner Pilotprojekte hinweg erleichtern. Thematisch besteht darüber hinaus eine Leerstelle im Bereich der Ähnlichkeitsbewertung. Es ist naheliegend, dass Wissenstransfer umso besser funktioniert, umso ähnlicher sich die betrachteten Probleme sind – welche Aspekte hier eine Rolle spielen und wie man diese messen und damit nutzbar machen könnte, ist jedoch bisher nicht näher erforscht worden. Dies scheint auch in den vielfach eher Grundlagenorientierten Forschungsschwerpunkten begründet zu sein.

Auch auf Seiten der zukünftigen Anwender in der Industrie sind Aufgaben zu erledigen, die man unter dem Oberbegriff der Automatisierung des Industrial Transfer Learning Workflows zusammenfassen kann. Zentral ist die automatische Erkennung einer Prozessveränderung, die ein erneutes Training rechtfertigt – bspw. in Folge von Produktwechsel, Anlagenverschleiß oder wechselnden Umgebungsbedingungen. Dieses Training muss anschließend ähnlich des AutoML-Ansatzes vollautomatisch ablaufen können und dabei auch die Hyperparameteroptimierung sowie Variation synthetischer Trainingsdaten ohne menschlichen Eingriff umfassen. Und schließlich werden Frameworks und Toolboxes benötigt, die in die bestehenden Unternehmensinfrastrukturen eingebettet werden können und von der Integration neuer Datenquellen über die Modell-Verwaltung bis hin zur Definition neuer vom Lern-Algorithmus zu lösenden Problemen eine umfassende Unterstützung der Nutzer gewährleisten. Weitere Synergien ließen sich über eine Verknüpfung mit den Konzepten des intelligenten Digitalen Zwillinges [14] oder des intelligenten Rekonfigurationsmanagements [15] realisieren.

4 Fazit

Von einem flächendeckenden Einsatz künstlicher Intelligenz kann in der industriellen Praxis bisher keine Rede sein. Es fehlt dafür unter anderem an Lösungen zum robusten Umgang mit geringen Datenmengen und hohen Dynamiken. Die beschriebenen Szenarien zeigen hierfür Lösungswege mit Hilfe von Industrial Transfer Learning auf.

Ein Vorteil liegt dabei in der Verzahnung von Simulation und Realität durch Sim2Real Transfer Learning, das nachweislich die Robustheit von KI-Agenten steigert und somit Kosten für Experimente in der Realität senkt. Hier zahlt sich aus, dass Simulationen schon lange als zentrale Methode bei der Entwicklung und Entscheidungsunterstützung im Betrieb genutzt werden.

Zu beachten ist, dass der Einsatz von Industrial Transfer Learning mit technischen und organisatorischen Veränderungen einhergehen muss. So müssen bspw. entsprechende Infrastrukturen in Form von dezentralen Speicher- und Rechenkapazitäten geschaffen sowie neuartige Protokolle zum Daten- und Modellaustausch entwickelt werden.

5 Referenzen

[1] Deloitte: Realising the economic potential of machine-generated, non-personal data in the EU: Report for Vodafone Group. July 2018. https://www.vodafone.com/content/dam/vodcom/files/public-policy/Realising_the_potential_of_IoT_data_report_for_Vodafone.pdf

[2] Tercan, H., Guajardo, A., Meisen, T.: Industrial Transfer Learning: Boosting Machine Learning in Production; IEEE 17th International Conference on Industrial Informatics (INDIN), S. 274-79, 2019.

[3] Maschler, B., Tatiyosyan, S., Weyrich, M.: Regularization-based Continual Learning for Fault Prediction in Lithium-Ion Batteries. 15th CIRP Conference on Intelligent Computation in Manufacturing Engineering (ICME), 2021.

- [4] Meyes, R., Tercan, H., Roggendorf, S., Thiele, T., Büscher, C., Obdenbusch, M., Brecher, C., Jeschke, S., Meisen, T.: Motion Planning for Industrial Robots using Reinforcement Learning. *Procedia CIRP* 63, S. 107-112, 2017.
- [5] Scheiderer, C., Mosbach, M., Posada-Moreno, A. F., Meisen, T.: Transfer of Hierarchical Reinforcement Learning Structures for Robotic Manipulation Tasks. *International Conference on Computational Science and Computational Intelligence (CSCI)*, 2020.
- [6] Maschler, B., Weyrich, M.: Deep Transfer Learning for Industrial Automation. *IEEE Industrial Electronics Magazine* 15 (2), S. 65-75, 2021.
- [7] Tobin, J., Fong, R., Ray, A., Schneider, J., Zaremba, W., Abbeel, P.: "Domain randomization for transferring deep neural networks from simulation to the real world." *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, S. 23-30, 2017.
- [8] Scheiderer, C., Dorndorf, N., Meisen, T.: Effects of Domain Randomization on Simulation-to-Reality Transfer of Reinforcement Learning Policies for Industrial Robots; *International Conference on Artificial Intelligence*, 2020.
- [9] Maschler, B., Vietz, H., Jazdi, N., Weyrich, M.: Continual learning of fault prediction for turbofan engines using deep learning with elastic weight consolidation. *25th IEEE International Conference on Emerging Technologies and Factory Automation (ETFA)*, S. 959-66, 2020.
- [10] Maschler, B., Knodel, T., Weyrich, M.: Towards Deep Industrial Transfer Learning for Anomaly Detection on Time Series Data. *26th IEEE International Conference on Emerging Technologies and Factory Automation (ETFA)*, 2021.
- [11] Li, Z., Hoiem, D.: Learning without Forgetting. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 40 (12), S. 2935-2947, 2016.
- [12] Tercan, H., Guajardo, A., Heinisch, J., Thiele, T., Hopmann, C., Meisen, T.: Transfer-Learning: Bridging the Gap between Real and Simulation Data for Machine Learning in Injection Molding. *Procedia CIRP* 72, S. 185-90, 2018.
- [13] Tercan, H., Deibert, P., Meisen, T.: Continual learning of neural networks for quality prediction in production using memory aware synapses and weight transfer. *Journal of Intelligent Manufacturing*, 2021.
- [14] Maschler, B., Braun, D., Jazdi, N., Weyrich, M.: Transfer learning as an enabler of the intelligent digital twin. *Procedia CIRP* 100, S. 127-32, 2021.
- [15] Maschler, B., Müller, T., Löcklin, A., Weyrich, M.: Transfer Learning as an Enhancement for Reconfiguration Management of Cyber-Physical Production Systems. *15th CIRP Conference on Intelligent Computation in Manufacturing Engineering (ICME)*, 2021.