



Foto: AMAG AG

Kristin Samac

Ein Vorgehenskonzept zur Senkung der Bestände innerhalb von Herstellprozessen

Die Dynamik des Marktes und eine strategische Ausrichtung als Nischenproduzent in der Prozessindustrie fordern eine Produktion in kleinen Losen und eine hohe Produktdifferenzierung gepaart mit hoher Lieferfähigkeit und -flexibilität. Das führt zu hohen Beständen. In diesem Beitrag wird ein Vorgehensmodell zur Lösung der Problemstellung von zu hohen Beständen im Prozess vorgestellt. Die Phasen des Vorgehensmodells finden sich im DMAIC Prozess des Prozessmanagements wieder. Nach der Zieldefinition und Systemabgrenzung werden Daten aufbereitet, Analyseinstrumente ausgewählt und an die Gegebenheiten im Unternehmen angepasst. Um das konkrete Problem zu analysieren eignen sich das Modell der Produktionskennlinien und die Gesamtanlageneffektivität als Indikator. Durch Anwendung dieser Instrumente und Data Mining, durchgeführt nach dem CRISP-DM, werden Muster erkannt und Potenziale zur Optimierung identifiziert. Im Sinne von Double Loop Learning startet der Prozess nach der Umsetzung der erarbeiteten Maßnahmen mit neuen Leitwerten erneut oder setzt in einer vorigen Phase ein.

Für einen Nischenproduzent in der Prozessindustrie stellen die Variantenvielfalt, kurze Lieferzeiten und hohe Termintreue kritische Erfolgsfaktoren dar um in der Dynamik des Marktes bestehen zu können. „[...] neben der Kompetenz im Bereich Forschung, Entwicklung und Technologie ist ein hohes Maß an Flexibilität mit möglichst kurzen Reaktionszeiten auf individuelle Kundenwünsche“ (AMAG 2013, S. 16) gefordert. Das verlangt eine Produktion in kleinen Losen und eine hohe Produktdifferenzierung gepaart mit hoher Lieferfähigkeit und -flexibilität, was prinzipiell zu hohen Beständen führt. Hohe Bestände bedeuten gebundenes Kapital und verursachen lange Durchlaufzeiten. Werden die Bestände reduziert, besteht einerseits die Gefahr

an Flexibilität einzubüßen und andererseits die Anlagen nicht voll auslasten zu können. In einer anlagenintensiven Industrie wie der Prozessindustrie ist eine hohe Anlagenauslastung gefordert. Eine Schlüsselrolle zur Lösung dieses Planungsdilemmas kommt den Mitarbeitern der Produktionsplanung und Disposition zu, die durch ein adäquates Analyse- und Informationssystem unterstützt werden sollen.

Vorgehenskonzept

Zur Entwicklung dieses Analyse- und Informationssystems wurde ein Vorgehenskonzept erstellt, welches Modelle und Methoden inkludiert, die bei der Festlegung der optimalen Bestände unterstützen und zu einer Verbesserung

führen sollen. Dieses besteht aus neun Phasen. Abbildung 1 zeigt diese sowie den Ablauf und die Schleifen zwischen denselben.

Die neun Phasen des Vorgehenskonzepts können in den DMAIC Prozess eingegliedert werden. DMAIC beschreibt die Phasen im Prozessmanagement – Define, Measure, Analyse, Improve und Control. Zuerst soll das Problem definiert, im Folgenden die Ist-Situation gemessen und analysiert werden, sodass daraus Handlungen für die Verbesserung abgeleitet und umgesetzt werden können. In der Control-Phase werden die Verbesserungen verankert und standardisiert. Werden die zwei Prozesse übereinander gelegt, können die Phasen „Zieldefinition“ und „Systemabgrenzung“ aus Abbildung

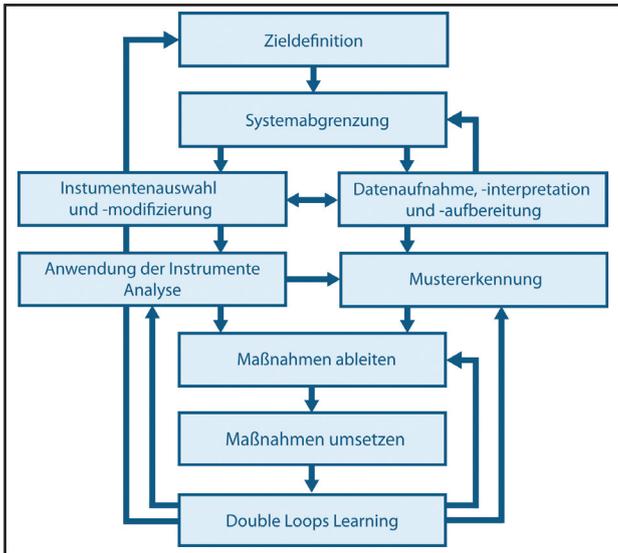


ABB. 1: VORGEHENSKONZEPT (EIGENE DARSTELLUNG)

1 dem Abschnitt „Define“ zugeordnet werden. „Dateninterpretation und -aufbereitung“ sowie die „Instrumentenauswahl und -modifizierung“ gehören thematisch zu „Measure“ und die Phasen „Anwendung der Instrumente“ und „Mustererkennung“ zu „Analyse“. „Improve“ inkludiert die Phasen „Maßnahmen ableiten und umsetzen“ und die Phase „Double Loop Learning“ passt thematisch zu „Control“ (Siehe Abbildung 2). Die Phase des Data Mining (CRISP-DM) (darauf wird später genauer eingegangen) erstreckt sich über „Measure“ und „Analyse“ und wird nochmals durch einen Kreislauf beschrieben.

Ausgehend von der Problematik hoher Bestände im Prozess, ist das Ziel die Bestände zu minimieren ohne die Anlagenauslastung zu verringern und die Termintreue zu verschlechtern. Die Definition der Ziele erfolgt am Beginn. Es wird kommuniziert was mit dem Projekt erreicht werden soll. Ebenso werden die Systemgrenzen abgesteckt, sodass der zu analysierende und zu verbessernde Bereich festgelegt ist. Im dritten Schritt erfolgt die Auswahl geeigneter Instrumente für die Analyse.

Im Allgemeinen bilden Modelle den Originalprozess nicht absolut realitätsgetreu ab, sondern sollen essentielle Eigenschaften, die auf einen bestimmten Anwendungszweck zugeschnitten sind, in ausreichender Genauigkeit wiedergeben. Modelle sind in Betracht auf das Ziel und den Zweck auszuwählen (Wiendahl & Nyhuis 2004, S. 2). Bei der Wahl von Kennzahlen gilt „so wenig wie möglich und so viel wie nötig“. Es ist nicht fördernd, eine Viel-

zahl von Kennzahlen zur Analyse heranzuziehen wenn diese nicht aussagekräftig sind.

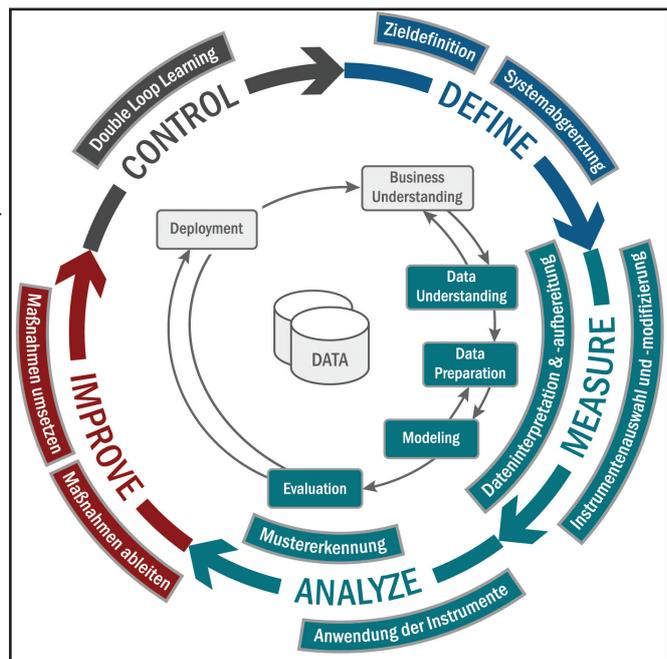
Produktionskennlinien und OEE

Bei der gegebenen Problematik, niedrige Bestände im Prozess anzustreben und die Anlagen voll auszulasten (Dilemma der Ablaufplanung) eignet sich das Wirkmodell der Produktionskennlinien. Die logistische Kennlinie steht in Verbindung mit dem Trichtermodell und dem Durchlaufdiagramm, welche sich dem Durchsatz und Bestand an Anlagen widmen (Nyhuis & Wiendahl 2012, S. 61). Die Produktionskennlinie bildet „[...] die Wirkzusammenhänge der logistischen Zielgrößen Bestand, Leistung und Durchlaufzeit ab [...]“ (Münzberg et al. 2009, S. 44). Die Berechnung des Betriebspunktes und die Darstellung auf der Kennlinie machen Verbesserungspotenziale sichtbar. Verbesserungen durch die Reduktion des Bestandes oder durch Erhöhung der Verfügbarkeit und damit der Leistung werden durch diese Berechnung identifiziert und dargestellt (Samac 2014, S. 33 f.). Abbildung 3 zeigt Produktionskennlinien mit dem Verlauf der Leistung, Durch-

laufzeit, Reichweite und Übergangszeit im Bezug auf den Bestand, sowie die Richtung der Verschiebung der Kennlinien bei Verbesserungen. Mit diesem Modell können die Mitarbeiter der Produktionsplanung und Disposition sehen, wie hoch der aktuelle Bestand ist und wie niedrig er sein könnte ohne die Anlagenauslastung zu reduzieren. Um das aggregatspezifische Modell in der Prozessindustrie anwenden zu kön-

nen, muss es auf die gegebenen Bedingungen angepasst werden.

Nyhuis' Produktionskennlinie ist ein deduktiv-experimentelles und statisches Erklärungsmodell (Beckmann et al. 2014, S. 23). Der deduktive, allgemeingültig interpretierbare Anteil ist die zugrundeliegende Modellstruktur. Die Parameter zur Anpassung an reale Gegebenheiten sind experimentell (Nyhuis & Wiendahl 2012, S. 61). Dabei handelt es sich um den Streckfaktor Alpha und den C_{Norm} -Funktionswert. Beide Parameter beeinflussen die Krümmung der Kennlinie (siehe Abbildung 3) und die Platzierung des idealen Bestandsbereichs. In den C_{Norm} -Funktionswert fließen die bestandsbedingten Leistungsverluste ein (Nyhuis & Wiendahl 2012, S. 78). Der Streckfaktor beeinflusst die Höhe des Pufferbestandes und kann über die Belastungsstreuung berechnet werden (Busse et al. 2012, S. 724 ff.). Durch eine realitätsgetreue Anpassung der beiden Parameter werden



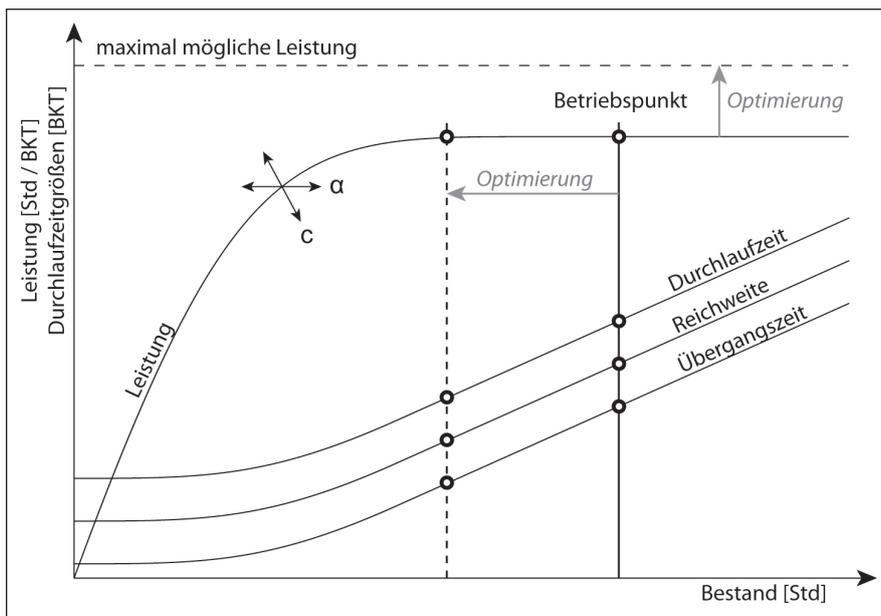


ABB. 3: PRODUKTIONSKENNLINIE (IN ANLEHNUNG AN NYHUIS & WIENDAHL 2012, S. 84)

In diese Faktoren fließen sechs Verlustquellen ein: Anlagenausfall, Rüsten/Einrichten, Leerlauf und Kurzstillstände, verringerte Taktgeschwindigkeit, Anlaufschwierigkeiten und Qualitätsmängel (Al-Radhi 2002, S. 8 ff.). Durch diese Kennzahl werden anlagenwirksame Verluste erkennbar. Werden diese Verluste reduziert kann die Leistung erhöht, damit können mehr Aufträge abgearbeitet und die Produktivität gesteigert werden.

Allgemein ist bei der Auswahl der Instrumente darauf zu achten, dass die Anwendungsbedingungen der Instrumente vor Ort gegeben sind. Eventuell können Adaptionen und Anpassung erforderlich sein. Ist eine Anpassung an die örtlichen Gegebenheiten nicht möglich, muss eine erneute Auswahl getroffen werden.

Die Qualität der Ergebnisse der Analyseinstrumente ist von der Qualität der Daten abhängig. Nur wenn die Daten richtig und plausibel sind, können es die Resultate ebenfalls sein. Ist die Datenbasis nicht korrekt, stimmen die Kennzahlen nicht, ergeben falsche Werte und führen zu falschen Schlüssen. Deswegen sind Daten zu verstehen, zu hinterfragen und auf Plausibilität zu prüfen. Gegebenenfalls müssen die Daten genauer erhoben oder auf anderen Wegen beschafft werden. Unter anderem gehen darauf CHAPMAN ET AL. (2000) in dem von Ihnen beschriebenen

CRISPS-DM (CRoss-Industry Standard Process for Data Mining) ein.

CRISP-DM (CRoss-Industry Standard Process for Data Mining)

Die Daten werden nicht nur als Input für die Analyseinstrumente benötigt. Durch Data Mining können zusätzliche Erkenntnisse erlangt werden. Unter „Data Mining ist die Zusammenfassung von Methoden und Algorithmen [...]“ (Pietsch & Memmler 2003, S. 58) für „[...] die automatische und nichttriviale Suche nach Wissen in Messdaten“ (Lusti 1999, S. 250) zu verstehen. CHAPMAN ET AL. (2000) haben den Data Mining Prozess in einem Zyklus dargestellt. Dieser Zyklus besteht, wie in Abbildung 2 dargestellt, aus sechs Phasen. Im ersten Schritt gilt es die Projektziele und Anforderungen des Projektes zu verstehen, diese in ein Data Mining Problem zu konvertieren und einen vorläufigen Plan zum Erreichen der Ziele zu erstellen. Danach startet die „understanding phase“ mit der ersten Sammlung der Daten und Aktivitäten zum Vertraut machen mit den Daten. Qualitätsprobleme werden identifiziert und erste Erkenntnisse aus den Daten gewonnen bzw. Teilergebnisse, aus denen Hypothesen, bezüglich versteckter Informationen, geformt werden können. Die nächste Phase (Data preparation) beinhaltet alle Aktivitäten um das finale Datenset aus den Rohdaten zu erstellen. Diese Tätigkeiten müssen

wahrscheinlich öfters in verschiedenen Reihenfolgen durchgeführt werden, beispielsweise dokumentieren, tabellieren, Attribute selektieren, transformieren und säubern der Daten. Im vierten Schritt erfolgt die Auswahl und Anwendung von Modellierungstechniken. Die Parameter werden kalibriert um optimale Werte zu erhalten. Auf der nächsten Ebene des Projektes wird das entwickelte Modell (oder Modelle) bewertet. Alle Schritte der Entwicklung werden überprüft, um sicher zu gehen, dass mit diesem Modell die Projektziele erreicht werden können. Eines der Hauptziele ist herauszufinden, ob ein wichtiges Thema bzw. Problem übersehen wurde. Am Ende dieser Phase sollte eine Entscheidung über die Verwendung der Data Mining Ergebnisse feststehen. Im letzten Abschnitt gilt es das gewonnene Wissen bereitzustellen. Im einfachsten Fall kann dies durch einen Report geschehen, oder komplex durch die Implementierung eines sich wiederholenden Data Mining Prozesses im gesamten Unternehmen (Chapman et al. 2000, S. 10f.).

Aus der Anwendung der Produktionskennlinien wissen die Disponenten welcher Bestand in den Stau- und Pufferlager angestrebt werden soll. Der OEE-Wert zeigt die Angriffspunkte um die verlustfreie Produktion (pro Arbeitszeit) zu erhöhen. Aus diesen Erkenntnissen und denen des Data Mining werden Maßnahmen abgeleitet und umgesetzt. Damit ist der Prozess nicht abgeschlossen. Zur stetigen Verbesserung muss der Output zum Input gemacht, bzw. die Anforderungen und Ziele geändert und laufend dem sich dynamisch ändernden Auftragsspektrum angepasst werden.

Double Loop Learning

Double Loop Learning oder organisationales Lernen beschreibt Lernprozesse in zwei Schleifen. Im Gegensatz zum Einschleifen-Lernen, bei dem die Wertvorstellungen einer Handlungstheorie nicht geändert werden, führt das Doppelschleifen-Lernen zu einem Wertewechsel der handlungsleitenden Theorien und der Strategien und Annahmen. Die beiden Rückmeldeschleifen verbinden die Auswirkungen des Handelns mit den Strategien und Wertvorstellungen (Argyris & Schön 2006,

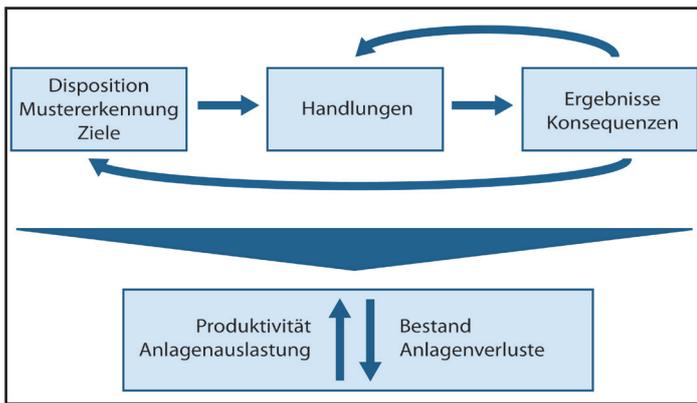


ABB. 4: DOUBLE LOOP LEARNING (EIGENE DARSTELLUNG)

S. 35 f.). Ausgehend von dem Problem hoher Bestände und der Bedingung der möglichst hohen Anlageneffizienz wurden Analysen durchgeführt und Handlungen umgesetzt. Der Prozess des Einschleifen-Lernens wäre nach dem Eintreten der Verbesserung durch die Umsetzung der Handlungen abgeschlossen. Das Ziel ist erreicht. Wenn das Problem erneut auftritt, werden die gleichen Handlungen vorgenommen. Beim Doppelschleifen-Lernen werden nach der Umsetzung und Verbesserung die Ausgangssituation und die Ziele neu betrachtet, da diese sich geändert haben. Der Prozess beginnt von vorne oder in vorgelagerten Phasen erneut.

In Abbildung 4 sind die Schleifen abgebildet. Aus den Konsequenzen der früheren Handlungen wird Wissen generiert und weiter verarbeitet, beispielsweise in der Auswahl und Anwendung der Analyseinstrumente oder der Inputdaten für das Data Mining.

Fazit

Durch den Einsatz von Produktionskennlinien, der Gesamtanlageneffektivität, Data Mining und Double Loop Learning kann eine Verbesserung der Produktionsplanung und Disposition erreicht werden. Unter Berücksichtigung der gegebenen Rahmenbedingungen und Anpassung der Instrumente auf diese erhalten die Mitarbeiter der Produktionsplanung und Disposition eine Unterstützung eines Elektronikwerks. *Industrie Management*, 25 (5), S. 43–46.

Literaturverzeichnis

Al-Radhi, M. (2002): Total Productive Management. Erfolgreich produzieren mit TPM. (2. Auflage.). München, Wien: Carl Hanser Verlag.

AMAG (2013): Flexibilitätsorientierte Produktionsplanung und -steuerung. AluReport 03.2013, S. 16-17. URL: https://www.amag.at/fileadmin/user_upload/amag/Downloads/AluReport/DE/AR-2013-3-DE-AR_201303_Flexi_Prodplanung.pdf [09.II.2014]

Argyris, C.; Schön, D. (2006): Die Lernende Organisation. Grundlagen, Methoden, Praxis.(3. Auflage) Stuttgart: Klett-Cotta.

Beckmann, H.; Döbbeler, F.; Künzler, O. (2014): Produktionskennlinien im Prozesskettenparadigma. *Industrie-Management*, 30 (1), S. 22–26.

Busse, T.; Nywlt, J.; Nyhuis, P. (2012): Belastungsstreuung in der Produktion. *ZWF*, 107 (10), S. 722–726.

Chapman, P.; Clinton, J.; Kerber, R.; Khabaza, T.; Reinartz, T.; Chearer, C.; Wirth, R. (2000): CRISP-DM 1.0. Step-by-step data mining guide. URL: <http://www.the-modeling-agency.com/crisp-dm.pdf> [3.II.2014]

Lusti, M. (1999): Data Warehousing und Data Mining. Eine Einführung in entscheidungsunterstützende Systeme. Berlin, Heidelberg: Springer.

Münzberg, B.; Busse, T. D.; Van Bebber, A. (2009): Kennlinien im Produktcontrolling. Implementierung der Produktionskennlinien in das laufende Produktionscontrolling eines Elektronikwerks. *Industrie Management*, 25 (5), S. 43–46.

Nyhuis, P.; Wiendahl, H.-P. (2012): Logistische Kennlinien: Grundlagen, Werkzeuge und Anwendungen. (3. Auflage.). Berlin, Heidelberg: Springer.

Pietsch, T.; Memmler, T. (2003): Balanced Scorecard erstellen. Kennzahlenermittlung mit Data Mining. Berlin: Erich Schmidt Verlag GmbH.

Samac, K. (2014): Anwendungen und Entwicklungspotentiale von Produktionskennlinien sowie Grenzen bei deren Einsatz. In: *Logistische Modellierung. 2. Wissenschaftlicher Industrielogistik-Dialog in Leoben (Wild)*. Hrsg.: Zsifkovits, H.; Altendorfer-Kaiser, S.; München, Mering: Rainer Hampp Verlag.

Wiendahl, H.-P.; Nyhuis, P. (2004): Logistische Kennlinien. In: *Logistik-Management. Strategien-Konzepte-Praxisbeispiele (Bd. Band 2)*. Hrsg.: Baumgartner, H., Wiendahl, H.-P., Zentes, J.; Berlin, Heidelberg: Springer.

Autorin:

Dipl.-Ing. Kristin Samac ist seit Dezember 2012 Mitarbeiterin am Lehrstuhl für Wirtschafts- und Betriebswissenschaften an der Montanuniversität Leoben. Ihr Tätigkeitsfeld liegt im Bereich Produktionsmanagement. Bevor sie den Weg einer wissenschaftlichen Mitarbeiterin eingeschlagen hat, schloss sie die HTBLA für Bautechnik mit Schwerpunkt Hochbau in Krems ab und absolvierte das Studium der Industrielogistik mit Vertiefung Logistik Management an der Montanuni. Während des Studiums machte Frau Samac verschiedene Praktika in unterschiedlichen Unternehmen und verbrachte ein Semester in Schweden, an der University of Linköping.



Dipl.-Ing.

Kristin Samac

wiss. Mitarbeiterin
am Lehrstuhl f. Wirtschafts- u. Betriebswissenschaften,
Montanuniversität Leoben