

# Smart Big Data in der industriellen Fertigung

Yvonne Hegenbarth,<sup>1</sup> Gerald H. Ristow<sup>2</sup>

**Abstract:** In der industriellen Fertigung wird ein Bauteil im Laufe des Herstellungsprozesses immer wertvoller, so dass Störungen im Produktionsablauf oder Fertigungsfehler möglichst frühzeitig erkannt werden müssen. Im Zeichen von Industrie 4.0 geschieht dies mittels unterschiedlicher Sensoren, die automatisch ausgelesen werden oder selbst aktiv ihre Werte kommunizieren. Die Daten müssen analysiert und miteinander in Relation gesetzt werden. Es ist wünschenswert, diese Informationen in Echtzeit auszuwerten, insbes. wenn es sich um zeitkritische und aufwändige Herstellungsprozesse handelt. Die Sensordaten können durch Daten aus Logdateien und Datenbanken angereichert werden, um den Maschinenzustand vollständig zu beschreiben. Anhand von konkreten Anwendungsfällen aus der industriellen Fertigung zeigen wir, wie eine echtzeitfähige Streamingplattform helfen kann, die Produktion zu optimieren. Hierbei wird nicht nur die Qualität einzelner Bauteile betrachtet, sondern die gesamte Produktionsanlage, so dass Prozessabweichungen frühzeitig erkannt werden. Ebenfalls werden Vorhersagen sowohl zum Abnutzungsgrad von Maschinen und Werkzeugen gemacht als auch der mögliche Zeitpunkt einer manuellen Intervention vorausbestimmt.

## 1 Einleitung

Als Firma beteiligen wir uns aktiv an vielen Forschungsprojekten. Das Thema Industrie 4.0 bekommt immer mehr an Bedeutung, wobei die Überwachung und Verbesserung der industriellen Fertigung gefragt ist. Je früher auf Unregelmäßigkeiten oder Störungen reagiert wird, desto geringer ist der Ausschuss, der Maschinenleerlauf oder -stillstand. Insofern ist es erstrebenswert, schon zur Laufzeit bzw. zum aktuellen Produktionszeitpunkt alle benötigten Daten zur Verfügung zu haben. Hier hat sich eine flexible und vielseitig einsetzbare Streaming Analytics Plattform, welche die Daten in (nahezu) Echtzeit verarbeitet, sehr bewährt, siehe z.B. [GS15].

Als Beispiel sei hier das Forschungsprojekt „BigPro – Einsatz von Big Data-Technologien zum Störungsmanagement in der Produktion“<sup>3</sup> genannt, aus dem einige Erkenntnisse und Ergebnisse vorgestellt werden. Konkret sollen zwei Anwendungsfälle aus der Sensorfertigung betrachtet werden:

1. Das Plasmaätzen in der Waferproduktion, auf den detailliert in Abschnitt 2 eingegangen wird. Hierbei wird die Qualität des aktuellen Ätzzvorgangs mithilfe von Data Mining Techniken bestimmt, um Ausschuss frühzeitig zu erkennen.
2. Das Testen von Drucksensoren, auf das detailliert in Abschnitt 3 eingegangen wird. An dieser Stelle werden die Sensordaten über das Einlesen von Logdateien gewonnen,

---

<sup>1</sup> Software AG, Reseach, Uhlandstrasse 12, D-64297 Darmstadt, Yvonne.Hegenbarth@softwareag.com

<sup>2</sup> Software AG, Reseach, Uhlandstrasse 12, D-64297 Darmstadt, Gerald.Ristow@softwareag.com

<sup>3</sup> <http://www.fir.rwth-aachen.de/en/research/research-projects/bigpro-01is14011>

welche noch synchronisiert werden mussten. Des Weiteren bestimmen wir den Maschinendurchsatz und berechnen daraus, wann ein manuelles Eingreifen nötig sein wird.

In Abschnitt 4 geben wir eine kurze Zusammenfassung und einen Ausblick auf die noch geplanten Aktivitäten im BigPro Forschungsprojekt.

## 2 Anwendungsfall – Plasmaätzvorgang in der Waferproduktion

Micro-Electro-Mechanical Systems, sogenannte MEMS, sind heute allgegenwärtig, meist als Sensoren oder Aktoren. Diese sind in der Lage Abmessungen im Mikrometerbereich zu messen. Sie bestehen meist aus Silizium und werden aus Wafern gefertigt. Der bekannteste Prozess zur Herstellung ist das Plasmaätzen. Hierbei wird eine Lackmaske aufgetragen, die Bereiche vor dem Ätzangriff schützt. Es entstehen beim Ätzen als Reaktionsprodukte u.a. Polymere, die sich in der Ätzkammer abscheiden. Während des Ätzens wird der Wafer in der Ätzkammer durch die Zufuhr von Helium von der Rückseite gekühlt.

Abb. 1 zeigt den schematischen Aufbau des Helium-Systems, zum Kühlen des Wafers in der Ätzkammer.

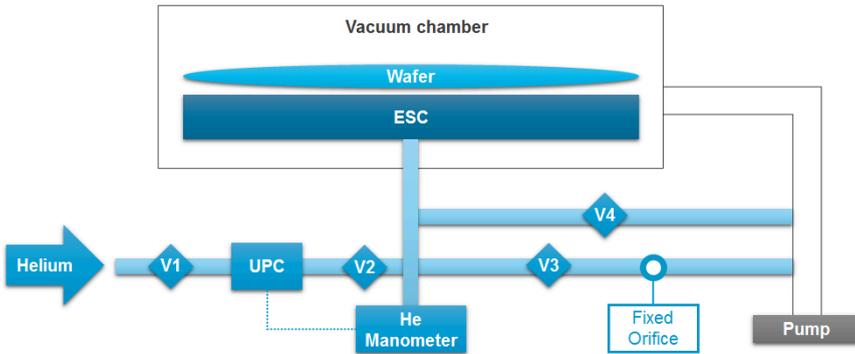


Abb. 1: Schematischer Aufbau der Plasmaätzkammer, aus [He16]

Der Wafer wird auf einem elektrostatischen Chuck (ESC) abgelegt und dort mittels eines elektrischen Feldes fixiert. Eine Pumpe sorgt für ein Vakuum in der Ätzkammer. Über den Unit Pressure Controller (UPC) wird ein Heliumdruck durch den ESC an die Rückseite des Wafers angelegt, der durch das Manometer gemessen wird.

In Gesprächen mit Domainspezialisten wurden mögliche Störungsfälle identifiziert und nach ihrer Häufigkeit und ihrem Einfluss auf den Produktionsablauf klassifiziert. Dabei kam heraus, dass die schwerwiegendste Störung Partikel zwischen Wafer und dem ESC sind, die zu einer schlechten thermischen Ankopplung und dem Austritt von Helium in die Ätzkammer führen. Eine häufige Ursache ist die Verunreinigung durch zu viele abgeplatzte Polymere in der Ätzkammer. Als Kenngrößen wurde die visuell erfasste Polymerfadendicke und der vom Manometer gemessene Heliumfluss identifiziert.

Da z.Zt. noch keine geeignete Schnittstelle der Sensoren zur Verfügung steht, wurden die zu erwarteten Werte in enger Anlehnung an das System simuliert. Abb. 2 zeigt die möglichen Systemzustände, parametrisiert durch den horizontal aufgetragenen Heliumfluss und die vertikal aufgetragene Polymerfadendicke. Es werden vier gut voneinander trennbare Bereiche, sogenannte Cluster, definiert.

- i) kein Heliumfluss (ganz links)
- ii) sehr hoher Heliumfluss, verursacht durch das Einschwingen (ganz rechts)
- iii) kleiner, sehr klar definierter Heliumfluss (links in grün markiert)
- iv) hoher, schwankender Heliumfluss für dickere Polymerfäden (rechts in rot markiert)

Der rot markierte Bereich ist das kritische Cluster. Wenn das System sich in diesem Zustand befindet, ist der Wafer höchstwahrscheinlich unbrauchbar. Das System muss daraufhin angehalten und die Ätzkammer von den Polymerfäden gereinigt werden.

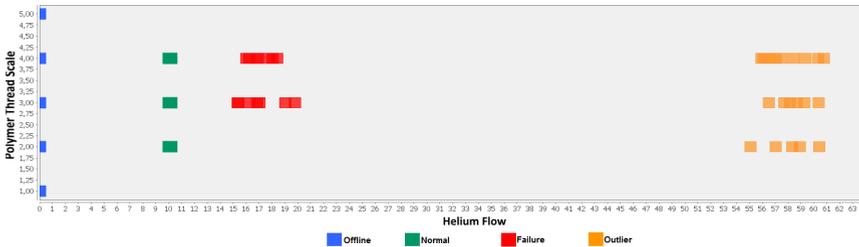


Abb. 2: Visuelle Clusterzuordnung gegeben durch Heliumfluss und Polymerfadendicke, aus [He16]

Im Allgemeinen kann die Einteilung in unterschiedliche Cluster nicht so einfach manuell vorgenommen werden, z.B. wenn der Parameterraum höherdimensional ist, so dass automatisierte Verfahren zur Anwendung kommen. In [He16] wurden verschiedene Clusteranalyse-Algorithmen auf ihre Qualität im hier beschriebenen Anwendungsfall untersucht. Im Rahmen dieser Ausarbeitung werden einige relevante Ergebnisse kurz vorgestellt.

Als Clusteringverfahren wurde u.a. der k-Means Algorithmus, siehe [Ma67] und auch [De14], angewendet. Erst bei einem Output von acht Clustern konnte eine annehmbare Clusterzuordnung erreicht werden. Drei der vier zuvor beschriebenen Bereiche werden sehr gut erkannt. Weitere fünf Cluster beschreiben den Normalbetrieb, welche allerdings zusammengefasst werden können. Eine Vorgabe von weniger Clustern führte in diesem Fall zu einer noch größeren Abweichung des im Abb. 2 beschriebenen Sollzustands. Das Ergebnis des k-Means Algorithmus ist in Abb. 3 gezeigt.

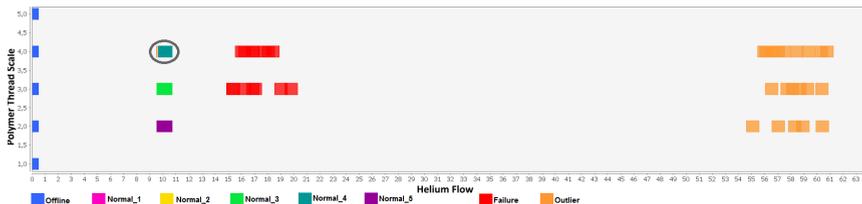


Abb. 3: Streudiagramm k-Means (8 Cluster), aus [He16]

Bei der Verwendung des hierarchischen Clustering Algorithmus werden nur fünf Cluster berechnet. Das Ergebnis wird in Abb. 4 dargestellt. Der Normalbereich wird hier als eine zusammengehörige Klasse identifiziert. In diesem Fall ordnet der Algorithmus den Outlier-Bereich (Abb. 4, ganz rechts) zwei Cluster zu, die wiederum leicht zusammengefasst werden können.

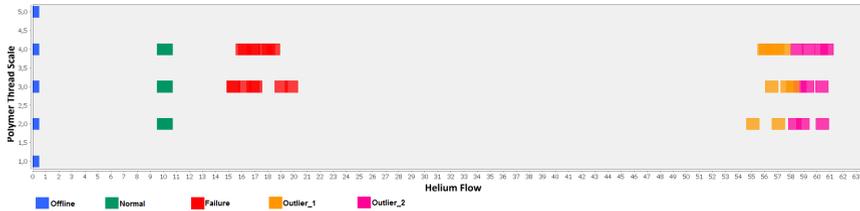


Abb. 4: Streudiagramm hierarchische Clusteranalyse, aus [He16]

Nachdem durch die Clusteranalyse eine Klassenzuweisung mit Testdaten vorgenommen worden ist, kann ein Klassifikationsalgorithmus, wie Naive Bayes oder Decision Tree, ausgewählt werden. Mit Hilfe eines geeigneten Klassifikators wird in [He16] gezeigt, dass eine hohe Vorhersagegenauigkeit der Daten in Hinblick auf ihre Klassenzugehörigkeit erreicht werden kann. Durch das Exportieren und Laden einer Predictive Model Markup Language (PMML) Datei in eine Streaming Analytics Plattform ist eine Vorhersage in nahezu Echtzeit lösbar.

Nach Verfügbarkeit der entsprechenden Schnittstellen zu den Sensordaten, kann mit Zuversicht eine automatische Erkennung der Qualität des Ätzvorgangs und damit der des Wafers durchgeführt werden.

Normalerweise wird in unserem Szenario der aktuelle Maschinenzustand durch die Verknüpfung von unterschiedlichen Ereignissen, sogenannten Events, bestimmt. Die Analyse erfolgt durch Abfragen, sog. Queries, die den Ereignis- und Parameterraum überwachen und auf Auffälligkeiten, sog. Patterns, untersuchen. Da eine Auffälligkeit oder ein Störfall durch ein kompliziertes Pattern beschrieben werden könnte, macht es Sinn sich zu überlegen, ob schon ein Teilpattern auf so etwas hindeutet. Es erscheint sinnvoll, die Teilpattern mit Wahrscheinlichkeiten zu versehen, um auch bisher noch nicht aufgetretene Auffälligkeiten zu erkennen und darauf aufmerksam zu machen. Erste Ergebnisse sind sehr vielversprechend und weitere Details sind in [Se16] aufgeführt.

### 3 Anwendungsfall – Testen von Drucksensoren

Der zweite Anwendungsfall betrifft das automatisierte Testen von Drucksensoren. Dazu werden die Sensoren von Greifern auf Schlitten platziert und durch die Anlage bewegt. In dem hier beschriebenen Anwendungsfall wird der Sensor bei zwei unterschiedlichen Raumtemperaturen, zu jeweils vier verschiedenen Drücken getestet und entsprechend kalibriert.

Die Anlage ist in Abb. 5 skizziert. Die Sensoren werden unten links angeliefert und nach erfolgreichem Test rechts auf eine Rolle bzw. Gurt aufgebracht (5). Defekte Sensoren, die den Testvorgang nicht bestanden haben, werden in einen Abfallkorb platziert (6). Die Schritte sind im Einzelnen:

1. Die Sensoren werden aus dem Vorratsbehälter auf den Schlitten platziert.
2. Der Schlitten gruppiert die Sensoren und wird in die Testvorrichtung gelegt.
3. Die gruppierten Sensoren werden nacheinander in zwei Testglocken gefahren und dort bei unterschiedlichen Temperaturen und Drücken getestet.
4. Die Sensoren werden wieder in Gruppen aus dem Testbereich entfernt und die Testergebnisse werden revidiert.
5. Bei einem positivem Testergebnis wird der Sensor auf eine Rolle bzw. Gurt platziert,
6. hingegen bei einem negativem Testergebnis wird der Sensor als Ausschuss markiert.

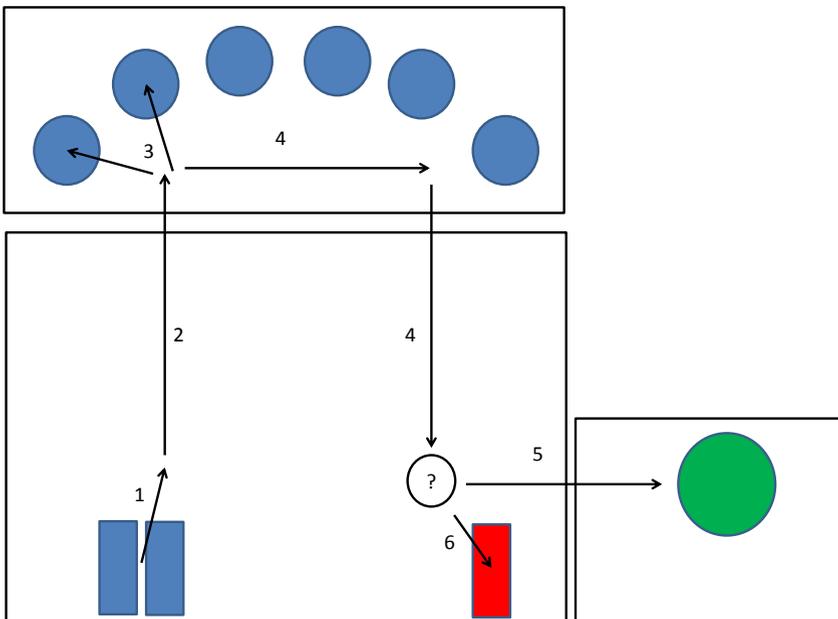


Abb. 5: Skizze der Testanlage mit markiertem Weg des Sensors

### 3.1 Synchronisation & Echtzeitabfragen der Maschinen-Logdateien

Während dem gesamten Prozess werden sowohl Ereignisse als auch Testergebnisse aufgezeichnet und größtenteils in Logdateien abgelegt. Ein direkter Zugang zu den Maschinen-

bzw. Sensordaten ist noch nicht möglich, jedoch geplant. Aufgrund dessen müssen die Logdateien zeitnah eingelesen und ausgewertet werden, um den aktuellen Zustand der Maschine und seiner Komponenten zu kennen. Am Ende wird jeder Sensor überprüft, ob dieser wirklich auf den Gurt platziert werden soll, oder in den Abfallkorb.

Insgesamt werden im beschriebenen Anwendungsfall fünf unterschiedliche Logdateiformate ausgewertet. Der Einleseprozess wird zwar synchronisiert gestartet und die entsprechende Anfangszeit markiert, jedoch kann dies im Laufe der Auswertung auseinanderlaufen, je nachdem, wie viele Informationen pro Logdateiformat weiterverarbeitet werden müssen. Außerdem ist bei der Auswertung der Daten zu berücksichtigen, dass die Maschinenuhren in der Anlage untereinander nicht synchronisiert sind. Somit müssen Echtzeitabfragen robust formuliert werden. Abfragen, welche Daten aus zwei unterschiedlichen Maschinen-Logdateien enthalten, müssen unabhängig voneinander bestehen und werden erst im Nachhinein zusammengebracht.

In Abschnitt 3.1.1 wird der implementierte Synchronisierungsmechanismus beschrieben, welcher die Synchronisierung der einzelnen Parserthreads garantiert. Abschnitt 3.1.2 beschreibt das Verfahren der Echtzeitabfragen bei fehlender Maschinen-Zeitsynchronisation.

### **3.1.1 Synchronisation der Maschinen-Logdateien**

Damit die Maschinendaten in ihrer korrekten zeitlichen Abfolge verarbeitet werden, wird ein Steuerprogramm (Scheduler) implementiert. Dieser läuft nach dem zeitbasiertem *Earliest Deadline First* Prinzip. Der Scheduler läßt von jeder Maschine eine Task ein und sortiert diese Task-Liste aufsteigend ihrem Fertigstellungstermin (Deadline). Die erste Task in der Liste bekommt demnach die höchste Priorität, da ihre Deadline als erstes zeitnah endet und der Prozess vorweg fertig sein muss.

### **3.1.2 Echtzeitabfragen bei fehlender Maschinen-Zeitsynchronisation**

Um den Verlauf des Sensors in der Anlage zu verfolgen, muss auf die fehlende Maschinen-Zeitsynchronisation geachtet werden. Andernfalls werden Echtzeitabfragen, welche strikt den zeitlichen Verlauf des Prozess folgen, unerwartet ungültig oder es gehen Daten bzw. Informationen verloren. Grund hierfür ist die im Anwendungsfall fehlende Maschinen-Zeitsynchronisation. Die Herausforderung besteht Informationen aus zwei unterschiedlichen Maschinen-Logdateien zu ziehen, welche jedoch von ihrer zeitlichen Folge abhängig sind. Für diesen Fall muss für jede Maschine jeweils eine Echtzeitabfrage formuliert werden, welche zunächst alle notwendigen Informationen sammelt. Erst nachdem beide Abfragen ausgeführt wurden, können die gesammelten Informationen zusammengeführt werden.

### 3.2 Bestimmung der Maschinenproduktivität

Ein wesentliches Merkmal zum identifizieren des Maschinenstaus ist u.a. den Durchsatz der Maschine zu ermitteln. In einem zuvor benutzerdefinierten Zeitabstand wird berechnet, wie viele Sensoren von der Maschine pro Stunde verarbeitet wurden. Zur Ermittlung der Kennzahl wird in der Streaming Analytics Plattform ein sich stets schiebendes Zeitfenster (Sliding Time Window) definiert. In Abb. 6 wird die Auswertung der Maschinenproduktivität dargestellt.

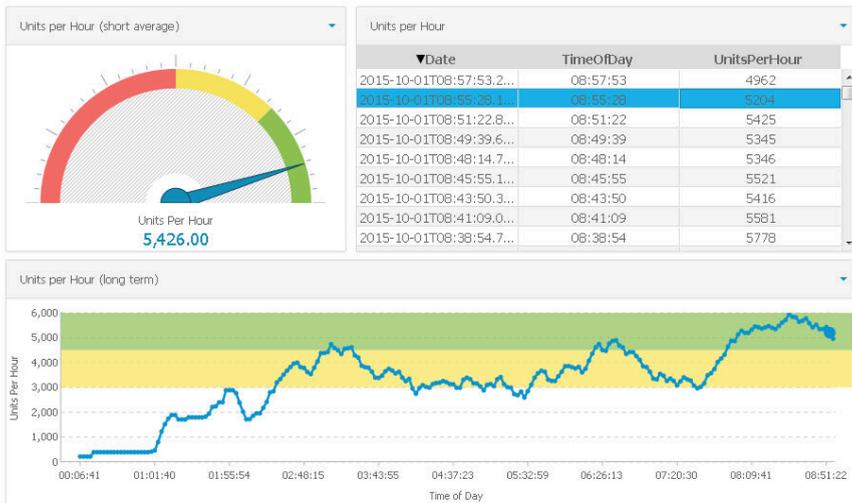


Abb. 6: Maschinenproduktivität einer Testanlage für Drucksensoren

In der Tabelle (oben rechts) werden die aktuell eingetroffenen Daten zur Auswertung der Maschinenproduktivität angezeigt. Das Barometer (oben links) visualisiert den aktuellen Status der Maschine. Bei einem hohen Durchsatz zeigt die Nadel in den grün eingezeichneten Wertebereich. Sinkt der Durchsatz, deutet die Nadel auf den gelben Bereich. Wird der rote Wertebereich angezeigt, läuft im Umkehrschluss die Maschine nicht störungsfrei. Den Verlauf der Maschinenproduktivität in den letzten neun Stunden wird als Liniendiagramm (unten) dargestellt mit ebenfalls eingefärbten Wertebereichen. Zu Beginn der Messung ist ein stärkerer Anstieg anzunehmen, da die Maschine neu gestartet wird. Nach ca. 1-2 Stunden hat sich der Messwert eingependelt und gibt Aufschlüsse über den Zustandsverlauf der Maschine.

### 3.3 Vorhersage für einen manuellen Eingriff

Ein positiv getesteter Sensor wird auf einen von zwei vorhandenen Gurten in der Anlage platziert. Auf einen Gurt passen entweder 5.000 oder 10.000 Sensoren. Ein Mitarbeiter sieht von außen zwar, welche Gurtgröße angebracht wurde, kann aber während der Maschinenlaufzeit nicht genau abschätzen, wann der Gurt voll wird und manuell ausgewechselt werden muss. Dies hat zur Folge, dass im Werk entweder Gurte zu früh ausgewechselt werden oder zu spät und die Maschine still steht. Durch eine *Verhältnismessung* (Dreisatz) kann der

Zeitpunkt zum Auswechseln des Gurtes berechnet werden. Zur Berechnung wird hierfür die Gurtgröße benötigt, zusammen mit der aktuellen Anzahl an Sensoren auf dem Gurt und den in Abschnitt 3.2 berechneten Durchsatz pro Stunde. In Abb. 7 wird das Abschwächen der verbleibenden Zeit (in Minuten) für den Wechsel des Gurtes bzw. der Rolle dargestellt.

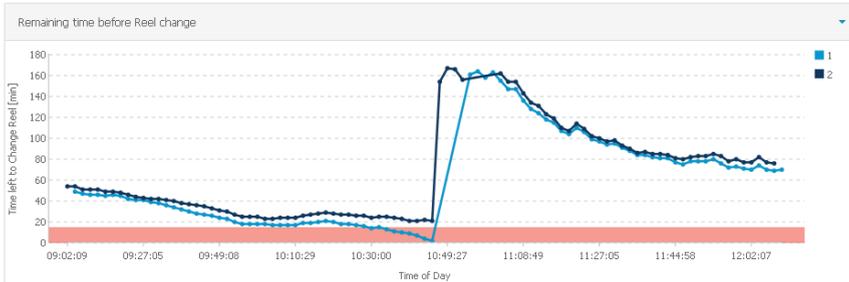


Abb. 7: Automatisierte Vorhersage für die verbleibende Zeit für das Wechsel der Rollen

Als Liniendiagramm sind die zwei Gurte zu erkennen, welche parallel befüllt werden. Auf der y-Achse wird die noch verbleibende Zeit dargestellt, bis die Rolle überfüllt ist. Erreicht die Linie den roten Bereich, soll sich der Mitarbeiter darauf einstellen, dass der Gurt zeitnah ausgewechselt werden muss. Der im Diagramm zu sehende Ausschlag zeigt, dass hier beide Gurte ausgetauscht wurden. Gurt Nr.1 wurde gewechselt, weil dieser tatsächlich voll war, allerdings hätte Gurt Nr.2 erst nach ca. 20 Minuten gewechselt werden müssen.

## 4 Zusammenfassung und Ausblick

Wir haben anhand zweier Beispiele aus der industriellen Chipfertigung gezeigt, wie eine echtzeitfähige Streaming Analytics Plattform<sup>4</sup> benutzt werden kann, um Aussagen über die Stabilität und Qualität des Fertigungsprozesses zu erhalten. Zum einen konnten Aussagen über die Güte von einzelnen Sensoren bestimmt werden, doch auch Aussagen über den Maschinenzustand sind leicht möglich, wenn man das nötige Expertenwissen einfließen lässt. Z.B. konnte der momentane Durchsatz bestimmt werden, oder auch der zeitliche Verlauf, so dass Auffälligkeiten leicht erkennbar sind. Desweiteren haben wir gezeigt, wie man auch Vorhersagen über eintreffende Ereignisse machen kann, so dass die Plattform auch für Predictive Maintenance Aufgaben einsetzbar ist.

## 5 Danksagungen

Wir danken Roland Schmidt, Suad Sejdovic, Joachim Teutsch, Tim Friedrich und Sebastian Büttner für anregende und fruchtbare Diskussionen und Anmerkungen.

Das diesem Bericht zugrundeliegende Vorhaben wurde mit Mitteln des Bundesministeriums für Bildung, und Forschung unter dem Förderkennzeichen 01IS14011C gefördert. Die Verantwortung für den Inhalt dieser Veröffentlichung liegt bei den Autoren.

<sup>4</sup> siehe <http://www.apamacommunity.com>

## Literatur

- [De14] Dean, J.: *Big Data, Data Mining, and Machine Learning*. John Wiley & Sons, Inc., Hoboken, New Jersey, 2014.
- [GS15] Gärtner, D.; Schimmelpfennig, J.: Vom Sensor zum Geschäftsprozess – Industrie 4.0 in der Stahlindustrie. In (Köhler-Schute, C., Hrsg.): *Industrie 4.0: Ein praxisorientierter Ansatz*. KS-Energy Verlag, Berlin, S. 128–136, 2015, ISBN: 978-3-945622-01-8.
- [He16] Hegenbarth, Y.: *Vorhersagemodelle mit Complex Event Processing zur Störungserkennung in einer Chip-Produktion*, Bachelorarbeit, Hochschule Darmstadt, 2016.
- [Ma67] MacQueen, J. B.: Some Methods for Classification and Analysis of MultiVariate Observations. In (Cam, L.; Neyman, J., Hrsg.): *Proceedings of the fifth Berkeley Symposium on Mathematical Statistics and Probability*. Bd. 1, University of California Press, S. 281–297, 1967.
- [Se16] Sejdovic, S.; Hegenbarth, Y.; Ristow, G. H.; Schmidt, R.: Proactive Disruption Management System: How Not to Be Surprised by Upcoming Situations. In: *Proceedings of the 10<sup>th</sup> ACM International Conference on Distributed and Event-based Systems*. DEBS '16, ACM, Irvine, California, S. 281–288, 2016, ISBN: 978-1-4503-4021-2.