

Fachtagung Mechatronik 2019 Paderborn, 27.-28.03.2019





Veranstaltungsort: Heinz Nixdorf MuseumsForum Fürstenallee 7, 33102 Paderborn

- Mechatronische Produkte (neue Funktionalitäten, Industrie 4.0, Kosteneffizienz, Zuverlässigkeit, ...)
- Ressourceneffizienz (Energie, Material, ...)
- Automatisierte Mobilität
 (Konzepte, Modelle, Sensorik)
- Systems Engineering und Entwicklungsmanagement (Prozesse, Verfahren, Software, ...)
- Innovative Konzepte und digitale Geschäftsmodelle (Modelle, Regelung, Optimierung, Eco-Systeme)

- Nutzerfreundlichkeit und Akzeptanz (Assistenzsysteme, Schnittstellen, Interaktion, Gesetzgebung, ...)
- Systemvernetzung und Systemintegration (Konzepte, Verfahren, ...)
- Smarte Aktoren (Konzepte, Beispiele, ...)
- Serienfertigung mechatronischer Produkte (Fallbeispiele, Komponenten, Architektur, Qualitätsmanagement, ...)

www.VDI-Mechatroniktagung.de

Mehrkriterielle Prozessoptimierung in der digitalisierten Produktion Multi Criteria Process Optimization in the Smart Factory

Johannes Zumsande, M. Sc.*, Karl-Philipp Kortmann, M. Sc., Mark Wielitzka, M. Sc., Dipl.-Ing. Christian Hansen und Prof. Dr.-Ing. Tobias Ortmaier

Leibniz Universität Hannover, Institut für Mechatronische Systeme, 30167 Hannover, Deutschland *johannes.zumsande@imes.uni-hannover.de

Kurzfassung

Moderne Produktionsanlagen weisen im Zuge der fortschreitenden Automatisierung eine erhöhte Parametrierbarkeit auf. Gleichzeitig wächst im Spannungsfeld der globalisierten Marktwirtschaft der Bedarf nach optimaler, flexibler und individueller Fertigungsplanung und -ausführung, was die Parametrierung eines Produktionsprozesses zusätzlich erschwert. Dem gegenüber stehen jedoch auch neue Möglichkeiten diesen Herausforderungen zu begegnen. Eine umfassende und strukturierte Datenbasis im Sinne der Industrie 4.0 ermöglicht es, dynamisch auf neue Umgebungsbedingungen zu reagieren und die Produktion bezüglich teils konträrer Ziele (z. B. Taktzeit und Leistungsspitze der Anlage) optimal einzustellen. Im Rahmen dieser Arbeit wurde eine mehrkriterielle Prozessoptimierung, die auf einem gemessenen und physikalisch modellierten Prozessabbild basierte, an einer zu Forschungszwecken zur Verfügung stehenden Modellfabrik entworfen. Zur Validierung dienten die folgenden drei Szenarien: Optimierung des Energieverbrauchs bei minimaler Taktzeit, Begrenzung der Anlagenleistungsspitze und die Reduktion der mechanischen Belastung eines Roboters.

Abstract

In the cause of increasing automation, modern production systems are highly tuneable. Simultaneously, today's globalized market requires an optimal, flexible and individual production planning, which further complicates the parametrization of a production process. At the same time new possibilities of facing those challenges arise. In the context of a Smart Factory, a comprehensive and well-organized database provides the knowledge to respond dynamically to new environmental conditions and tune the process with respect to concurrent gains (e. g. cycle time and plant peak power of the plant). We propose a multi-criteria process optimization based on a digital twin of a production plant. It has been applied to and

evaluated on a model factory, which is used for research studies, by means of three demonstrating scenarios: Optimizing energy consumption within fastest cycle time, limit peak power and reduce wear of a robot.

1 Einleitung

Die industrielle Produktion steht im kontinuierlichen Wandel. War es in den letzten Jahrzehnten vor allem der stetig steigende Automatisierungsgrad der Produktionsanlagen, erhöht heute die flexible Produktionsplanung mit dem verstärkten Trend zur Produktindividualisierung die Komplexität und Parametrierbarkeit moderner Produktionsprozesse zusätzlich [1]. Getrieben von den Kundenanforderungen hat sich die Dimensionalität der Prozessparametrierung erhöht. Wo früher hochparametrierbare Produktionsanlagen hinsichtlich weniger Produktvariationen und minimaler Taktzeit ausgelegt wurden, ist der Produktionsprozess heute aufgrund der engmaschig vernetzen und globalisierten Wirtschaft in eine flexible Produktionsplanung eingebettet [2]. Beispielsweise muss auf veränderliche Randbedingungen (z. B. Kundenaufträge, Energiepreise, Logistik oder Anlagenzustand) möglichst dynamisch reagiert werden, um hohe Lagerkapazitäten und lange Lieferzeiten zu vermeiden. Eine Parametrierung hinsichtlich teils konträrer Zielgrößen (Taktzeit, Prozessstabilität, Ressourceneffizienz, usw.) [3] erfolgt dabei aktuell häufig basierend auf dem individuellen Erfahrungsschatz des Anlagenbedieners. Hieraus resultieren mehrere Problemstellungen. Die manuelle Adaption der Prozesssteuerung hinsichtlich wechselnder Zielkriterien stellt eine große Herausforderung für das Personal dar; insbesondere wechselndes Maschinenpersonal birgt hohe Risiken hinsichtlich der Prozessqualität. Weiterhin können Parameterwechselwirkungen in der Prozesskette i. d. R. nicht berücksichtigt werden, sodass technologische Unterstützung oder eine Automatisierung der Prozesssteuerung erforderlich sind, welche idealerweise auf ein umfassendes Prozessabbild fußen [4]. In [5] wird beschrieben, wie ein solches Prozessabbild in einer intelligenten Fabrik organisiert werden kann. Durch eine holistische Informationsgrundlage sind Lösungen des Optimierungsproblems unter der Vielzahl von Randbedingungen (z. B. Auftragslage, Gesetze, Verhalten der Konkurrenz und der Kunden, Energiepreise, Verfügbarkeit von Ersatzteilen) möglich, welche den Anforderungen einer modernen und globalisierten Marktwirtschaft genügen. Das Prozessmodell CRISP-DM (Cross-Industry Standard Process for Data Mining) nach Wirth [6] beschreibt dabei eine definierte, zyklische Abfolge an Schritten, hin zu einer Lösung im Kontext der Industrie 4.0. In der vorliegenden Publikation wird ein Ansatz zur mehrkriteriellen Prozessoptimierung hinsichtlich konträrer Zielgrößen präsentiert, der ein Baustein in dem Konzept der Smart Factory sein kann, um die holistischen Informationen auf die Feldbusebene zu übertragen. Bezogen auf das CRISP-DM werden die Phasen *Data-Understanding*, *Data-Preparation*, *Modeling* und *Evaluation* adressiert.

Um eine wiederholbare und robuste Prozesssteuerung zu ermöglichen, ist eine Überführung in ein mathematisches Modell unabdingbar. Nur so können komplexe Wechselwirkungen abgebildet und die optimale Parametrierung des modellierten Produktionsprozesses garantiert werden. Durch eine Erhöhung der Modellgüte kann die Genauigkeit der Optimalsteuerung sukzessive auch im Prozess erhöht werden. Durch die Optimierung werden die Einstellparameter *x* des Produktionsprozesses dahingehend variiert, dass das Optimum bzgl. der unterschiedlich gewichteten und/oder beschränkten Zielkriterien *y* erreicht wird. Häufig sind die gewünschten Zielgrößen jedoch nicht direkt messbar und müssen durch physikalische, datenbasierte oder heuristische Modelle beschrieben werden.

Im Rahmen dieser Veröffentlichung wurden die Einstellparameter Ausführgeschwindigkeit (Override) o_k und ein verzögerter Bearbeitungsstart $t_{k,del}$ der *K* Roboter untersucht, um die Zielgrößen Taktzeit, Taktreserve, Energieverbrauch, Leistungsspitze und Verschleiß zu optimieren. Alle Größen bis auf den Verschleiß wurden durch physikalische Modelle bestimmt und letzterer als proportional zur maximalen mechanischen Lastspitze angenommen (einfaches heuristisches Modell).

2 Die Modellfabrik



Abbildung 1 Die Modellfabrik am Institut für Mechatronische Systeme

Die vorgestellten Methoden sind an der Modellfabrik implementiert und getestet worden, die in **Bild 1** und in **Bild 2** dargestellt ist. Diese bildet einen vollautomatisierten Handhabungsprozess bestehend aus drei Roboterkinematiken und optionaler Zwischenkreiskopplung ab. Während des Prozessdurchlaufs wird eine Palette pneumatisch aus einem Magazin auf das Förderband A geschoben. Durch drei Lichtschranken, die entlang des Förderbandes angebracht sind, wird das Förderband A zur Bearbeitung an drei Stationen gestoppt. An der ersten Station platziert ein SCARA-Roboter Aluminiumklötze in die Aussparungen in der Palette. Die Klötze besitzen ihrerseits Aussparungen, in die ein Delta-Roboter Kunststoffsterne legt. Die Sterne werden dabei von einer Kamera auf Förderband B erkannt und vom laufenden Förderband gegriffen. Den Abschluss des Handhabungsprozesses bildet ein Regalbediengerät, welches die Paletten von Förderband A greift und in einem Hochregallager platziert. Eine größtmögliche Produktindividualität wird durch verschiedene Sequenzen und Mengen an zu platzierenden Objekten abgebildet. Um eine industrienahe, getaktete Transferstraße abbilden zu können, wird die Modellfabrik im Rahmen dieser Veröffentlichung ohne Material betrieben. Aufgrund baulicher Restriktionen wäre ansonsten eine simultane Bearbeitung aller Roboter unmöglich gewesen.



Abbildung 2 Schematische Darstellung der Modellfabrik mit Palettenmagazin und Ausstoßer (1), Rutsche mit Aluminiumklötzen (2), SCARA-Roboter (3), Förderband A mit Paletten, Förderband B mit Sternen, Lichtschranken (4), Kamera zur Erfassung der Sternposition und –orientierung (5), Delta-Roboter (6), Regalbediengerät (7) und Hochregallager (8)

Jeder Roboter erhält von der Ablaufsteuerung die Zielposition (Palettenaussparung oder Regalfachnummer) und die Freigabe zur Bearbeitung. Anschließend senden die Roboter, solange die Ausgangsposition nicht wieder erreicht wurde, das Signal xBusy an die Ablaufsteuerung zurück. Um den Prozess zu beschleunigen, wird nach dem Ende der Interaktion mit dem Förderband A ein xProceed gesendet. So kann das Fördeband A auch dann verfahren, wenn der Roboter seine Bewegung noch nicht beendet hat. Die Leistungsflüsse sind in Bild 3 schematisch dargestellt. Drei Versorger speisen je einen Zwischenkreis, die optional zusammengeschaltet werden können. Übersteigt die Zwischenkreisspannung einen Schwellwert, wird die Energie über einen Bremswiderstand dissipiert. Jedes Modul besitzt eine individuelle Anzahl an Achsen bestehend aus Inverter, Motor und Getriebe. Die beiden Förderbänder werden dabei über den Versorger des Delta-Roboters gespeist. Da sich das Förderband B ausschließlich während der Bearbeitung des Delta-Roboters bewegt, wird dieses Förderband dem Delta zugeordnet. Die Geschwindigkeiten der Förderbänder werden nicht variiert und können somit mit einer konstanten Förderenergie (für Förderband A) bzw. mit konstanter Leistung für Förderband B modelliert werden.

3 Datenaufbereitung

Als Vorbereitung der späteren mehrkriteriellen Prozessoptimierung muss zunächst das Verhalten der Anlage bekannt und strukturiert verfügbar sein. Eine ideale Möglichkeit



Abbildung 3 Die Leistungsflüsse für die drei Module mit Versorgern, Zwischenkreisen mit Bremswiderständen und Achsen bestehend aus Inverter, Motor und Getriebe (v. l. n. r.)

bietet sich während der Inbetriebnahme der Produktionsanlage [7]. Iterativ werden Einstellparameter variiert und die Bewegungen zunächst mit geringen Ausführgeschwindigkeiten getestet und bewertet, um diese nachfolgend sukzessive zu erhöhen. Die Messdaten wurden im Rahmen dieser Veröffentlichung mit verschiedenen Overrides (0, 1 - 1, 0)mit einer Schrittweite von 0,1) aufgenommen. Aus diesen Daten lässt sich ein Abbild des Prozesses gewinnen, welches die Abhängigkeit der Prozessausgänge von den Einstellparametern beschreibt. Um individualisierte Prozesse beschreiben zu können, müssen die Messdaten zunächst in die verschiedenen Teilbewegungen zerlegt werden, welche dann später zu beliebigen Bearbeitungen zusammengesetzt werden können. Dies kann manuell geschehen oder durch das Anlernen eines Zustandsautomaten (z.B. nach Maier [8]), der basierend auf den Steuersignalen der Roboter den diskreten Ablauf erlernt. An der Modellfarbik sind die Signale Zielposition, xProceed und xBusy zur Identifikation der Teilbewegungen verwendet worden. Durch die Übermittlung der Zielposition war ein automatisiertes Zuordnen der Daten zu bestimmten Teilbewegung ebenfalls möglich.

Zur Bestimmung der Energieverläufe der einzelnen Module sind aus Vorarbeiten bekannte physikalische Modelle [9] eines anderen Versuchsstandes an der Anlage identifiziert worden. Es werden dabei konstante Verlustleistungen, die ohmschen Statorwickelverluste, Ummagnetisierungsverluste und proportionale Verlustterme (z. B. Getriebereibung) berücksichtigt. Um den Rechenaufwand während der Optimierung und die benötigte Datenmenge zu reduzierend, sind aus den gemessenen und partitioniert vorliegenden Datenverläufen Merkmale berechnet worden, die in der Optimierung zur Bestimmung der Zielkriterien verwendet werden. Dabei existieren drei Detaillierungsgrade: Prozesskonstanten, Kennfelder und Messdatenverläufe. Die Prozesskonstanten sind nicht von den Einstellparameter x abhängig und können somit als singulärer Wert hinterlegt werden. Da die Förderbandgeschwindigkeit konstant ist, sind sowohl die Förderzeit $t_{\rm F}$ als auch die Förderenergie W_F von Förderband A solche Prozesskonstanten. Ebenfalls konstant ist die Leistung von Förderband B ${\it P}_{\rm FB}$ und die Anlagenstillstandsleistung Pkonst.

Treten bei der Berechnung der Zielgrößen *y* keine Abhängigkeiten zwischen den einzelnen Robotermodulen auf, werden die Merkmale separat in Abhängigkeit der Einstellparameter *x* in Kennfeldern gespeichert und Zwischenwerte z. B. mittels linearer Interpolation angenähert. Dies umfasst die Ausführzeit $t_{k,n}$ von Roboter *k* und Bewegung *n*, die Zeit $t_{k,n,prc}$, nach der das Signal *xProceed* gesendet wird (wenn es sich um das letzte zu platzierende Objekt handelt), die Bewegungsenergie $W_{k,n}$ und die mechanische Leistungsspitze $\hat{P}_{k,n,mech}$.



Abbildung 4 Darstellung des gemessenen Verlaufs, der Hüllkurve und des tiefpassgefilterten Signals für den SCARA-Roboter

Treten zur Bestimmung der Zielgrößen Wechselwirkungen im Prozess auf (z.B. bei der Bestimmung der Anlagenleistungsspitze oder aufgrund der Zwischenkreiskopplung) müssen die Messdatenverläufe in Abhängigkeit des Overrides gespeichert und die Merkmale während der Optimierung berechnet werden. Zur Steigerung der Robustheit und Verringerung der Rechenzeit bietet sich zur Datenreduktion die Regressionen der Datenverläufe, die Tiefpassfilterung und Unterabtastung des Signals oder einer Hüllkurve an (siehe **Bild 4**). Die Leistungsverläufe $P_{k,n,roh}(t)$ der Module sind mit Ausnahme der Förderbänder auf diese Weise hinterlegt worden. Zur Bestimmung des Energieverbrauchs sind die Messdaten tiefpassgefiltert und mit 20Hz unterabgetastet worden ($P_{k,n}(t)$). Um die Grenzen der Anlagenleistungsspitze einzuhalten, ist eine Hüllkurve $\widehat{P}_{k,n}(t)$ verwendet worden. Dabei ist mittels der Formel

$$\widehat{P}_{k,n}(t_i) = \max_{t \in [t_i - \Delta t, t_i + \Delta t]} P_{k,n}(t)$$
(1)

der Maximalwert im Intervall $[t_i - \Delta t, t_i + \Delta t]$ gespeichert worden. Durch die zu wählenden Breite Δt des Zeitfensters kann eine obere Hüllkurve realisiert werden. Zu sehen ist, dass im vorliegenden Fall die Intervallbreite Δt proportional zur Leistungsanforderungen steigt, um diese einerseits robust abzubilden und andererseits die Minima, welche die Grundlage der Optimierung mittels verzögerter Startzeiten bilden, nicht überzubewerten.

Der interpolierte Verlauf für einen nicht gemessenen Override wird aus einem oberen und unteren Stützsignal bestimmt. Hierzu wird zunächst die Ausführzeit der interpolierten Bewegung über den näherungsweise antiproportionalen Zusammenhang zwischen dem Override und der Ausführzeit ermittelt. Anschließend wird das untere und obere Stützsignal auf diese Länge gestreckt bzw. gestaucht, um über die gewichtete Summe das unbekannte Signal anzunähern. Die Gewichte entsprechen hierbei den normierten Abständen zwischen dem Override des interpolierten Verlaufs und den Overrides der Stützkurven (siehe **Bild 5**).



Abbildung 5 Verlauf der beiden Stützlinien (Override 0,5 und 0,7) und der Vergleich zwischen der gefilterten Messung (Override 0,6) und dem geschätzten Verlauf

4 Prozessmodellierung

Die Merkmale bzw. Verläufe einzelner Teilbewegungen n der Module k liegen in einer zentralen Datenbank vor. Um den aktuellen Prozess abzubilden, müssen diese basierend auf der bekannten Auftragslage an den Modulen zu einem Gesamtprozess zusammengefügt werden. Hierdurch wird es möglich, die Zielkriterien, welche sich für die spezifische Belegung und Einstellparameter (o_k und $t_{k,del}$) ergeben, zu bestimmen.

Die Taktzeit berechnet sich aus den Verzögerungszeiten $t_{k,del}$, den Bearbeitungszeiten $t_{k,n}$, der *xProceed*-Zeit der letzten Bewegung $t_{k,N,prc}$ und der Förderzeit t_F von Förderband A zu:

$$t_{\text{Takt}} = \max\left[t_{\text{F}} + \max_{k \in [1,K]} \left(t_{k,\text{del}} + \sum_{n=1}^{N-1} t_{k,n} + t_{k,N,\text{prc}}\right), \\ \max_{k \in [1,K]} \left(t_{k,\text{del}} + \sum_{n=1}^{N} t_{k,n}\right)\right].$$
(2)

Hieraus kann die Taktreserve

$$t_{k,\text{res}} = t_{\text{Takt}} - \left(t_{k,\text{del}} + \sum_{n=1}^{N} t_{k,n}\right)$$
(3)

jedes Modules bestimmt werden. Der Energieverbrauch der Anlage ergibt sich aus den Stillstandsleistungen P_{konst} der Anlage, der Taktzeit und (im Falle einer nicht vorhandenen Zwischenkreiskopplung) der Addition der Teilenergiebedarfe $W_{k,n}$ und des Energieverbrauchs der Förderbandbewegung $W_{\rm F}$:

$$W_{\text{ges}} = W_{\text{F}} + t_{\text{Takt}} P_{\text{konst}} + \sum_{k=1}^{K} \sum_{n=1}^{N} W_{k,n}.$$
 (4)

Die Leistung aller Inverter berechnet sich durch das Zusammenfügen der Verläufe der Einzelbewegungen $P_{k,n}(t)$ und anschließender Summation über alle Module unter Verwendung der konstanten Leistung P_{FB} von Förderband B zu

$$P_{\rm inv,ges}(t) = P_{\rm FB} + \sum_{k=1}^{K} \sum_{n=1}^{N} P_{k,n}(T),$$
(5)

$$\widehat{P}_{\text{inv,ges}}(t) = P_{\text{FB}} + \sum_{k=1}^{K} \sum_{n=1}^{N} \widehat{P}_{k,n}(T)$$
(6)

mit

$$T = t - \sum_{i=1}^{n-1} t_{k,i}.$$
 (7)

Hieraus lässt sich direkt die maximale Anlagenleistungsspitze und über den Leistungsfluss des Zwischenkreises $P_{\text{DC}}(t)$ der Energieverbrauch W_{ges} bei vorhandener Zwischenkreiskopplung bestimmen:

$$\widehat{P}_{\text{ges}} = P_{\text{konst}} + \max_{t \in [0, t_{\text{Takt}}]} \widehat{P}_{\text{inv,ges}}(t),$$
(8)

$$P_{\rm DC}(t) = \begin{cases} P_{\rm inv,ges}(t) & \text{für } P_{\rm inv,ges}(t) > 0, \\ 0 & \text{sonst.} \end{cases}$$
(9)

$$W_{\text{ges}} = t_{\text{Takt}} P_{\text{konst}} + \int_0^{t_{\text{Takt}}} P_{\text{DC}}(t) dt.$$
 (10)

Die mechanische Lastspitze ergibt sich für jedes Modul aus dem Maximum aller Teilbewegungen:

$$\widehat{P}_{k,\text{mech}} = \max_{n \in [1,N]} \widehat{P}_{k,n,\text{mech}}.$$
(11)

5 Mehrkriterielle Optimierung

Eine Möglichkeit der mehrkriteriellen Optimierung ist die Ermittlung der Paretofront des Optimierungsproblems mittels genetischem Algorithmus [10]. Das Ergebnis ist die Menge aller optimalen Lösungen für eine bestimmte Belegung, womit die Auswahl des optimalen Parametersatzes durch vorgegebene Gewichtungen und Restriktionen vorgenommen werden kann. Dem Vorteil, dass alle optimalen Lösungen bekannt sind, steht der Nachteil einer langen Rechenzeit gegenüber. Hier bietet die Überführung in ein einkriterielles Optimierungsproblem Vorteile, da nur die optimale Lösung bezüglich einer Belegung und einer bestimmten Gewichtung und Restriktion der Zielgrößen und Einstellparameter ermittelt wird. Jedoch muss bei einer Änderung der Gewichte und Restriktionen die Optimierung immer erneut durchgeführt werden. Daher bietet sich die einkriterielle Optimierung vor allem für häufig wechselnde Auftragslagen (Losgröße 1) und einer somit erforderlichen Onlineimplementierung an. Vor diesem Hintergrund wird nachfolgend genauer auf die einkriterielle Optimierung eingegangen.

Ein solches Optimierungsproblem kann bspw. durch einen Partikel-Schwarm-Algorithmus [11–13] gelöst werden. Hierbei werden im Parameterraum eine zu wählende Anzahl an Partikeln initialisiert, die jeweils einen Parametersatz repräsentieren. Nun kann für jedes Partikel das Gütefunktional bestimmt und basierend auf den Güten der Partikel die deren Position und Geschwindigkeit angepasst werden. Um hierbei ein besseres Konvergenzverhalten zu erhalten, ist eine Normierung der Zielgrößen vorteilhaft. Hierzu wurde das Intervall [0,1] gewählt, wobei 0 das optimierungstechnische Minimum und 1 das Maximum ist. Zur Bestimmung der Maximal- und Minimalwerte wird eine einkriterielle Optimierung für jedes zu betrachtende Zielkriterium durchgeführt. Häufig müssen in der Produktion bestimmte Zielkriterien z. B. eine gewünschte Taktzeit erreicht werden. Hier ergibt es Sinn, das Zielkriterium über enge Restriktionen abzubilden und die restlichen Zielkriterien mit Gewichtungsfaktoren zu belegen. Durch die zufällige Initialisierung der Partikel kann es jedoch vorkommen, dass alle Partikel die engen Restriktionen verletzen. Daher werden Partikel an den Grenzen des Suchraums gezielt initialisiert.

6 Ergebnisse

Es wurden drei Szenarien optimiert und anhand von Messungen (inklusive Anlagenleistungsmessungen) validiert. Die drei Szenarien waren:

- I Optimierung des Energieverbrauchs und der Anlagenleistungsspitze (je mit 0,5 gewichtet) bei Einhalten der minimalen Taktzeit (über Restriktion abgebildet),
- II Optimierung des Energieverbrauchs und der Taktzeit (je mit 0,5 gewichtet) bei Limitierung der Anlagenleistungsspitze auf 1300W,
- III Optimierung des Energieverbrauchs und der Taktzeit (je mit 0,5 gewichtet) bei Limitierung der mechanischen Leistungsspitze des Delta-Roboters auf 50% bzgl. der Referenzbahn.

Die Belegung war für die drei Szenarien bis auf den Delta-Roboter, der in Szenario III neun statt sechs Sterne platzierte, identisch und die Rechendauer war zur Überprüfung der Echtzeittauglichkeit auf 25 s beschränkt. Als Referenzfall für Szenario I wurden die Verzögerungszeiten auf 0s und die Ausführgeschwindigkeiten auf 1,0 gesetzt. In der Onlineimplementierung bestimmt sich die Vorgabe der Rechendauer des neuen Auftrages aus der berechneten Taktzeit des aktuellen Auftrages. Die aus der Optimierung resultierenden Einstellparameter sind in **Tabelle 1** und die Ergebnisse in **Tabelle 2** zu sehen. Die dazugehörigen Leistungsverläufe sind in **Bild 6** für alle drei Szenarien dargestellt.

 Tabelle 1
 Einstellparameter der Szenarien I, II und III

Sz.		SCARA	Delta	RBG
Ι	o_k	1,000	0,930	0,676
	$t_{k,del}$	0,000 s	0,076 s	0,000 s
II	o_k	0,971	0,460	0,438
	$t_{k,\text{del}}$	0,000 s	5,575 s	0,196 s
III	o_k	0,970	0,425	0,391
	$t_{k,del}$	1,989 s	0,000 s	2,995 s

 Tabelle 2
 Resultate f
 ür die Szenarien I und II mit der Leistungsspitze Anlagenleistungsspitze sowie Szenario III mit der mechanischen Leistungsspitze des Delta-Roboters

	Taktzeit	Leistungsspitze	Energieverbrauch
Ref.	29,8 s	3,6kW	18,6kJ
Sz. I	29,8 s	2,0 kW	18,2 kJ
Red.	0,0%	44,4%	2,2%
Sz. II	41,4s	1,3 kW	23,4 kJ
Ref.	29,8 s	121,5W	18,6kJ
Sz. III	42,7 s	54,6W	24,2 kJ
Red.	-43,3%	55,1%	-30,1%

Bei Szenario I zeigt sich anhand der Ergebnisse und Leistungsverläufe, dass die Anlagenleistungsspitze um 44,4% reduziert werden konnte. Dies ist vor allem auf die dominante Leistungscharakteristik des Regalbediengerätes zurückzuführen, welches verlangsamt werden konnte. Für Szenario II wird die maximale Leistung von 1300W leicht überschritten. Mögliche Ursachen sind Ungenauigkeiten der Energiemodelle oder äußere Einflüsse wie Temperatur und Einlaufverhalten der Motoren.



Abbildung 6 Die Ergebnisse für die Szenarien I, II und III (v. o. n. u.)

Bei Szenario III ist der Parametersatz der Referenzbahn durch eine mehrkriterielle Optimierung ohne die Restriktion der mechanischen Leistungsspitze bestimmt worden. Er stellt daher schon ein Optimum des Prozesses dar. Um die Vorgabe der mechanischen Beanspruchung in Szenario III einzuhalten, musste der Prozess verlangsamt werden, wodurch Optimierungsspielraum für das Regalbediengerät und den SCARA-Roboter geschaffen wurde. Aufgrund der wesentlich längeren Taktzeit konnte der Energieverbrauch pro Takt jedoch nicht reduziert werden.

7 Fazit und Ausblick

Im Rahmen dieser Veröffentlichung ist ein erster Ansatz zur mehrkriteriellen Prozessoptimierung implementiert worden. Basierend auf einer strukturierten Datengrundlage können beliebige Belegungen bzgl. Taktzeit, Taktreserve, Leistungsspitze, mechanische Belastung und Energeiverbrauch optimiert werden. In Zukunft wird das Konzept in eine bestehend Cloud-Infrastruktur [14] an der Modellfabrik eingegliedert, um jederzeit aktuelle Daten der Anlage zur Verfügung zu haben. Im Rahmen der erneuten Datenaufnahme für diese Veröffentlichung hat sich eine große Veränderung gegenüber älteren Messungen gezeigt. Es hat sich z. B. die Leistungsspitze der Anlage bei maximalen Ausführgeschwindigkeiten von 7,4kW auf 3,6kW reduziert. Dies ist auf neue Regelungsmethoden, veränderte Achsgrenzwerte, dem Einlaufverhalten und veränderliche Umgebungsbedingungen zurückzuführen und kann über adaptive Variablenverläufe in einer Cloud abgebildet werden. Des Weiteren kann eine statistische Aussage über das Einhalten eines Zielkriteriums getroffen werden, wenn jede Teilbewegung mehrmals hinterlegt wird. Durch die Verknüpfung von Modellen und Messdaten in einer zentralen Datenbank lassen sich die verschiedenen am Institut bekannten Methoden einfach identifizieren und implementieren. Schlussendlich ist in der realen Produktion eine Überführung in monetäre Zielkriterien sinnvoll, um den unterschiedlichen globalen Herausforderungen begegnen zu können.

8 Literatur

- [1] Ramsauer, C.: *Industrie* 4.0 *Die Produktion der Zukunft*. WINGbusiness 3 (2013), Nr. 2013, S. 6–12
- [2] Kagermann H.: Change through digitization Value creation in the age of Industry 4.0. Management of permanent change (2015). S.23-45
- [3] Sundström, N.; Wigström, O.; Lennartson, B.: Conflict between energy, stability, and robustness in production schedules. IEEE Transactions on Automation Science and Engineering (2017). 14-2, ISSN 1545-5955, S. 658-668.
- [4] Kagermann, H., Wahlster, W., Helbig, J. (Hrsg.) (2013): Deutschlands Zukunft als Produktionsstandort sichern – Umsetzungsempfehlungen für das Zukunftsprojekt Industrie 4.0 Abschlussberichtdes Arbeitskreises Industrie 4.0. April 2013
- [5] Gröger, C.; Kassner, L.; Hoos, E.; Königsberger, J.; Kiefer, C.; Silcher, S.; Mitschang, B.: *The Datadriven Factory*. In: ICEIS 2016 Proceedings of the 18th International Conference on Enterprise Information Systems 2016. 25./28. April 2016 Rom. Springer 2016. ISBN 978-3-319-62385-6. S. 40-52.
- [6] Wirth, R. and Hipp, Jochen: CRISP-DM: Towards a

Standard Process Model for Data Mining. In: Proceedings of the 4th International Conference on the Practical Applications of Knowledge Discovery and Data Mining 2000. 11./13. April 2000 Manchester, UK. Practical Application Company 2000. ISBN 978-1-90-24260-8-2. S. 29-39.

- Kiel, E. (Hrsg.): Antriebslösungen: Mechatronik für Produktion und Logistik. Hamburg: Springer-Verlag, 2007.
- [8] Maier, A.; Niggemann, O.; Vodenčarević, A.; Just, R.; Jaeger, M.: Anomaly detection in production plants using timed automata. In: 8th International Conference on Informatics in Control, Automation and Robotics (ICINCO). Juli 2011 Noordwijkerhout, Niederlande.
- [9] Eggers, K.; Hansen, C.; Kotlarski, J.; Ortmaier, T.: *Reduction of Energy Consumption by Optimized Robot Cell Design*. In: Proceedings of the Symposium on Automated Systems and Technologies 2014. 2./13. Mai 2014 Hannover. PZH Verlag 2014. ISBN 978-3-944586-84-7. S. 65-70.
- [10] Deb, K.; Pratap, A.; Agarwal, S.; Meyarivan, T.: A fast and elitist multiobjective genetic algorithm: NSGA-II. IEEE transactions on evolutionary computation, Vol 6(2), 2002. S. 182–197.
- [11] Kennedy, J.;Eberhart, R. Particle Swarm Optimization. In: Proceedings of the IEEE International Conference on Neural Networks. Perth, Australia, 1995, S. 1942–1945.
- [12] Mezura-Montes, E.; Coello Coello, C. A.: Constraint-handling in nature-inspired numerical optimization: Past, present and future. Swarm and Evolutionary Computation, 2011. S. 173–194.
- [13] Pedersen, M. E. H.: Good Parameters for Particle Swarm Optimization. Hvass Laboratories Technical Report no. HL1001, 2010.
- [14] Maurer, I.; Riva, M. H.; Hansen, C.; Ortmaier, T.: Cloud-based Plant and Process Monitoring based on a Modular and Scalable Data Analytics Infrastructure. In: Tagungsband des 2. Kongresses Montage Handhabung Industrieroboter, 2017.