

Künstliche Intelligenz VI

Prozessoptimierung mit KI: Problemstellungen und Ansätze

Künstliche Intelligenz verspricht mehr Effizienz, weniger Abfall und bessere Qualität. Doch welche Ansätze taugen wirklich in der Praxis? Dieser Beitrag zeigt, wie KI heute in der Prozessoptimierung eingesetzt wird und worauf Unternehmen dabei besonders achten sollten.

› Johan Pocard, Dr. Iason Kastanis

In der heutigen wettbewerbsintensiven Industrielandschaft ist die Prozessoptimierung keine Option mehr, sondern Notwendigkeit. Unternehmen in Fertigung, Logistik, Robotik und Chemieingenieurwesen stehen unter zunehmendem Druck, ihre Effizienz zu steigern, Abfall zu reduzieren und die Qualität ihrer Produkte zu sichern. Dafür müssen sie oft komplexe Systeme mit Hunderten voneinander abhängiger Variablen anpassen. Traditionelle Ansätze sind oft zu starr, um mit dynamischen und vielschichtigen Abläufen Schritt zu halten.

Ansätze zur Optimierung

Künstliche Intelligenz bietet neue Möglichkeiten, solche Abläufe intelligenter, adaptiver und effizienter zu gestalten. Es gibt drei verschiedene Ansätze, wie KI Industrieprozesse optimieren kann:

- › Sequenzielle Entscheidungsfindung
- › Verbesserung von Prozessparametern
- › Prozessbewertung.

Jeder Ansatz bringt eigene Methoden, Herausforderungen und praktische Lösungen mit sich und eignet sich für unterschiedliche Anwendungen. Dieser

Beitrag zeigt, wo KI konkrete Verbesserungen ermöglicht, die weit über das hinausgehen, was klassische Techniken leisten können.

Sequenzielle Entscheidungsfindung

Hier geht es um die Optimierung von Abläufen, zum Beispiel, um Aufgaben schneller zu erledigen, Robotersysteme effizienter zu gestalten oder Lieferketten

zu verbessern. Die Anwendungsmöglichkeiten wachsen stetig: In der Logistik planen KI-Systeme Hunderte von Lieferungen dynamisch, optimieren Lagerwege oder leiten LKWs auf Basis von Echtzeit-Verkehrsdaten um. In der Robotik passen Drohnen und mobile Roboter ihre Aktionen an veränderte Umgebungen an.

Früher nutzten Ingenieure dafür mathematische Verfahren wie lineare Algebra oder kombinatorische Optimierung. Diese sind in strukturierten Umgebungen sehr leistungsfähig, haben jedoch Schwierigkeiten, sich bei dynamischen, unsicheren oder nichtlinearen Systemen anzupassen. Die Anzahl Parameter wächst dann exponentiell an und lässt sich rechnerisch nicht mehr bewältigen.

KI-Methoden wie das bestärkende Lernen (Reinforcement Learning, RL) sind deutlich flexibler. Dabei wird ein sogenannter Agent durch Interaktionen mit seiner Umgebung trainiert. Durch Rückmeldungen in Form von Belohnungen lernt er, welche Aktionen zum gewünschten Ergebnis führen. Die Trainingsumgebung wird in der Regel simuliert, sodass der Agent Tausende Szenarien sicher und in kurzer Zeit durchspielen kann. Mit Techniken wie Reward Shaping bekommt der



kurz & bündig

- › Es gibt drei Ansätze, wie KI Industrieprozesse optimieren kann: sequenzielle Entscheidungsfindung, Verbesserung von Prozessparametern, Prozessbewertung.
- › KI kann die Geschwindigkeit sequenzieller Entscheidungsfindungen verbessern, Parameter zur Qualitätssteigerung anpassen oder den aktuellen Zustand eines Systems bewerten.
- › Jeder Ansatz bringt eigene Methoden, Herausforderungen und praktische Lösungen mit sich und eignet sich für unterschiedliche Anwendungen.

Agent nicht nur ein Erfolgssignal am Ende der Trainingseinheit, sondern auch nach Zwischenschritten – was den Lernprozess beschleunigen kann.

Eine häufige Herausforderung bei der sequenziellen Entscheidungsfindung ist die Diskrepanz zwischen Simulation und Realität. Was in der Simulation funktioniert, kann in der Realität aufgrund von Ungenauigkeiten im simulierten Modell scheitern. So kann ein Roboterarm, der in einer digitalen Zwillingsumgebung trainiert wurde, in einer physischen Umgebung aufgrund von geringfügigen Vibrationen, Sensorrauschen oder Reibung versagen. Zudem können definierte Systemvorgaben zu weniger guten Lösungen führen, wenn das Belohnungssystem schlecht durchdacht ist. Oder sich in seltenen Randfällen unvorhersehbar verhalten, wenn sie im Training nicht berücksichtigt wurden.

Um diese Probleme zu vermeiden, braucht es realistische Simulationen. Dafür ist ein fundiertes Verständnis der Geräte, Systeme und Einschränkungen nötig, was wiederum eine enge Zusammenarbeit zwischen Entwicklern und Auftraggebern bedarf. Physikalische Modellierungsbibliotheken helfen, reale Phänomene mit hoher Genauigkeit zu simulieren. So unterstützt die Python-Bibliothek Holopy beispielsweise die Modellierung der Wechselwirkung von Licht mit verschiedenen Oberflächen in bildbasierten Steuerungssystemen. Auch Visualisierungstools spielen eine wichtige Rolle: Durch eine grafische Analyse können Entwickler Lücken in der Abdeckung des Eingaberaums oder Bereiche identifizieren, in denen die Vorgaben regelmässig versagen.

Mit der fortschreitenden Entwicklung von Simulation und Lernalgorithmen wird die sequenzielle Entscheidungs-KI in Zukunft eine noch zentralere Rolle bei der Prozessoptimierung übernehmen.

Verbesserung von Prozessparametern

Bei dieser Form der Optimierung wird die Qualität oder der Output eines Prozesses

durch Feinabstimmung seiner Parameter verbessert. Das wird bereits in vielen Bereichen erfolgreich getan – etwa bei der Abstimmung von Spritzgiessparametern in der Fertigung, der Optimierung von Katalysatoren in chemischen Reaktionen oder bei der Steigerung der Energieeffizienz in HLK-Systemen.

Klassische Methoden lösen solche Aufgaben mithilfe von Prozessmodellierung und statistischen Methoden wie Regressionsanalyse, Versuchsplanung (Design of Experiments, DOE) und Response-Surface-Methoden gut, solange die Problemstellungen klein und berechenbar sind. Bei komplexen, hochdimensionalen Systemen sind sie jedoch oft nicht praktikabel.

Hier bietet KI neue Werkzeuge. Physikalisch informierte neuronale Netze (PINNs) kombinieren Daten mit physikalischen Gesetzen. Das reduziert den Bedarf an grossen Datensätzen und verbessert gleichzeitig die Anwendbarkeit der Modelle. Bayessche Optimierung hilft, mit einer begrenzten Anzahl – kostspieliger – Experimente die besten Parameter zu finden. Anstatt jede Kombination erschöpfend zu testen, liefert dieser Ansatz ein probabilistisches Modell der Zielfunktion. Damit wägt sie zwischen Exploration und Nutzen ab und liefert die vielversprechendsten Parameterkombinationen für den nächsten Test.

Solche Methoden sind oft Teil adaptiver Lernpipelines, bei denen jedes Experiment den nächsten Schritt beeinflusst. Mit intelligenten Stichprobenstrategien lässt sich die Datenerfassung gezielt steuern. Soll gleichzeitig die Produktionsgeschwindigkeit und die Produktqualität maximiert werden, hilft ein ausgewogener Stichprobenansatz, den besten Kompromiss zu finden. Das CSEM nutzte solche Strategien etwa bei der Optimierung von Zahnradschleifprozessen, wobei Formeln zur Mehrzieloptimierung eingesetzt wurden.

Trotz aller Fortschritte bleiben Herausforderungen. Die Datenerhebung ist oft

teuer und zeitaufwendig, vor allem, wenn physische Tests nötig sind. Zudem verändern sich Prozesse im Lauf der Zeit durch Verschleiss oder Umweltveränderungen und liefern dadurch inkonsistente Ergebnisse. Modelle müssen dann häufig nach jeder Iteration neu trainiert werden, was zusätzlichen Aufwand verursacht. Auch die Kommunikation zwischen den involvierten Parteien kann zu Engpässen führen: Für Prozessexperten aus der Industrie ist es oft schwierig, alle technischen Details so zu vermitteln, dass Datenwissenschaftler sie in Modelle übersetzen können.

Um diese Probleme zu überwinden, sollen Entwickler intelligente Stichprobenverfahren einsetzen, die direkt auf die Geschäftsziele zugeschnitten sind. Wer sich dabei auf die relevantesten Teile des Parameterraums konzentriert, kann unnötige Tests vermeiden. Eine weitere Massnahme ist die Entwicklung benutzerfreundlicher Schnittstellen, zum Beispiel mit der Webschnittstelle Streamlit. Darüber können Prozessexperten oder Prozessverantwortliche mit den Modellen interagieren, Ergebnisse visualisieren und Rückmeldung geben, ohne die technischen Details verstehen zu müssen. Das erleichtert die Kommunikation und beschleunigt den Optimierungsprozess.

Mit der Weiterentwicklung von Techniken wie PINNs und Bayessche Optimierung dürfte ihre Anwendung in der Industrie künftig noch stärker an Bedeutung gewinnen.

Prozessbewertung (Expertensysteme)

Bei der dritten Kategorie der Optimierung geht es nicht um Veränderungen, sondern darum, den aktuellen Prozesszustand besser zu verstehen. Das ist entscheidend für Überwachung, Diagnose und Qualitätskontrolle. Typische Anwendungen sind die Fehlererkennung in der Präzisionsfertigung, die Überwachung des Maschinenzustands oder die Vorhersage von Systemausfällen, bevor diese auftreten.

Herkömmliche Ansätze stützen sich stark auf Expertenwissen und regelbasierte Systeme. Diese sind jedoch oft starr und bereits kleine oder unerwartete Abweichungen in den Prozessdaten können zu Problemen führen. KI verbessert dies durch den Einsatz moderner Klassifizierungs- und Zeitreihenanalyseverfahren. Statt ausschliesslich auf vordefinierte Regeln zu vertrauen, lassen sich Modelle trainieren, die in realen Daten Muster erkennen. Mini Rocket beispielsweise ist ein effizienter und skalierbarer Algorithmus für die Zeitreihenklassifizierung, der sich bei Daten aus der Industrie als sehr zuverlässig erwiesen hat. Auch mit Random-Forest-Klassifikatoren und benutzerdefiniertem Feature Engineering können Modelle erstellt werden, die sowohl genau als auch interpretierbar sind.

Solche Modelle sind meist sehr spezifisch und keine Universallösung. Jedes neue Projekt erfordert daher erneut eine sorgfältige Modellierung, Merkmalsauswahl und Validierung. Unternehmen können diese Herausforderungen überwinden, indem sie Erfahrungen aus früheren Projekten systematisch dokumentieren. So entsteht mit der Zeit eine Bibliothek an Methoden, Merkmalen und Benchmarks, die zukünftige Implementierungen beschleunigt. Dieses institutionelle Wissen macht Modelle nicht nur präziser, sondern auch robuster gegenüber wechselnden Bedingungen.

Fazit

Künstliche Intelligenz bietet leistungsstarke und anpassungsfähige datengetriebene Lösungen und verändert damit die Optimierung industrieller Prozesse grundlegend. Sie kann die Geschwindigkeit sequenzieller Entscheidungsfindungen verbessern, Parameter zur Qualitätssteigerung anpassen oder den aktuellen Zustand eines Systems bewerten. Der Erfolg solcher Systeme hängt jedoch nicht allein von den Algorithmen ab. Er setzt ein umfassendes Verständnis der Problemstellung, eine präzise Modellierung realer

Systeme, sorgfältige Stichproben- und Validierungsstrategien sowie eine effektive Zusammenarbeit zwischen Ingenieuren, Datenwissenschaftlern, Anwendern und Betreibern voraus. Durch die Kombination von Simulation, maschinellem Lernen, Fachwissen und intuitiven Schnittstellen ermöglicht KI eine intelli-

gentere Prozessoptimierung als je zuvor. Die Zukunft industrieller Leistungsfähigkeit liegt nicht mehr in manuellen Anpassungen oder statischen Modellen, sondern in der Entwicklung intelligenter, responsiver und lernender Systeme, die sich anpassen und kontinuierlich verbessern. «



Porträt



Johan Pocard

Centre Suisse d'Electronique et de Microtechnique CSEM

Johan Pocard hat einen Master of Science in Maschinenbau von der Eidgenössischen Technischen Hochschule in Lausanne EPFL. Er hat an der Harvard University im Bereich Soft Robotics geforscht und arbeitet seit drei Jahren beim CSEM im Bereich Industrierobotik und maschinelles Lernen.



Dr. Iason Kastanis

Gruppenleiter,

Centre Suisse d'Electronique et de Microtechnique CSEM

Iason Kastanis hat einen Dokortitel in Informatik vom University College London. Seit mehr als einem Jahrzehnt entwickelt er Predictive-Analytics-Lösungen für die Industrie. Er hat Projekte in den Bereichen künstliche

Intelligenz, Computer Vision, Signalverarbeitung und Optimierung geleitet, in denen die entwickelten Technologien produktiv eingesetzt werden. Derzeit leitet er beim CSEM die Gruppe Predictive Analytics.

Die Autoren sind SAIROP-Partner. Mit der Swiss Artificial Intelligence Research Overview Platform SAIROP bringt die Schweizerische Akademie der Technischen Wissenschaften SATW wichtige Akteure des Schweizer KI-Ökosystems zusammen und bietet einen Überblick über KI-Dienstleistungen, Forschungsprojekte und Kooperationspartner. SAIROP soll die Zusammenarbeit zwischen Forschung, Industrie und Verwaltung fördern und den Wissenstransfer in der Schweiz unterstützen.

Die Schweizerische Akademie der Technischen Wissenschaften SATW ist das Expertennetzwerk im Bereich Technikwissenschaften in der Schweiz und im Kontakt mit den massgeblichen Schweizer Gremien für Wissenschaft, Politik und Industrie. Die SATW ist politisch unabhängig und nicht kommerziell.



Kontakt

johan.pocard@csem.ch, iason.kastanis@csem.ch
www.csem.ch, www.sairop.swiss, www.satw.ch