

1 Einleitung und Motivation

1.1 Ausgangssituation und Problemstellung

Aufgrund sich ständig ändernder Marktanforderungen und Regulierungen sowie zunehmendem Wettbewerb sehen sich produzierende Unternehmen großen Herausforderungen ausgesetzt¹. Unter Wettbewerbsbedingungen sind Kundenanforderungen bezüglich Funktionalität und Qualität der Produkte zu erfüllen. Dabei muss eine steigende Komplexität in den Fertigungsprozessen, bedingt durch neuartige Technologien und Flexibilität hinsichtlich Volumen und Varianten der Produkte, beherrscht werden^{2,3}. Dies gilt insbesondere für die Automobilbranche aufgrund des disruptiven Wandels zur Elektromobilität⁴. In der Produktion von Batterien führt mangelndes Produkt- und Prozessverständnis zu einer großen Streuweite der Produktqualität⁵.

In der industriellen Praxis wird die Qualität sowie die Sicherheit der Komponenten, Maschinen und Produkte mit Hilfe einer hohen Anzahl an Prüfschritten gewährleistet. Aufgrund der damit einhergehenden verlängerten Durchlaufzeit während der Fertigung reduzieren die erforderlichen Prüfstationen und Prüfabläufe die Fertigungseffizienz. Außerdem ist ein großer Anteil an den Investitions- und Betriebskosten auf Prüfprozesse zurückzuführen^{6,7}. Zurzeit basiert die Ermittlung von Optimierungspotenzialen hinsichtlich Fertigungseffizienz und -qualität auf geringen Datenmengen, verteilten Datenbasen, einem großen Erfahrungsschatz der Mitarbeiter sowie aufwändigen, oft händisch ausgeführten Auswertungen.⁸

Bei der Aufarbeitung von Fehlern jeglicher Art tritt dieser Umstand verschärft zu Tage. In frühen Entwicklungsphasen des Produktionssystems werden potentielle Ursachen

¹ Vgl. Panetto, H./Iung, B. et al. (Challenges for Manufacturing Enterprises), 2019, S. 5-6

² Vgl. Hammer, M./Somers, K. et al. (Profit Per Hour as a Target), 2017, S. 717

³ Vgl. Busogi, M./Song, D. et al. (Manufacturing Complexity), 2019, S. 22096-22097

⁴ Vgl. Kampker, A./Vallée, D. et al. (Produktion von Elektrofahrzeugen), 2018, S. 73

⁵ Vgl. Kampker, A./Vallée, D. et al. (Elektromobilität), 2018, S. 21

⁶ Vgl. Hirsch, V./Reimann, P. et al. (Analytical Quality Control), 2018, S. 1333

⁷ Vgl. Kampker, A./Heimes, H. et al. (Enabling Data Analytics), 2018, S. 121

⁸ Vgl. Kampker, A./Heimes, H. et al. (Enabling Data Analytics), 2018, S. 121

von Fehlern mittels Fehlermöglichkeits- und -einflussanalyse (FMEA)⁹ identifiziert und dokumentiert. Aufgrund fehlender Verfügbarkeit von Informationen sind reaktive Zyklen zur Fehleraufarbeitung und zur kontinuierlichen Verbesserung nur mit hohem manuellem Aufwand zu bewältigen. Dieser Zustand ist in Abbildung 1-1 an einem generischen Fertigungsprozess dargestellt.

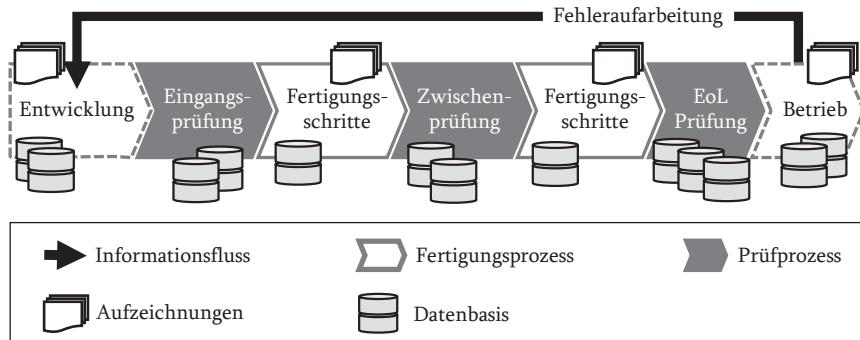


Abbildung 1-1: Fehleraufarbeitung in der Serienfertigung

Der Weg von der Entwicklung über Eingangsprüfungen, diverse Fertigungsschritte bis hin zum Betrieb wird durch Zwischenprüfungen und End of Line (EoL) Prüfungen begleitet. Während der gesamten Fertigung, einschließlich der Prüfungen, werden neben der automatisierten Datenerfassung auch händisch Aufzeichnungen erstellt. Die auf diesem Weg erhaltenen Informationen werden in unterschiedlichen Datenbasen gespeichert, z. B. werden qualitätsrelevante Daten getrennt von Prozessdaten archiviert. Die Fehleraufarbeitung findet problemgetrieben und somit reaktiv statt. Dies bedeutet, dass die unterschiedlichen Datenquellen im Fehlerfall unter hohem manuellem Aufwand verknüpft, verarbeitet und mit Expertenwissen angereichert werden müssen, um Fehlerursachen identifizieren zu können. Diese Vorgehensweise ist mit hohem Zeitaufwand verbunden und führt zu einer langen Reaktionszeit bei der Fehleraufarbeitung und der Einleitung von verbesserten Maßnahmen. Die gewonnenen Erkenntnisse beziehen sich somit ausschließlich auf den reaktiv betrachteten Einzelfall und lassen sich nicht auf zukünftige Fehleraufarbeitungen übertragen.

Unerwartete Fehler innerhalb des Fertigungssystems führen zu verringrigerter Qualität der Prozesse und Produkte¹⁰. Um schneller auf diese Fehler reagieren zu können, sind Kenntnisse der Zusammenhänge zwischen den einzelnen Prozessparametern und der

⁹ Vgl. da Mota Batista, S. S./Oliveira, M. A. de et al. (FMEA in Manufacturing), 2019, S. 1021-1036

¹⁰ Vgl. Lindemann, B./Fesenmayr, F. et al. (Anomaly Detection in Discrete Manufacturing), 2019, S. 313

Produktqualität erforderlich. Dies gilt ebenfalls für die Verbesserung der Produktionsprozesse, insbesondere für den elektrifizierten Antriebsstrang^{11,12}. Somit ist ein kontinuierlicher Wissensaufbau anzustreben, der in einer Wissensbasis mündet, die sowohl die Prozessoptimierung als auch die Anwender der Fertigungssysteme beim Identifizieren und Beheben von Fehlern unterstützt.

In der Informationstechnologie (IT) wird Data Analytics (DA) eingesetzt, um Wirkzusammenhänge unter Zuhilfenahme von großen Datenmengen zu identifizieren¹³. Dabei werden unterstützende Ansätze aus den Bereichen des Internet-of-Things¹⁴ sowie des Machine Learnings¹⁵ (Maschinelles Lernen; ML) und des Data Minings¹⁶ (DM) verwendet. Vorgehensmethoden, wie z. B. der Cross-Industry Standard Process for Data Mining (CRISP-DM)¹⁷, kommen zur Anwendung. Diese Ansätze und Vorgehensweisen bieten ein hohes Potential, um den Wissensaufbau in der Serienfertigung zu beschleunigen. Ein möglicher Lösungsansatz zur Anwendung von Data Analytics in der Serienfertigung, angelehnt an das CRISP-DM Modell, ist in Abbildung 1-2 dargestellt.

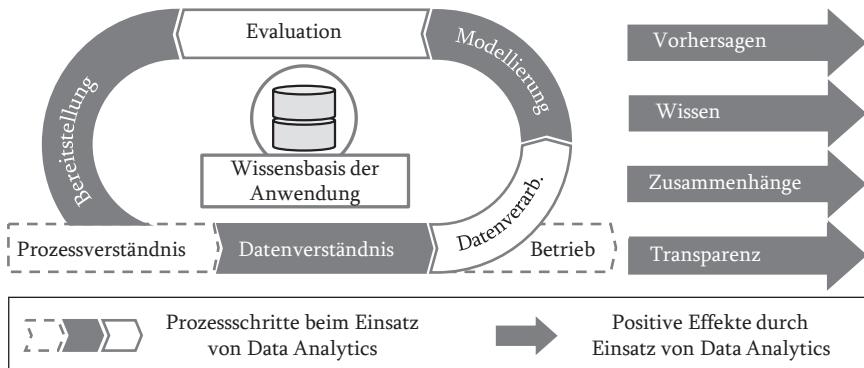


Abbildung 1-2: Möglicher Lösungsansatz mittels Data Analytics¹⁸

Basierend auf einer zentralen Wissensbasis würden hierbei die Schritte Prozessverständnis, Datenverständnis, Datenverarbeitung, Modellierung, Evaluation und Bereitstellung durchlaufen werden, um eine Data Analytics Anwendung zu implementieren

¹¹ Vgl. Kornas, T./Daub, R. et al. (Cause-Effect Relationships in Battery Production), 2019, S. 380

¹² Vgl. Nallusamy, S. (Productivity Enhancement in Manufacturing), 2020, S. 1-8

¹³ Vgl. Dai, H.-N./Wong, R. C.-W. et al. (Big Data Analytics), 2019, S. 4 ff.

¹⁴ Vgl. Dai, H.-N./Wang, H. et al. (Manufacturing Internet of Things), 2019, S. 1 ff.

¹⁵ Vgl. Carleo, G./Cirac, I. et al. (Machine Learning Sciences), 2019, S. 3 ff.

¹⁶ Vgl. Seidel, R./Amada, H. et al. (Data Mining System Architecture), 2020, S. 75-80

¹⁷ Vgl. Martinez-Plumed, F./Contreras-Ochando, L. et al. (CRISP-DM to DST), 2020, S. 2

¹⁸ In Anlehnung an Martinez-Plumed, F./Contreras-Ochando, L. et al. (CRISP-DM to DST), 2020, S. 2

und zu betreiben. Durch diesen Prozess würde eine Datentransparenz geschaffen, die es erlaubt, Zusammenhänge zu identifizieren, die zum Wissensaufbau herangezogen werden könnten. Die gewonnenen Modelle würden Vorhersagen auf Basis historischer Daten und Informationen gestatten.

Allerdings führen bei Data Analytics Projekten bestehende Denkweisen, Fähigkeiten und Werkzeuge zu einer Abbruchquote von über 60% während der Pilotierungsphase¹⁹. Die Datenbasen und Datenerfassungsmechanismen bestehender Fertigungssysteme bieten keine hinreichende Grundlage zur umfassenden Anwendung von Data Analytics^{20,21}. Bezuglich der Datenverfügbarkeit unterscheiden sich Fertigungssysteme, bei denen die Daten physikalischer Prozesse zunächst erfasst werden müssen, von IT-Systemen, bei denen die erforderlichen Daten bereits vorliegen. Dieser zusätzliche Schritt der Datenerfassung bei Fertigungssystemen führt bei der Anwendung von Data Analytics zu einer Reihe von Hürden wie z. B. dem Vorliegen heterogener und verteilter Datenbanken, beschränktem Datenbankzugriff, fehlenden Datenpunkten und eingeschränkten Rückverfolgungsmöglichkeiten aufgrund nicht vorliegender Verlaufsdaten sowie Hardwarelimitationen im Produktionsumfeld²². Zusätzlich wird die Anwendbarkeit von Data Analytics durch hohe Kosten für neue Kontroll- und IT-Infrastrukturen eingeschränkt. Aus diesen Gründen ist eine direkte Übertragbarkeit der Methoden aus der IT auf die Fertigungsprozesse nicht gegeben.^{23,24}

1.2 Zielsetzung

Auf Grundlage dieser in Unterkapitel 1.1 dargestellten Ausgangssituation leitet sich die Zielsetzung dieser Arbeit ab: Es soll ein Beitrag zur Bewältigung der hohen Komplexität innerhalb neuartiger Fertigungssysteme geleistet werden. Dabei soll der Fokus auf der Absicherung von Produktqualität und Prozessstabilität in der Serienfertigung liegen.

Zur Beherrschung von Komplexität eignen sich grundsätzlich Data Analytics Ansätze wegen ihrer Fähigkeit, unbekannte Wirkzusammenhänge zu identifizieren und zu modellieren^{25,26}. Aus der Betrachtung der Ausgangssituation wurde ersichtlich, dass sich

¹⁹ Vgl. Henrion, M. (Why Data Analytics Projects Fail), 2019, S. 1-2

²⁰ Vgl. Uhlemann, T. H.-J./Lehmann, C. et al. (The Digital Twin), 2017, S. 337

²¹ Vgl. Heimes, H./Kampker, A. et al. (Potenziale & Hürden Data Analytics), 2019, S. 60

²² Vgl. Dai, H.-N./Wang, H. et al. (Manufacturing Internet of Things), 2019, S. 3

²³ Vgl. Uhlemann, T. H.-J./Lehmann, C. et al. (The Digital Twin), 2017, S. 337

²⁴ Vgl. Dai, H.-N./Wang, H. et al. (Manufacturing Internet of Things), 2019, S. 3

²⁵ Vgl. Dai, H.-N./Wong, R. C.-W. et al. (Big Data Analytics), 2019, S. 4 ff.

²⁶ Vgl. Popova Zhuhadar, L./Thrasher, E. (Data Analytics Adressing Complexity), 2019, S. 3