

Intelligente Anlaufsteuerung für die Batteriezellenproduktion

Ann-Kathrin Goßmann,
Matthieu Poyer,
Rui Yan Li,
Sebastian Henschel,
Julius Pfrommer,
Constanze Hasterok,
Achim Kampker und
Jürgen Fleischer*

Der Anlauf von Produktionslinien infolge wechselnder Produktvarianten oder Produktionsprozesse stellt Hersteller von Batteriezellen aufgrund hoher Ausschussraten vor einen enormen Qualitäts- und Kostendruck. Eine Regelung basierend auf Verfahren der künstlichen Intelligenz kann helfen, die Anlaufprozesse zu beschleunigen. Im Forschungsprojekt InTeAn wurde hierzu ein Vorgehen zur Entwicklung einer Prozessregelung zur Reduktion von Anlaufzeit und Kosten in der Batteriezellproduktion entwickelt.

Einleitung

Nicht zuletzt seit dem fortschreitenden Wachstum der Elektromobilität in vielen europäischen Ländern, ist die Nachfrage nach Lithium-Ionen-Batterien stark angestiegen. Die geforderten schnellen Anläufe von neuen Produktionslinien, gepaart mit neuen Zellmaterialien stellen die Industrie vor gewaltige Herausforderungen. Insbesondere beim Hochlauf von Produktionsanlagen sind hohe Ausschussraten daher keine Seltenheit. Verstärkt wird das Problem von häufig nicht vollständig verstandenen Auswirkungen schwankender Material- und Umgebungsbedingungen durch die kostenintensiven Rohmaterialien der Batteriezellproduktion, die bis zu 60 Prozent [1] der Gesamtkosten für eine fertige Batteriezelle ausmachen kön-

nen. Insbesondere der Beschichtungsprozess der Elektroden zu Beginn der Zellherstellung stellt spezielle Anforderungen. Die Beschichtungsqualität, welche maßgeblich durch eine homogene Schichtdicke und saubere Beschichtungskanten definiert wird, erfordert häufig immer noch ein händisches Anfahren des optimalen Prozessfensters. Dieses ist wiederum abhängig von prozessinternen Parametern, wie der Produktionsgeschwindigkeit oder dem Volumenstrom und den Eigenschaften (z. B. Viskosität) des zugeführten Aktivmaterials (Slurry). Gleichzeitig unterliegen diese Einflussgrößen aber auch Schwankungen, beispielsweise durch wechselnde Qualitäten der zugeführten Rohmaterialien im Mischprozess, weshalb kontinuierliche Anpassungen notwendig sind.

Das Einsatzgebiet von Verfahren basierend auf künstlicher Intelligenz (KI) in der industriellen Produktion ist vielfältig und reicht von Erkennung von Anomalien und Condition Monitoring bis hin zur Prozessoptimierung. Insbesondere Prozesse wie die Beschichtung, für die eine vollständige physikalische Beschreibung entweder nicht vorhanden ist oder nicht mit vertretbarem Aufwand erreicht werden kann, können von dem Einsatz von KI profitieren. Mit einer ausreichenden Datenbasis können datengetriebene Modelle verwendet werden, um die physikalische Beschreibung der Anlage zu ergänzen oder ggf. ganz zu ersetzen. Diese Prozessmodelle können zur Regelung verwendet werden oder beim Umrüsten der Anlage einen initialen Parametersatz vorschlagen. Sie erhöhen so die Anlagenverfügbarkeit und Flexibilität, wodurch sie gerade für den (Wieder-)Anlauf von Produktionsanlagen hilfreiche Unterstützung bieten.

Vorgehen

Im Rahmen des Forschungsprojekts InTeAn (Intelligente Anlaufsteuerung zur kostenreduzierten und flexiblen Fertigung zukünftiger Batteriezellen) wurde eine intelligente Anlaufsteuerung für die Batteriezellenfertigung entwickelt und die gesammelten Erkenntnisse abstrahiert in einem Vorgehensmodell zusammengefasst. Hierbei wurde in den einzelnen Schritten zum Teil auf bereits etablierte Vorgehensmodelle für die Entwick-

* Korrespondenzautorin

Ann-Kathrin Goßmann, M. Sc.; Fraunhofer-Institut für Optronik, Systemtechnik und Bildauswertung IOSB; Fraunhoferstraße 1, 76131 Karlsruhe; Tel.: +49 (0) 6151 8229721, E-Mail: ann-kathrin.gossmann@iosb.fraunhofer.de

Weitere Autor:innen

Matthieu Poyer, M. Sc.; Fraunhofer IOSB
Rui Yan Li, M. Sc.; PEM der RWTH Aachen
Sebastian Henschel, M. Sc.; wbk – Institut für Produktionstechnik des KIT
Dr.-Ing. Julius Pfrommer; Fraunhofer IOSB
Dr. rer. nat. Constanze Hasterok; Fraunhofer IOSB
Prof. Dr.-Ing. Achim Kampker; PEM der RWTH Aachen
Prof. Dr.-Ing. Jürgen Fleischer; wbk – Institut für Produktionstechnik des KIT

Hinweis

Bei diesem Beitrag handelt es sich um einen von den Mitgliedern des ZWF-Advisory-Board wissenschaftlich begutachteten Fachaufsatz (Peer Review).

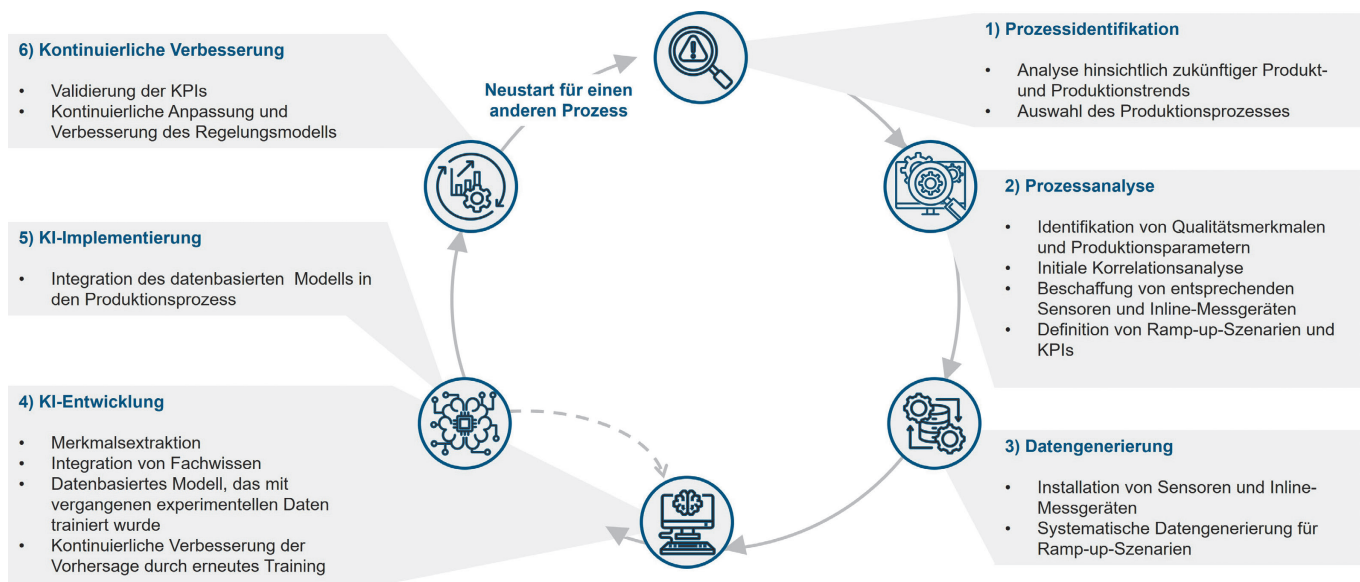


Bild 1. Methodik zur Implementierung eines KI-basierten Prozessreglers für den Anlauf einer Batteriezellproduktion

lung von KI-Komponenten zurückgegriffen. Ein bekanntes Vorgehensmodell ist das ML4P (Machine Learning for Production) [2] Vorgehensmodell, welches das Vorgehen für maschinelles Lernen in der Produktion beschreibt und mit zugehörigen Werkzeugen verknüpft. Der Fokus hierbei liegt auf der Entwicklung und dem Betrieb der Machine Learning (ML)-basierten Anwendung. Das Vorgehensmodell ist in sechs Phasen mit klar definierten Ergebnissen gegliedert und vereint agiles Vorgehen innerhalb der Proof-of-Concept-Phase mit linearem Vorgehen über alle Phasen hinweg. Dies hat zum Ziel, der großen Unsicherheit bei der Entwicklung von ML-Lösungen (= agiles Vorgehen bevorzugt) auf der einen Seite und der Planbarkeit der Entwicklung von Produktionsanlagen (= lineares Vorgehen bevorzugt) auf der anderen Seite Rechnung zu tragen. Daneben existiert mit PAISE® (Process Modell for AI Systems Engineering) [3] ein Vorgehensmodell, das speziell für die systematische Entwicklung und den Betrieb von KI-basierten Lösungen als Teil von komplexen technischen Systemen (KI-Engineering [4]) entwickelt wurde. Es beinhaltet sowohl die Systemorientierung als auch die KI-Orientierung und verfolgt somit einen übergreifenden Ansatz, der das Gesamtsystem in der Entwicklung und im Betrieb im Blick hat. KI-Komponenten und Datensätze werden hier als Subsystem angesehen und somit

von Anfang an in die Entwicklung des Gesamtsystems integriert.

Die im InTeAn-Projekt entwickelte Methodik adaptiert die in den Vorgehensmodellen beschriebenen Kerntätigkeiten auf eine spezifische Aufgabe der KI-Komponente (Regelung) und einen spezifischen Prozessschritt (Anlauf) und kann dadurch als Leitfaden für vergleichbare Problemstellungen gesehen werden. Der Ablauf der sechs übergreifenden Phasen wird in Bild 1 dargestellt. Zu Beginn wird im Rahmen der Prozessidentifikation eine Analyse durchgeführt, um zukünftige Produkt- und Produktionstrends zu identifizieren und geeigneten Produktionsprozesse auszuwählen, welche im Rahmen der KI-Entwicklung fokussiert werden. In der darauffolgenden Prozessanalyse werden kritische Qualitätsmerkmale und Produktionsparameter ermittelt. Darüber hinaus erfolgt die Definition notwendiger Sensorik sowie konkreter Anlaufszenarien und Key Performance Indikatoren (KPIs). In der Phase der Datengenerierung findet die Implementierung der Sensorik sowie eine systematische Datenerzeugung für die definierten Anlaufszenarien statt. Der nächste Schritt, die KI-Entwicklung, umfasst die Merkmalsextraktion und die Integration von Domänenwissen, wobei ein datengestütztes Modell mit den zuvor gesammelten experimentellen Daten trainiert wird. Anschließend wird das entwickelte datengestützte Modell in den Pro-

duktionsprozess integriert, um seine Leistung unter realen Bedingungen zu testen. Die kontinuierliche Verbesserung bildet die abschließende Phase, in der die KPIs validiert und das datengestützte Modell fortlaufend angepasst und verbessert werden. Bei Bedarf kann der Gesamtprozess iterativ neu gestartet werden, um eine kontinuierliche Optimierung und Anpassung weiterer Produktionsprozesse zur Verbesserung von Produktqualität und Effizienz zu ermöglichen.

Im Projektverlauf wurden diese übergreifenden Phasen am Beispiel der Entwicklung und Implementierung einer KI-basierten Prozessregelung für den Beschichtungs- und Trocknungsprozess der Pilotline im eLab der RWTH Aachen umgesetzt. Im Folgenden wird das Vorgehen näher erläutert.

Prozessidentifikation

Im Rahmen des ersten Prozessschritts Prozessidentifikation wird eine umfassende Marktanalyse zu Batteriezellformaten und -chemien durchgeführt, um zukünftige Produkt- und Produktionstrends zu identifizieren. Hierbei wurden insbesondere der Trend zu größeren Zellformaten (z.B. Cell-to-Pack-Technologie) und zu Materialien ohne kritische Verfügbarkeit (z.B. Kobalt) bzw. mit Potential zur Optimierung der Zellkapazität (z.B. Silizium in der Anode) identifiziert. Beide Trends weisen einen klaren Einfluss auf das Pro-

zessverhalten in der Beschichtung- und Trocknung von Elektroden auf, welcher in der Folge im Projekt fokussiert wurde. Die Fertigung von neuen Zellgeometrien erfordert in der Regel eine Veränderung des Beschichtungsprozesses, wie zum Beispiel die Anpassung der Auftragsdüse.

Prozessanalyse

Im Rahmen der Prozessanalyse werden nach der Definition von *Kampker et al.* [5] relevante und beeinflussbare Prozess- und Qualitätsparameter definiert. Bei der Elektrodenbeschichtung sind dies unter anderem die Bahngeschwindigkeit der Beschichtungsanlage sowie der Volumenstrom der Slurrypumpe. Beide Prozessparameter beeinflussen die finale Schichtdicke der Elektroden [6]. Darüber hinaus spielt die Oberflächenbeschaffenheit der Beschichtung ebenfalls eine qualitätskritische Rolle und soll über optische Überprüfungen erfasst werden.

Zudem erfolgt nach *Laick* [7] eine Definition von Anlaufszenarien, welche im Folgenden über die Regelung beschleunigt werden sollen. Im Fokus stehen insbesondere Änderungen in den Handlungsfeldern zur Änderung des Produkts und der Produktion. Konkret umfassen diese die Szenarien Änderung des Materials, der Zellgeneration, der Produktionscharge oder den Wiederanlauf nach Anlagenwartung sowie die Änderung von Prozessparametern. Zur Evaluierung dieser Szenarien werden zudem KPI wie Anlaufzeit, Energieverbrauch und Materialverbrauch definiert.

Datengenerierung

Um die KI-Regelung zu entwickeln ist eine umfassende Datenerhebung notwendig. Hierzu müssen zuerst die in der Prozessanalyse identifizierten Parameter messtechnisch an der Anlage erfasst werden. Dies kann durch Sensoren wie Lasertriangulationssensoren zur Erfassung der Beschichtungsdicke, oder Kameras zum Detektieren von Oberflächenfehlern erfolgen. Der weitere Entwicklungsprozess profitiert hierbei erheblich davon, wenn sämtliche Informationen in einer zentralen Datenbank zusammengetragen werden. Dadurch wird im späteren Prozess ein komplexes Abgleichen und Anpassen von Zeitstempeln der Messungen vermieden. Dies kann durch industriell

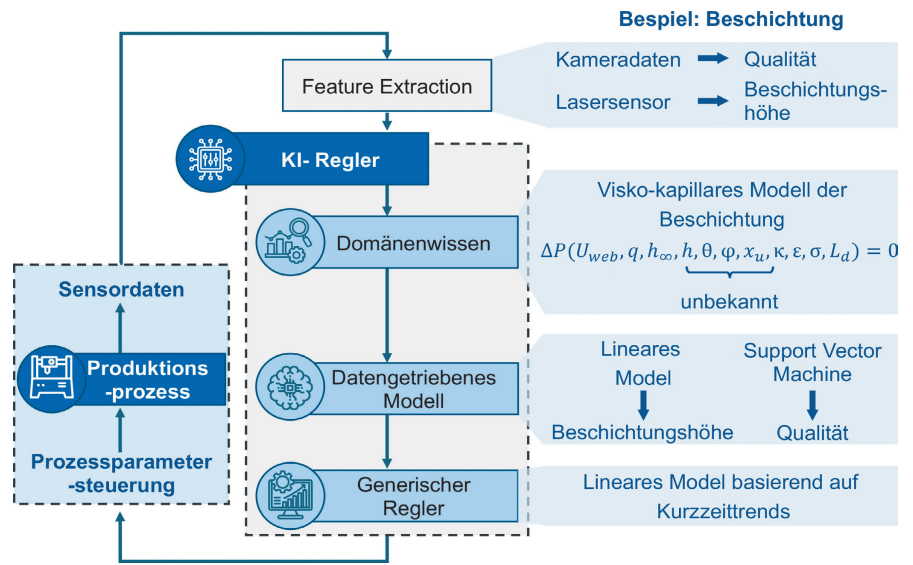


Bild 2. Architektur des KI-Reglers am Beispiel der Regelung der Elektrodenbeschichtung

etablierte Softwarelösungen zum Tracing von Daten oder eine individuell programmierte Lösung realisiert werden.

Wenn die technischen Voraussetzungen für die Datenerfassung geschaffen wurden, kann mit der eigentlichen Datenaufnahme begonnen werden. Hierbei sollte ein möglichst breites Prozessfenster, inklusive Randbereiche wie hohe Bahngeschwindigkeiten, mit den Versuchen abgedeckt werden, um einen repräsentativen Datensatz zu erhalten

KI-Entwicklung

Die Architektur des KI-Reglers für die Beschichtungshöhe ist in Bild 2 dargestellt. Eingangsgröße für den Regler sind so genannte Features, also charakteristische Merkmale des Prozesses. Diese müssen zuerst aus den Sensordaten extrahiert werden. Für den Beschichtungsprozess ist das zum Beispiel die Beschichtungshöhe und das Vorliegen von Defekten in der Beschichtung. Der entwickelte Regler besteht aus drei Stufen. In der ersten Stufe wird das Prozesswissen, abgebildet durch ein physikalisches Modell, dazu genutzt den möglichen Parameterbereich auf physikalische sinnvolle Werte einzugrenzen. In der zweiten Stufe wird ein datengetriebenes Modell, trainiert auf den zuvor erhobenen Daten, genutzt, um die optimalen Parameter zu bestimmen. Die Kombination von physikalischem und datengetriebenem Modell erlaubt es mit weniger Trainingsdaten

auszukommen, da das Modell die physikalischen Grenzen nicht erst erlernen muss. Gleichzeitig kann die Robustheit des Reglers durch die Einschränkungen des physikalischen Modells erhöht werden. Bei der Beschichtung wird in der zweiten Stufe des Reglers eine Kombination aus zwei KI-Modellen zur Anwendung gebracht: ein lineares Modell für die Vorhersage der Beschichtungshöhe und eine Support Vector Machine für die Vorhersage der Beschichtungsqualität. Die dritte Stufe des Reglers stellt sicher, dass der Regler auch dann reagieren kann, wenn laut datengetriebenem Modell (Stufe 2) der optimale Parametersatz eingestellt, aber in der Realität die Zielgröße noch nicht erreicht ist. Dieser Fall tritt ein, wenn das datengetriebene Modell den aktuellen Prozesszustand nicht hinreichend gut beschreibt, zum Beispiel durch eine unzureichende Menge an Trainingsdaten in diesem Bereich. Bei der Regelung der Beschichtung greift dann ein Regler, der Trends in den Parametern erkennt und die Zielgröße iterativ einregelt. So ist der Regler auch ohne Anpassung des Modells handlungsfähig. Ziel der kontinuierlichen Modelloptimierung ist es, die Anzahl dieser iterativen Regelschritte zu reduzieren.

KI-Implementierung

Für die Implementierung des Reglers wird im Anschluss eine Schnittstelle zur bestehenden produktionsbedingten IT-Infrastruktur benötigt. Zu diesem Zweck erfolg-

te im InTeAn-Projekt über eine Python-basierte Schnittstelle eine Anbindung an die bestehende Infrastruktur des CELLFABS basierend auf einem Kepware OPC Server, welcher auf dem Kommunikationsstandard Open Platform Communications Unified Architecture (OPC UA) aufsetzt.

Kontinuierliche Verbesserung

Die Voraussetzung dafür, dass ML Modelle zuverlässige Vorhersagen liefern ist, dass die Daten, auf denen sie trainiert wurden, vergleichbar zu den aktuellen Daten der Anlage sind. Dies kann im Normalfall nicht für die gesamte Nutzungsdauer gewährleistet werden. Beispielsweise durch Verschleiß, Austausch von Komponenten oder ein neu zu fertigendes Produkt kann es dazu kommen, dass sich Randbedingungen ändern und das Modell das Prozessverhalten nicht mehr abbildet. Dann muss das Modell aktualisiert werden. Eine zentrale Herausforderung bei dem Betrieb von KI-Komponenten ist, diesen Zeitpunkt zu erkennen und das Modell dementsprechend anzupassen. Hierzu eignen sich wiederum KI-Methoden, die sogenannte Drift-Detection und Drift-Adaption durchführen und das Modell automatisch fortlaufend an Prozessänderungen anpassen. [8]

Im Rahmen der kontinuierlichen Verbesserung wurden mit den im InTeAn-Projekt entwickelten KI-Regler nach der ersten Implementierung weitere Versuche an der Beschichtungsanlage durchgeführt. Die hierbei gewonnenen Prozessdaten wurden genutzt, um das datengetriebene Modell zu optimieren. Anhand von vorher definierten Kriterien, wie z.B. die Anlaufzeit, konnte die Verbesserung quantifiziert werden. So führt die Regelung des Volumenstroms in Abhängigkeit der Bahngeschwindigkeit zu einer um 20 Prozent kürzeren Anlaufzeit im Vergleich zu einer händischen Anpassung dieser beiden Parameter.

Ausblick

Die Anwendung des Vorgehensmodell erfolgte im Projekt bisher auf der Pilotlinie im eLab der RWTH Aachen. Um das Vorgehen ebenfalls für die Industrie nutzbar zu machen, wird als nächster Schritt eine Validierung des Vorgehens auf Anlagen im Serienmaßstab angestrebt.

Literatur

1. Orangi, S.; Strømman, A. H.: A Techno-Economic Model for Benchmarking the Production Cost of Lithium-Ion Battery Cells. *Batteries* 8 (2022) 8, S. 83
DOI:10.3390/batteries8080083
2. Fraunhofer IOSB (Hrsg.): ML4P- Vorgehensmodell Machine Learning For Production – Whitepaper (2022)
DOI:10.24406/publica-485
3. Hasterok, C.; Stompe, J.: PAISE® – Process Model for AI Systems Engineering. *Automatisierungstechnik* 70 (2022) 9, S. 777–786
DOI:10.1515/auto-2022-0020
4. Usländer, T.; Schulz: KI-Engineering in der Produktion – Whitepaper der Fraunhofer-Institute IOSB und IAIS (2023)
DOI:10.24406/publica-1685
5. Kampker, A.; Heimes, H.; Dorn, B.; Clever, H.; Ludwigs, R.; Li, R.; Drescher, M.: Concept for Digital Product Twins in Battery Cell Production. *World Electric Vehicle Journal* 14 (2023) 4
DOI:10.3390/wevj14040108
6. Hagi, S.; Summer, A.; Bauerschmidt, P.; Daub, R.: Tailored Digitalization in Electrode Manufacturing: The Backbone of Smart Lithium-Ion Battery Cell Production. *Energy Technology* 10 (2022) 10
DOI:10.1002/ente.202200657
7. Laick, T.: Hochlaufmanagement: Sicherer Produktionshochlauf durch zielorientierte Gestaltung und Lenkung des Produktionsprozesssystems. *FBK produktionstechnische Berichte*, Bd. 47
8. Lima, M.; Neto, M.; Filho, T. S.; de A. Fagundes, R. A.: Learning Under Concept Drift for Regression – A Systematic Literature Review. *IEEE Access* 10 (2022), S. 45410–45429
DOI:10.1109/ACCESS.2022.3169785

Die Autor:innen dieses Beitrags

Ann-Kathrin Goßmann, M.Sc., studierte Maschinenbau an der TU Darmstadt. Seit 2023 ist sie Wissenschaftliche Mitarbeiterin am Fraunhofer IOSB in der Abteilung Kognitive Industrielle Systeme.

Matthieu Poyer, M.Sc., studierte Mathematik an der Universität Paris-Saclay und der Universität von Lyon. Seit 2022 ist er Wissenschaftlicher Mitarbeiter in der Abteilung Kognitive Industrielle Systeme am Fraunhofer IOSB.

Rui Yan Li, M.Sc., studierte Wirtschaftsingenieurwesen mit Fachrichtung Maschinenbau an der RWTH Aachen University. Seit 2022 ist er Wissenschaftlicher Mitarbeiter am Lehrstuhl Production Engineering for E-Mobility Components (PEM) im Bereich Battery Production Management.

Sebastian Henschel, M.Sc., studierte Wirtschaftsingenieurwesen an der Hochschule Mannheim. Seit 2021 ist er Wissenschaftlicher Mitarbeiter am wbk – Institut für Produktionstechnik des KIT im Bereich Agile Produktionsanlagen.

Dr.-Ing. Julius Pfrommer leitet die Abteilung für Kognitive Industrielle Systeme (KIS) am

Fraunhofer IOSB. Die Abteilung entwickelt intelligente Komponenten und Verfahren für eine flexible und ressourceneffiziente Produktion.

Dr. rer. nat. Constanze Hasterok leitet die Gruppe für intelligente cyber-physische Systeme am Fraunhofer IOSB. Die Arbeitsgruppe schlägt die Brücke zwischen KI-Grundlagenforschung und industrieller Umsetzung von KI-Methoden zusammen mit produzierenden Unternehmen.

Prof. Dr.-Ing. Achim Kampker ist Leiter des Lehrstuhls „Production Engineering of E-Mobility Components“ (PEM) der RWTH Aachen und bekannt durch die Mitentwicklung des Elektrofahrzeugs „StreetScooter“. Darüber hinaus ist er Mitglied des Vorstands der „Fraunhofer-Einrichtung für Batteriezellenfertigung FFB“ in Münster.

Prof. Dr.-Ing. Jürgen Fleischer ist seit 2003 Leiter des Instituts für Produktionstechnik am Karlsruher Institut für Technologie (KIT) und für den Bereich Maschinen, Anlagen und Prozessautomatisierung verantwortlich.

Abstract

Intelligent Ramp-up Controller for Battery Cell Production. The ramp-up of production lines as a result of changing product variants or production processes puts battery cell manufacturers under enormous quality and cost pressure due to high reject rates. A control system based on artificial intelligence methods can help to speed up the start-up processes. The InTeAn research project developed a procedure for developing a process control system to reduce ramp-up times and costs in battery cell production.

Förderhinweis

Das diesem Bericht zugrunde liegende Vorhaben wurde mit Mitteln des Bundesministeriums für Bildung und Forschung unter dem Förderkennzeichen 03XP0357C (Projekt InTeAn) gefördert. Die Verantwortung für den Inhalt dieser Veröffentlichung liegt bei den Autor:innen.

Schlüsselwörter

Batteriezellproduktion, Ausschussreduktion, Steuerungstechnik, Künstliche Intelligenz, Maschinelles Lernen, Regelung

Keywords

Battery Cell Production, Scrap Reduction, Control Technology, Artificial Intelligence, Machine Learning, Control