

# **Integration maschineller Lernverfahren in eine Materialflusssimulation zur Verhaltensabstraktion und -vorhersage komplexer Fertigungssysteme**

Integration of Machine Learning Techniques in a Material Flow Simulation for  
Behaviour Abstraction and Prediction of Complex Manufacturing Systems

Toni Donhauser<sup>1</sup>, Dominik Kisskalt<sup>2</sup>, Andreas Mayr<sup>2</sup>,  
Michael Scholz<sup>2</sup>, Peter Schuderer<sup>1</sup>, Jörg Franke<sup>2</sup>,  
toni.donhauser@thi.de, dominik.kisskalt@faps.fau.de, andreas.mayr@faps.fau.de,  
michael.scholz@faps.fau.de, peter.schuderer@thi.de, joerg.franke@faps.fau.de

<sup>1</sup>Technische Hochschule Ingolstadt, Ingolstadt (Germany)

<sup>2</sup>Friedrich-Alexander-Universität Erlangen-Nürnberg (FAU), Lehrstuhl für  
Fertigungsautomatisierung und Produktionssystematik (FAPS), Erlangen (Germany)

**Abstract:** Modeling complex interactions and dependencies in production systems proves effortful in traditional event-based simulation tools mainly relying on a whitebox approach. In this context, the integration of machine learning techniques offers new possibilities for establishing a more efficient modeling of the systems behavior by using historic data. Therefore, this paper presents a concept for linking a material flow simulation with machine learning models. The implementation of this novel, data-driven modeling approach is shown using the example of the hardening process for calcium silicate masonry units. By using and comparing different supervised learning models, a behavior model for the complex manufacturing control of the autoclaving process could be created based on historical data of the real process. As a result, the generated behavior modeling does not depend on a priori knowledge, which significantly reduces the modeling effort in many of these complex simulation cases.


## **1 Ausgangssituation**

Materialflusssimulationen bieten zahlreiche Einsatzmöglichkeiten bei der Lösung komplexer Probleme aus Logistik und Produktion. Einzelne Fertigungsprozesse werden hierbei gemeinhin als Transformation eines Eingangsprodukts in ein Ausgangsprodukt über eine bestimmte Bearbeitungsdauer hinweg modelliert. Die Bearbeitungszeit ist im Regelfall a priori für die einzelnen Prozessschritte – teils auch in Abhängigkeit einzelner Eigenschaften der zu bearbeitenden Produkte – festgelegt. Ist sie allerdings von zusätzlichen Einflussfaktoren, wie dem Zustand umliegender

Prozesse und Anlagen im Gesamtsystem abhängig, so sind für eine hinreichend genaue Vorhersagequalität in vielen Fällen die zugrundeliegenden, oftmals komplexen und nicht vollends bekannten Zusammenhänge des Realsystems innerhalb des Simulationsmodells abzubilden. Dies wiederum setzt beim klassischen White-Box-orientierten Modellierungsansatz das Vorhandensein von umfassendem Wissen, meist in Form impliziten Wissens der Prozessexperten, voraus. Wenn die Prozesse jedoch durch vielfältige, nichtlineare Einflussfaktoren mit der umliegenden Produktionsumgebung in Wechselwirkung stehen, gestaltet sich eine manuelle White-Box-Modellierung ausgesprochen aufwändig und fehleranfällig, wenn nicht gar unmöglich. Kann das Verhalten der Fertigungsprozesse nicht hinreichend genau erklärt werden und das Zusammenwirken verschiedener Einflussfaktoren nicht detailgenau quantifiziert werden, so schränkt dies zwangsweise die Aussagekraft und Validität eines Simulationsmodells ein.

## 2 Problemstellung im Bereich der Kalksandsteinherstellung

Derartige Herausforderungen birgt auch die Simulation der Werksabläufe zur Herstellung des Baustoffs Kalksandstein (KS). Der Härteprozess der Rohlinge unterliegt dabei intensiven prozessualen und thermodynamischen Wechselwirkungen, die sich selbst physikalisch nur mit sehr hohem Aufwand modellieren lassen (Schlegel et al., 2013). Bei der Dampfhärtung, die zur Bildung stabiler, kristalliner Verbindungen zwischen den Sandkörnern dient, stellt ein zentraler Dampferzeuger Wasserdampf zur Autoklavierung der Rohlinge bereit, der über ein Leitungssystem den Autoklaven zugeführt wird (siehe Abb. 1).



**Abbildung 1:** Dampfsystem zur Härtung von Kalksandsteinen

Die erforderliche Dampfmenge und die damit verbundene Geschwindigkeit des Anfahrens des Härtekessels hängt von Faktoren wie der Umgebungstemperatur, dem Volumen und der Temperatur des Inhalts sowie der zu erreichenden Härtekurve ab. Hierin liegen erste Einflussfaktoren für die Bearbeitungszeit. Zudem ist es aus energetischen Gesichtspunkten erforderlich, den Restdampf am Ende eines Härtevorgangs von dem abfahrenden auf einen anfahrenden Kessel überzulassen. Hierbei entstehen Wartezeiten, die wiederum Einfluss auf die Gesamtbearbeitungsdauer nehmen.

Anhand der obigen Ausführungen ist das komplexe Zusammenwirken verschiedener Einflussfaktoren auf den Ablauf des Härteprozesses, der unter Einfluss der diesbezüglichen Sensorwerte regelbasiert gesteuert wird, ersichtlich. Alleine die

zugrundeliegende Steuerungslogik in das Simulationsmodell zu übertragen oder dort nachzumodellieren ist nicht ausreichend, da im Modell externe Einflüsse auf das Systemverhalten nicht hinreichend genau nachbildbar sind. Da zudem die Anfahr- und Abfahrzeiten abhängig von der Möglichkeit der Dampfüberleitung zwischen zwei Autoklaven in einem zeitlichen Rahmen von etwa 30-180 Minuten variieren können, ist eine Modellierung mit festen Bearbeitungszeiten nicht zielführend.

### **3 Bestehende Ansätze zur Abbildung komplexer Zusammenhänge in Simulationsmodellen**

Üblicherweise werden Fertigungsprozessen in Materialflusssimulationsmodellen feste Bearbeitungszeiten zur Abbildung der Dauer des Prozesses zugeordnet, die allenfalls in Abhängigkeit einzelner Einflussfaktoren, wie dem bearbeiteten Produkt, variieren. So greift auch die grundlegende Simulation für KS-Werke nach (Donhauser et al., 2015; Donhauser et al., 2016) auf formatabhängige Härtezeiten zurück. Die Literatur bietet zur Abbildung komplexer Zusammenhänge in Form von thermodynamischen Wechselwirkungen aber auch die Möglichkeit der physikalischen Modellierung (Junge, 2007; Schmidt und Pawletta, 2014) oder der Co-Simulation in einem thermischen Simulationsmodell, das auf Differenzialgleichungen basiert (Peter und Wenzel, 2015; Peter et al., 2017; Schlüter et al., 2017).

Einen alternativen Modellierungsansatz höherer Übertragbarkeit zwischen ähnlichen Anwendungsfällen bildet die Verwendung von Verfahren des Maschinellen Lernens (ML), wie sie für bestimmte Anwendungsfälle in (Laroque et al., 2017; Rippel et al., 2017; Kibira et al., 2015) bereits eingesetzt werden. Diese können Zusammenhänge verschiedener Ein- und Ausgangsgrößen, etwa diskreter Steuerungsvariablen oder kontinuierlicher Prozess- bzw. Sensordaten, auf Basis historischer Datensätze erkennen und in Form von ausführbaren ML-Modellen abstrahieren. So kann das Verhalten des Systems im Simulationsmodell basierend auf erfassten Daten aus dem Realsystem ohne genaue Kenntnis der zugrundeliegenden physikalischen Wirkprinzipien oder der inhärenten Steuer- und Regelungslogik nachgebildet werden.

Ein solcher Black-Box-Ansatz reduziert die Einbindung von Simulations- und Prozessexperten deutlich und senkt den Modellierungsaufwand durch die Nutzung bereits vorliegender Datensätze. Zeitgleich wird die Möglichkeit der kontinuierlichen Verbesserung eröffnet, da der Trainingsvorgang beispielsweise bei einer Umstellung der Produktion beliebig oft neu angestoßen werden kann. Durch die Integration von ML in Materialflusssimulationen wird die Herausforderung der effizienten und flexiblen Modellierung hochkomplexer Produktionsabschnitte adressiert.

### **4 Maschinelles Lernen zur detaillierten Abbildung des Härteprozesses bei der Simulation von Kalksandsteinwerken**


Wie bereits in Kapitel 2 beschrieben, stellt insbesondere der Härteprozess von Kalksandsteinen herkömmliche White-Box-Ansätze vor Herausforderungen, da eine präzise physikalische Modellierung nur mit hohem Aufwand umsetzbar ist. Nachfolgend soll daher die Implementierung eines ML-Modells zur Ermittlung der

erforderlichen Bearbeitungszeit sowie erforderliche Anpassungen zu dessen Interaktion mit dem Simulationsmodell behandelt werden.

#### 4.1 Untersuchungsrahmen

Zur datengetriebenen Abbildung des Härteprozesses soll ein ML-Modell an das Simulationsmodell angebunden werden, das das multiplen Einflussfaktoren unterliegende Systemverhalten auf Basis erfasster Sensorwerte nachbildet. Auch vorgelagerte Prozessschritte beeinflussen dieses Systemverhalten. Vor dem Härten der KS finden im Regelfall drei Prozessschritte statt. Zunächst wird das Rohgemisch aus Kalk, Sand und Wasser angemischt. Dieses reagiert anschließend unter Volumenausdehnung exotherm für 30 - 120 min in Reaktoren. Nach dem Transport über Förderbänder werden mittels hydraulischer Pressen Rohlinge hergestellt und auf Härtewägen gestapelt. Diese Förderhilfsmittel werden mittels einer Schiebebühne in Autoklaven geladen, bis deren maximale Kapazität erreicht ist. Nach dem manuellen Schließen der Türen kann der Härteprozess gestartet werden. (Donhauser et al., 2016)

Hierfür existieren Steinsorten-spezifische Härtekurven, deren Soll-Verlauf in Abbildung 2 schematisch dargestellt ist. Aufgrund von Dampfüberleitungen zwischen an- und abfahrenden Autoklaven stellt sich der Ist-Verlauf in der Aufheiz- und Abkühlungsphase als in die Länge gezogene Kurve dar. Wirkt es sich nicht negativ auf nachfolgende Prozessschritte und den Gesamtdurchsatz aus, wird in der Haltephase zu einem früheren Zeitpunkt die weitere Dampfzufuhr eingestellt, so dass die Druckkurve langsam abfällt. Zur Erreichung der erforderlichen Steinqualität ist es neben der Einhaltung maximaler Druckänderungsgeschwindigkeiten entscheidend, dass das Produkt aus Zeit und Druck, d. h. das Integral unter der Kurve in Abbildung 2, mindestens einen vorgegebenen Wert („bar-h-Wert“) erreicht.



**Abbildung 2:** Soll-Verlauf (Härtekurve) der Dampfversorgung eines Härtekessels bei der Autoklavierung von KS

Um im Zusammenwirken aller Autoklaven sowie des Dampferzeugers die fallspezifischen, individuellen Ist-Härtekurven in der Simulation nachzubilden, liegt ein Datensatz mit Sensordaten für jeden Härtevorgang vor, die über ein gesamtes Jahr im modellierten Werk erfasst wurden. Dieser enthält folgende Daten:

- Initiale Eigenschaftswerte und Einstellparameter sowie Ergebniswerte: Autoklav, Soll-Härtekurve, Start-/Endzeit, Dauer der Härtephasen, bar-h-Wert (Ist/Soll)
- Minütlich aufgezeichnete Sensorwerte:
  - Soll- und Ist-Druck
  - Scheitel- und Sohlentemperatur
  - Kondensatabflussmenge

- Prozessstatus (z. B. Frischdampfzufuhr, Haltephase mit Dampfzufuhr, Restdampfphase ohne Dampfzufuhr, Dampfabgabe an anderen Autoklav)
- Überleitbelegung (verknüpfter Autoklav)

Das gewünschte ML-Modell soll für jedes Inputszenario folgende Freiheitsgrade im Zeitverlauf möglichst so festlegen, wie sie im realen Härteprozess eingetreten wären:

- Überleitpartnerschaften: Verknüpfung zweier Härtekessel zur Dampfüberleitung zwischen Spender- (Haltephase abgeschlossen, siehe Abb. 2) und Empfängerkessel (Aufheizphase begonnen, siehe Abb. 2)
- Wartezeiten auf Spender- respektive Empfängerkessel (alle Ventile geschlossen), ehe Frischdampf zugeführt oder das Abdampfen gestartet wird.
- Höhe des Ausgleichsdrucks bei Dampfüberleitung sowie Überleitgeschwindigkeit

Mithilfe dieser Informationen ist es letztlich möglich, die Dauer des gesamten Härtevorgangs für einen Autoklav zu errechnen. Diese stellt die erforderliche Bearbeitungszeit für den Härteprozess in der Simulation dar.

### 4.2 Interaktion zwischen ML- und Simulationsmodell

Die erforderlichen Berechnungsschritte zur Nachbildung des Härteprozesses teilen sich auf das Simulations- und das ML-Modell auf. Grundsätzlich berechnet das Simulationsmodell alle Materialflüsse im KS-Werk. Wird Material im Bereich der Autoklaven prozessiert, so ruft die Simulation bei vollständiger Beladung eines weiteren Autoklaven das ML-Modell auf, um den Ablauf des Härteprozesses basierend auf dem aktuellen Status der Autoklavierung im gesamten Dampfsystem (vgl. Abb. 1) realitätsnah nachzubilden. Diese Interaktion zeigt Abbildung 3 auf.

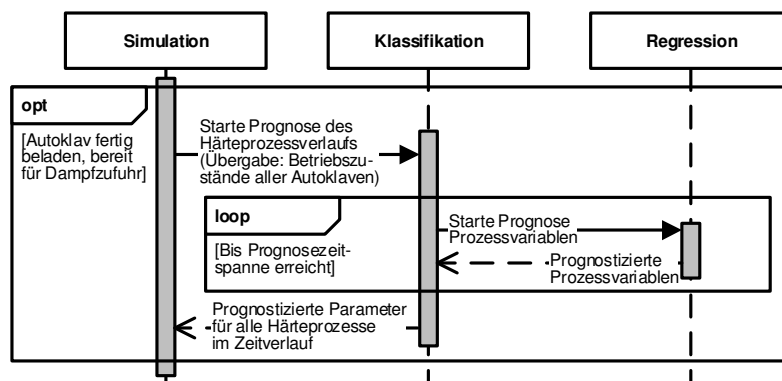


Abbildung 3: UML-Sequenzdiagramm zur Kommunikation zwischen ML-Modellen (Klassifikation und Regression) und Simulation

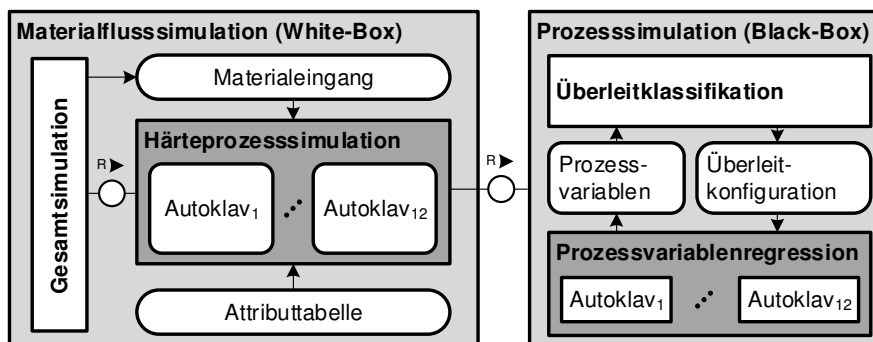
Auf Basis des aktuellen physischen und thermischen Zustands des Dampfsystems, der im Simulationsmodell fortlaufend aktualisiert wird, errechnet das ML-Modell Ablaufentscheidungen (Klassifikation) und künftige Änderungsraten der thermodynamischen Zustände (Regression). Diese gibt es an die Simulation zurück, welche gemäß diesen Vorgaben den weiteren Verlauf der Härtung nachbildet. Notwendige Parameter sind hierfür die Druckverläufe aller Autoklaven für den

weiteren Zeitverlauf sowie die Zeitpunkte für den Abschluss von Härte- und Überleitvorgängen mit dann erreichten Drücken.

Zu Beginn der Interaktion mit dem ML-Modell sind die im vorangehenden Abschnitt aufgeführten Parameter und Werte aus der Simulation zu übergeben, um den aktuellen Stand der Fertigung im ML-Modell abzubilden. Hierbei errechnen sich die initialen Temperaturen der Autoklaven in Abhängigkeit des Materialflusses in den vorangegangenen Prozessschritten und der vorherigen Nutzung der Kessel. Diese sind mithilfe einer Energiesimulation nach (Donhauser et al., 2019) zu bestimmen.

### 4.3 Erforderliche Anpassungen im Simulationsmodell

Zur Kommunikation mit dem ML-Modell sind im Simulationsmodell Schnittstellen zum Aufruf externer Programme und für den Datenaustausch einzurichten sowie die auszutauschenden Daten bereitzustellen. Wie Abbildung 4 zeigt, dient eine Socket-Schnittstelle dem Aufruf des ML-Modells innerhalb eines Python-Tools. Dieses wird mit gesammelten Daten aus den benutzerdefinierten Attributen der Autoklaven-Objekte aus der Simulation versorgt, um den aktuellen Zustand aller Härteessel mitzuteilen. Der Aufruf erfolgt über eine Steuerungsmethode aus einem Autoklaven-Objekt, sobald dieser Härteessel voll beladen und bereit zur Dampfbeschießung ist. Nach dem Aufruf wartet die Methode auf die Übertragung der Ergebnisse aus dem ML-Modell über die Attributtabelle.




**Abbildung 4:** Interaktionen zwischen und innerhalb ereignisdiskreter Ablaufsimulation und Machine-Learning-Modellen, dargestellt in der Fundamental Modeling Concepts (FMC) Notation

### 4.4 Implementierung des ML-Modells

Dem Referenzprozess CRISP-DM folgend, werden die Daten in einem ersten Schritt grafisch analysiert und anhand der eigenen Vorarbeiten zur KS-Herstellung (Donhauser et al., 2016; Donhauser et al., 2015; Donhauser et al., 2018) mit den zugrundeliegenden Produktionsabläufen in Verbindung gebracht. Anschließend erfolgt die Aufbereitung und Vorverarbeitung der Daten (u.a. Synchronisierung, Korrektur fehlender / fehlerhafter Messwerte).

Der betrachtete Datensatz beinhaltet sowohl die parallel zur Fertigung aufgezeichneten, kontinuierlichen Prozessvariablen als auch die hierzu synchronisierten, diskreten Steuerungssignale für die zwölf Autoklaven über einen


Zeitraum von 365 Tagen. Die kontinuierlichen Prozessvariablen umfassen dabei unter anderem den Istdruck ( $p$ ), Scheiteltemperatur ( $T_{st}$ ), Sohletemperatur ( $T_{sl}$ ) und die beiden Kondensatdurchsatzströme ( $k_1$ ,  $k_2$ ). Die Prozessvariablen wiederum geben den internen Steuerungszustand (u. a. „Haltephase“, „Türen geöffnet“, ...) für den jeweiligen Autoklav an und beschreiben die aktuelle Dampfüberleitungskonfiguration ( $\ddot{U}$ ). Sind zwei Autoklaven zum Dampf- bzw. Druckausgleich miteinander verbunden, so wird die Nummer des jeweils anderen Autoklavs protokolliert (siehe Abb. 5). Die Datenerfassung erfolgte ausschließlich bei aktiven Härtevorgängen und wurde für alle Prozessgrößen mit einer Taktung von einem Datenpunkt pro Minute durchgeführt.



**Abbildung 5:** Beispielhafte Verlaufskurven von Solldruck (oben), Sohle-Temperatur (mittig) und Überleitbelegung (unten) für zwei sequentielle Härtevorgänge eines Autoklavs

Eine Korrelationsanalyse über Prozessvariablen und aktive Überleitbelegungen ( $\ddot{U}$ ) lässt für Ist-Druck ( $p_i$ ) und Sohlen-Temperatur ( $t_{sl}$ ) eine hohe negative Pearson-Korrelation mit der aktiven Überleitbelegung erkennen (siehe Abb. 6). Dies ist ein zu erwartender Zusammenhang, da der Überleitvorgang nur energetisch von Vorteil ist, wenn gegenüber dem Empfänger-Autoklav eine hohe Differenz der inneren Energie besteht.

Nach der initialen Datenanalyse wird auf Basis der kontinuierlichen Prozessvariablen des beschriebenen Datensatzes mittels überwachter maschineller Lernverfahren auch die Kombination der Prozessvariablen betrachtet, um bestehende Muster wiederzuerkennen und eine bestmögliche Klassifizierung der Überleitbelegung zu erreichen. Zur Datenvorverarbeitung, dem Training und der Ausführung des trainierten ML-Modells wird die Programmiersprache Python in Form eines externen Tools eingesetzt und mit dem Datensatz gekoppelt. Alle weiteren essentiellen datenverarbeitenden Schritte sind unter Nutzung der Python-Packages numpy, pandas und scikit-learn implementiert.



**Abbildung 6:** Korrelationsmatrix mit Angabe des Pearson-Korrelationswertes und Darstellung der Prozessvariablenverteilung auf der Diagonale

Da bei der Bestimmung der Überleitpaare durch die Fertigungssteuerung der Zustand aller am Netz angeschlossenen Autoklaven von Relevanz ist, sind einzelne pro Autoklav dedizierte Klassifikationsmodelle nicht zielführend. Stattdessen wird ein Modell benötigt, welches alle Prozessgrößen der im jeweiligen Moment aktiven Autoklaven als Eingangsgröße aufnimmt.

Ändert sich die Überleitkonfigurationsprognose des Klassifikators gegenüber der vorherigen Prognose, so wird für die von der Änderung betroffenen Autoklaven ein Regressionsmodell angestoßen, welches wiederum den weiteren Verlauf der kontinuierlichen Prozessvariablen prognostiziert. Hierbei werden in zeitdiskreten Schritten wechselweise die Klassifikationskomponente und die Regressionsfunktionalität auf Basis ihrer jeweiligen Ausgangswerte ausgeführt, bis die angestrebte Prognosezeitspanne erreicht ist.

## 5 Validierung

Der Fokus der praktischen Realisierung liegt auf der Prognose der aktiven Überleitkonfiguration auf Basis der aufgenommenen Prozessvariablen. Bei dem skizzierten Problem handelt es sich um ein Multi-Klassen- und Multi-Output-Problem, wodurch die Auswahl potentieller ML-basierter Klassifikationsverfahren eingeschränkt wird. Da die Dimensionalität des Inputvektors auch bei einer schwankenden Anzahl an aktiven Autoklaven konstant bleiben muss, werden Zeitreihen inaktiver Autoklaven mit Werten außerhalb des im Prozess möglichen Zustandsraums aufgefüllt. Zur Optimierung und Auswahl geeigneter maschineller Lernverfahren wurde die Zielgröße durch eine One-Hot-Kodierung in ein Multi-Label-Problem überführt. Hierdurch kann die Treffergenauigkeit als zu optimierendes Gütekriterium genutzt werden. Um eine Über- bzw. Unteranpassung des Modells auf



den vorliegenden Datensatz zu vermeiden, wurde ein Kreuzvalidierungsverfahren beim Trainingsprozess mit fünf Durchläufen angewendet.

Das aus dem Ensemble Learning stammende Random-Forest-Tree-(RFT)-Modell erreichte dabei gegenüber Decision Tree, Extra Tree Classifier und K-Neighbors-Classifer-Modellen die höchste Prognosegüte. Der finale RFT ist mit 128 Schätzmodellen und einem „gini“ Entropie-Kriterium initialisiert. Hierdurch konnte eine finale Prognosegüte mit einer Treffergenauigkeit (engl: Accuracy) von 95,29 % und einer Trefferquote (engl: Recall) von 96,94 % erzielt werden.

## 6 Fazit und Ausblick

Die Modellierung des Härteprozesses für KS mithilfe von datenbasierten ML-Verfahren erlaubt eine erheblich präzisere und übertragbarere Abbildung in der Simulation, als dies mit konventioneller Simulationsmodellierung möglich ist. Zudem kann die Güte des Modells durch fortlaufende Aufnahme von Realdaten und deren Einbezug in das ML-Modell kontinuierlich gesteigert werden. Für die Interaktion des ML- und Simulationsmodells sind lediglich eine Aufruf- sowie eine Datenaustauschnittstelle erforderlich.

Die realisierten Prognoseleistungen durch den Einsatz überwachter Lernverfahren ermöglicht die benötigte datengetriebene Abstraktion des Steuerungsverhaltens für die Dampfüberleitung zwischen den Autoklaven. Im Rahmen der künftigen Weiterentwicklung der vorgestellten Systematik werden neben einer Optimierung hinsichtlich Vorverarbeitung, Modellauswahl und Parameteroptimierung für die Überleitklassifizierung die Regressionsmodelle für die Prozessabschnitte implementiert und das Gesamtmodell evaluiert.

## Danksagung

Die Autoren danken der Arbeitsgemeinschaft industrieller Forschungsvereinigungen (AiF) für die Förderung des Forschungsprojekts mit der IGF-Nr. 20 EWN. Dieses Projekt wird unter Federführung der AiF durchgeführt und vom Bundesministerium für Wirtschaft, Mittelstand und Energie (BMWi) auf Grundlage eines Beschlusses des Deutschen Bundestages finanziert.

## Literatur

- Donhauser, T.; Ebersbach, T.; Franke, J.; Schuderer, P.: Test and validation of an algorithm for simulation-based optimization of calcium silicate masonry unit production. *Procedia CIRP* 72 (2018) S. 249–254.
- Donhauser, T.; Ehrhardt, J.; Rackow, T.; Franke, J.; Schuderer, P.: Simulation-based Optimization of the Energy Consumption in the Hardening Process for Calcium Silicate Masonry Units. In: Franke, J.; Kreitlein, S. (Hrsg.): *Energy Efficiency in Strategy of Sustainable Production*, Nürnberg, 2015, S. 249–256.
- Donhauser, T.; Mayr, A.; Baier, L.; Franke, J.: Verfolgung von Bauteil- und Anlagentemperaturen in Produktionssystemen zur Energiesimulation bei thermischen Einflussfaktoren. In: Putz, M.; Schlegel, A. (Hrsg.): *Simulation in Produktion und Logistik*, Chemnitz, zur Veröffentlichung angenommen, 2019.

- Donhauser, T.; Rackow, T.; Hirschbrunn, J.; Schuderer, P.; Franke, J.: Valid Methodology for Using Discrete Event Simulation to Improve the Resource Consumption for the Manufacturing of Masonry Units. *Procedia CIRP* 41 (2016) S. 57–62.
- Junge, M.: *Simulationsgestützte Entwicklung und Optimierung einer energieeffizienten Produktionssteuerung*. Kassel: Kassel Univ. Press 2007.
- Kibira, D.; Hatim, Q.; Kumara, S.; Shao, G.: Integration Data Analytics and Simulation Methods to Support Manufacturing Decision Making. In: Yilmaz, L.; Chan, W.K.V.; Moon, I.-C.; Roeder, T.; Macal, C.; Rossetti, M. (Hrsg.): 2015 Winter Simulation Conference, Huntington Beach, CA, 2015, S. 2100–2111.
- Laroque, C.; Skoogh, A.; Gopalakrishnan, M.: Functional Interaction of Simulation and Data Analytics – Potentials and Existing Use-Cases. In: Wenzel, S.; Peter, T. (Hrsg.): *Simulation in Produktion und Logistik*, Kassel, 2017, S. 403–412.
- Peter, T.; Reiche, L.; Wenzel, S.; Fehlbier, M.: Coupled Simulation of Energy and Material Flow - a Use Case in an Aluminium Foundry. In: Chan, Wai Kin et al. (Hrsg.): *Winter Simulation Conference*, Las Vegas, NV, 2017, S. 3792–3803.
- Peter, T.; Wenzel, S.: Simulationsgestützte Planung und Bewertung der Energieeffizienz für Produktionssysteme in der Automobilindustrie. In: Rabe, M.; Clausen, U. (Hrsg.): *Simulation in production and logistics*, Dortmund, 2015, S. 535–544.
- Rippel, D.; Lütjen, M.; Redecker, M.A.; Decker, A.; Freitag, M.; Thoben, K.-D.: Simulating the Energy Consumption of Machines in Compound Feed Manufacturing for Investment Decisions. In: Wenzel, S.; Peter, T. (Hrsg.): *Simulation in Produktion und Logistik*, Kassel, 2017, S. 79–88.
- Schlegel, A.; Stoldt, J.; Putz, M.: Erweiterte Integration energetischer Betrachtungen in der Materialflusssimulation. In: Dangelmaier, W.; Laroque, C.; Klaas, A. (Hrsg.): *Simulation in Produktion und Logistik*, Paderborn, 09. - 11. Oktober 2013, 2013, S. 187–196.
- Schlüter, W.; Henninger, M.; Buswell, A.; Schmidt, J.: Schwachstellenanalyse und Prozessverbesserung in Nichteisen-Schmelz- und Druckgussbetrieben durch bidirektionale Kopplung eines Materialflussmodells mit einem Energiemodell. In: Wenzel, S.; Peter, T. (Hrsg.): *Simulation in Produktion und Logistik*, Kassel, 2017, S. 19–28.
- Schmidt, A.; Pawletta, T.: Hybride Modellierung fertigungstechnischer Prozessketten mit Energieaspekten in einer ereignisdiskreten Simulationsumgebung. In: *ASIM 2014 - 22. Symposium Simulationstechnik*, Berlin, 2014, S. 109–116.