

Thomas Busam

Kontinuierliche Verbesserung mittels Prescriptive Analytics



Kontinuierliche Verbesserung mittels Prescriptive Analytics

Continuous Improvement Using Prescriptive Analytics

Von der Fakultät für Maschinenwesen
der Rheinisch-Westfälischen Technischen Hochschule Aachen
zur Erlangung des akademischen Grades eines
Doktors der Ingenieurwissenschaften
genehmigte Dissertation

vorgelegt von

Thomas Andreas Busam

Berichter:

Univ.-Prof. Dr.-Ing. Dipl.-Wirt. Ing. Günther Schuh
Außerplanmäßiger Professor Dr.-Ing. Wolfgang Boos

Tag der mündlichen Prüfung: 04. November 2020

ERGEBNISSE AUS DER PRODUKTIONSTECHNIK

Thomas Busam

Kontinuierliche Verbesserung mittels Prescriptive Analytics

Herausgeber:

Prof. Dr.-Ing. T. Bergs
Prof. Dr.-Ing. Dipl.-Wirt. Ing. G. Schuh
Prof. Dr.-Ing. C. Brecher
Prof. Dr.-Ing. R. H. Schmitt

Band 33/2020



Bibliografische Information der Deutschen Nationalbibliothek

Die Deutsche Nationalbibliothek verzeichnet diese Publikation in der Deutschen Nationalbibliografie; detaillierte bibliografische Daten sind im Internet über <https://portal.dnb.de> abrufbar.

Thomas Busam:

Kontinuierliche Verbesserung mittels Prescriptive Analytics

1. Auflage, 2020

Apprimus Verlag, Aachen, 2020
Wissenschaftsverlag des Instituts für Industriekommunikation und Fachmedien
an der RWTH Aachen
Steinbachstr. 25, 52074 Aachen
Internet: www.apprimus-verlag.de, E-Mail: info@apprimus-verlag.de

ISBN 978-3-86359-926-3

D 82 (Diss. RWTH Aachen University, 2020)

Vorwort

Die vorliegende Dissertation entstand während meiner Zeit als Unternehmensberater im Komplexitätsmanagement der Schuh & Co. GmbH bzw. im Lean Management der Lean Enterprise Institut GmbH und als Doktorand am Lehrstuhl für Produktionssystematik des Werkzeugmaschinenlabors WZL der RWTH Aachen. Diese einzigartige Kombination aus Innovation, Forschung und professioneller Industriepraxis ermöglichte mir ein äußerst intensives Lernen aus verschiedenen Perspektiven.

Für die Erschaffung dieses fördernden und fordernden Umfelds gilt meinem Doktorvater, Herrn Professor Schuh, mein besonderer Dank. Zudem möchte ich Herrn Professor Boos für die Übernahme des Koreferates danken. Herrn Professor Loosen danke ich für die Übernahme des Vorsitzes meiner Prüfungskommission und Herrn Professor Itskov für die Annahme des Besitzes.

Auf meiner Forschungsreise haben mich auf der Seite des Instituts zahlreiche Kollegen unterstützt. Hervorheben möchte ich hier insbesondere Herrn Stefan Dani, Herrn Dr. Jan-Philipp Prote, Herrn Andreas Gützlaff und Herrn Frederick Sauer- mann, die mir mit wissenschaftlichem und administrativem Rat stets zur Seite standen.

Für die Unterstützung beim gemeinsamen Hinterfragen und Umsetzen gilt Herrn Rafael Lorenz, Herrn Christoph Pracht, Herrn Florian Wessels und Herrn Peter Grammlich mein besonderer Dank.

Ohne die nötige Industriepraxis wäre diese Arbeit nicht in dieser Form zustande gekommen. Für zahlreichen damit verbundenen Lernerfahrungen und für die herzliche Unterstützung möchte ich all meinen Kollegen und Chefs der Schuh & Co. danken, insbesondere Herrn Dr. Krumm für die richtungsweisende Hinterfragung meines Promotionsthemas. Hervorheben möchte ich außerdem Herrn Michael Friedrich für die intensiven Kontrollschleifen, Herrn Dr. Markus Stoffel für die Beantwortung

vieler Fragen sowie Herrn Jan-Hendrik Kraus, der zeitgleich mit mir die Promotionsphase bestritten hat und wir uns somit einige Herausforderungen teilen konnten. Zusätzlich möchte ich mich bei meinen Industriepartnern Herrn Dr. Bernhard Gottwald, Herrn Erik Müller und Herrn Sebastian Freitag bedanken, deren außerordentlicher Beitrag den praktischen Anwendungsbezug dieser Arbeit maßgeblich geprägt haben.

Mein tiefster Dank gilt meinem familiären Umfeld, allen voran meinen Eltern Barbara und Michael Busam sowie meiner Schwester Katharina Johansson, aber auch Paula Ventura Esteves und Antonio Esteves, die mir in diesen intensiven Jahren immer aufbauend zur Seite standen und mir den Rücken freihielten, wo immer sie konnten. Allen voran möchte ich meiner Freundin Mélanie Ventura Esteves für den durchgängigen Zuspruch und die liebevolle Motivation, trotz des häufigen Verzichts der gemeinsamen Zeit, ganz herzlich danken. Ihr gabt mir den nötigen Rückhalt, einiges an Unterstützung und das Durchhaltevermögen. Euch widme ich diese Arbeit.

Paris, November 2020

Thomas Busam

Zusammenfassung

Die heutigen Anforderungen an die Produktion, gerade in Hochlohnländern, sind vielschichtig. Kürzere Produktlebenszyklen, häufigere Produktänderungen während diesen Zyklen und z.T. massive Auftragsschwankungen bedingen häufigere Anpassungen der Produktionslinien. Dies resultiert in einem kürzeren stabilen Betriebszustand der Produktionsprozesse. Nichts desto trotz müssen häufig geschmälerete Teams in dieser kürzeren Zeit trotzdem die Prozesse zur Produktivitätssteigerung verbessern, um dem omnipräsenten Kostendruck begegnen zu können. Hinzu kommen die weiterhin hohen Latenzzeiten der traditionellen kontinuierlichen Verbesserung, bzw. die geringe Anpassungsfähigkeit von datengetriebenen Ansätzen.

Auf Grund des beschriebenen Spannungsfeldes wird im Rahmen dieser Forschungsarbeit eine Methodik zur Effizienzsteigerung des kontinuierlichen Verbesserungsprozesses mittels Prescriptive Analytics in einem durch Unsicherheit gekennzeichneten Produktionsumfeld entwickelt. Die Leitidee besteht darin, einem Prozessverbesserer aus einer standortübergreifenden Wissensdatenbank, mit bisher unbekanntem Wirkbeziehungen, gemäß der gewünschten Zielrichtung passende Verbesserungsansätze mit prognostizierten Ergebnissen automatisch vorzuschlagen. Hierzu werden im ersten Schritt User Stories mit Prozessparametern und Verbesserungsansätzen ermittelt und in einer Datenbank aufbereitet. Im zweiten Schritt werden aus den Prozessparametern für Unternehmen bisher unbekannte Ursachen-Wirkbeziehungen ermittelt, aus denen erste Prozessverbesserungen abgeleitet werden können. Diese Beziehungen werden in ein aufzubauendes Künstliches Neuronales Netz zur Prognose der Prozessparameter inkorporiert. Im dritten Schritt werden über eine Mustererkennung des zu verbessernden Prozesses und den User Stories, diejenigen Ideen dem Anwender vorgeschlagen, deren prognostizierte Ergebnisse die Zielerreichung erfüllen oder dazu beitragen.

Die entwickelte Methodik leistet somit einen Beitrag zur Modernisierung der kontinuierlichen Verbesserung und stellt Unternehmen eine Implementierungsstrategie sowie einen Anwendungsprozess zur Verfügung.

Summary

Today's challenges for production, especially in high-wage countries, are complex. Shorter product lifecycles, more frequent product changes during these cycles and to some extent massive order fluctuations require more frequent adjustments to the production lines. This results in a shorter stable operating state of the production processes. Nevertheless, usually downscaled teams still have to improve the processes to increase productivity in this shorter period of time in order to be able to counter the omnipresent cost pressure. In addition, there are the still high latencies in the traditional continuous improvement and the low adaptability of data-driven approaches.

Due to the described field of tension, a methodology for increasing the efficiency of the continuous improvement process by using prescriptive analytics in a production environment characterized by uncertainty is being developed within the scope of this research work. The main idea is to automatically propose suitable improvement approaches with predicted results to a process improver from a cross-location knowledge database, with previously unknown effect relationships, according to the desired targets. In the first step, user stories with process parameters and improvement approaches are defined and preprocessed in a database. In the second step, previously for the organization unknown cause-effect relationships are determined from the process parameters and first process improvements can be derived. These relationships will be incorporated into an artificial neural network, which predicts the process parameters. In the third step, by using a pattern recognition of the process to be improved and the user stories, those are suggested to the user whose predicted results meet or contribute to the achievement of the targets.

The developed methodology thus contributes to the modernization of continuous improvement and provides companies with an implementation strategy and an application process.

Inhaltsverzeichnis

Inhaltsverzeichnis	I
Abbildungsverzeichnis	VII
1 Einleitung	1
1.1 Motivation und Problemstellung	1
1.2 Zielsetzung und Forschungsfragen der Arbeit	5
1.3 Forschungsmethodischer Rahmen der Arbeit	6
1.4 Aufbau der Arbeit	10
2 Grundlagen des Betrachtungs- und Gestaltungsbereiches	13
2.1 Definitionen und Einordnung des Betrachtungsbereichs	14
2.1.1 Grundlegende Begriffsdefinitionen	14
2.1.2 Charakteristika eines durch Unsicherheit gekennzeichneten Produktionsumfeldes	20
2.2 Kontinuierliche Verbesserung	24
2.2.1 Lean Verständnis	24
2.2.2 Übersicht kontinuierliche Verbesserung	26
2.2.3 Verbesserungs-Kata	28
2.3 Datenbasierte Verfahren zur Präskription	32
2.3.1 Überblick und Strukturierung datenbasierter Verfahren	34
2.3.2 Künstliche Intelligenz	39
2.3.3 „Knowledge Discovery in Databases“-Prozess	44
2.3.4 Maschinelles Lernen	55
2.3.5 Künstliche Neuronale Netze	59

2.3.6	Weitere relevante Methoden & Algorithmen	71
3	Bestehende Ansätze zur kontinuierlichen Verbesserung	81
3.1	Herausforderungen bei der kontinuierlichen Verbesserung mittels Prescriptive Analytics in einem durch Unsicherheit gekennzeichneten Produktionsumfeld	81
3.1.1	Herausforderungen des Betrachtungsbereiches	82
3.1.2	Herausforderungen des Gestaltungsbereiches	86
3.1.3	Handlungsbedarf aus der Praxis und Ableitung von Bewertungskriterien	89
3.2	Ansätze zur traditionellen Kontinuierlichen Verbesserung	92
3.2.1	Verbesserungs-/Coaching-Kata nach ROTHER	92
3.2.2	Weitere Ansätze	93
3.3	Ansätze zur Kontinuierlichen Verbesserung mittels datengetriebener Verfahren	93
3.3.1	Digital Continuous Improvement System for Production nach HAMBACH ET AL.	93
3.3.2	QM-CRISP-DM Zyklus nach SCHÄFER ET AL.	95
3.3.3	Product State Konzept nach WUEST	96
3.3.4	Advanced Manufacturing Analytics-Plattform nach GRÖGER .	97
3.3.5	Deep Business Optimization nach NIEDERMANN	99
3.3.6	MaXCept nach KASSNER et al.	99
3.3.7	Graph-based Analytics Framework nach RINGSQUANDL ET AL.	100
3.3.8	Big Data Analytics based Fault Prediction for Shop Floor Scheduling nach WEI ET AL.	102
3.3.9	Process Mining Techniques in Manufacturing nach RUSCHEL ET AL.	103
3.4	Bewertung ausgewählter Ansätze	105
3.5	Ableitung des Forschungsbedarfs	108
4	Konzeption der Methodik zur kontinuierlichen Verbesserung mittels Prescriptive Analytics	109

4.1	Zielbild und Abgrenzung zur kontinuierlichen Verbesserung mittels Prescriptive Analytics	110
4.2	Anforderungen an die Methodik zur kontinuierlichen Verbesserung mittels Prescriptive Analytics	111
4.2.1	Inhaltliche Anforderungen	112
4.2.2	Formale Anforderungen	114
4.3	Ableitung von Partialmodellen	115
4.4	Grobkonzept zur kontinuierlichen Verbesserung mittels Prescriptive Analytics	118
4.4.1	Beschreibungsmodell zur Ermittlung und Aufbereitung von User Stories	120
4.4.2	Erweitertes Wirkmodell zur retrospektiven Ermittlung der Ursache-Wirkungsbeziehungen und Prognose	122
4.4.3	Erklärungsmodell zur Mustererkennung der User Stories und Ableitung von Verbesserungsansätzen	123
4.4.4	Begleitender Ordnungsrahmen	125
4.5	Zwischenfazit: Potentiale der Methodik	126
5	Detaillierung der Methodik zur kontinuierlichen Verbesserung mittels Prescriptive Analytics	127
5.1	Beschreibungsmodell zur Ermittlung und Aufbereitung von User Stories	128
5.1.1	Erarbeitung Domänenwissen / Prozessverständnis	129
5.1.2	Aufbau Dateninfrastruktur	132
5.1.3	Aufbau Datentopf: Prozessparameter	133
5.1.4	Aufbau Datentopf: User Stories	138
5.2	Erweitertes Wirkmodell zur retrospektiven Ermittlung der Ursache-Wirkungsbeziehungen und Prognose	141
5.2.1	Data Mining zum Aufdecken unbekannter Ursachen-Wirkbeziehungen	143

5.2.2	Inkorporation der Ursachen-Wirkbeziehungen in das erweiterte Wirkmodell	149
5.2.3	Auslegung und Training des erweiterten Wirkmodells	152
5.3	Erklärungsmodell zur Mustererkennung der User Stories und Ableitung von Verbesserungsansätzen	158
5.3.1	Prozessauswahl und Erzeugung der unfertigen User Story	160
5.3.2	Auswahl dem Prozess entsprechender User Stories	161
5.3.3	Abstandsberechnung von Vektoren zwischen Prozess und User Stories	162
5.3.4	Mustererkennung über ähnliches Cluster zur Auswahl von Verbesserungsansätzen	167
5.3.5	Prognose der Verbesserungsergebnisse durch Adaption an den neuen Ist-Zustand	169
5.3.6	Empfehlung durch Ranking der Auswirkungen auf die Zieldimension	170
5.4	Begleitender Ordnungsrahmen	171
5.4.1	Implementierungsstrategie	172
5.4.2	Anwendungsprozess der Methodik	174
5.5	Zwischenfazit: Kontinuierliche Verbesserung mittels Prescriptive Analytics	176
6	Validierung und kritische Reflexion	179
6.1	Praxisbeispiel: Hochdruckpumpenhersteller für PKW-Motoren	179
6.1.1	Ausgangssituation	179
6.1.2	Anwendung und Ergebnisse der Methodik	181
6.2	Praxisbeispiel: Filterhersteller	190
6.2.1	Ausgangssituation	191
6.2.2	Anwendung und Ergebnisse der Methodik	192
6.3	Kritische Reflexion der Anwendung	193
7	Zusammenfassung und Ausblick	195

Literaturverzeichnis	199
A Anhang	221
A.1 Datenvorverarbeitung des Prozessparameter-Datentopfes	221
A.2 Data Mining Analysen	232
A.3 Erstellung und Konfiguration des KNN	235

Abbildungsverzeichnis

Abbildung 1-1: Latenzzeiten beim kontinuierlichen Verbesserungsprozess	4
Abbildung 1-2: Wissenschaftssystematik nach ULRICH und HILL	8
Abbildung 1-3: Explorativer Forschungszyklus nach TOMCZAK	9
Abbildung 1-4: Forschungsprozess nach ULRICH und Anwendung in dieser Arbeit	11
Abbildung 2-1: Industrie 4.0-Entwicklungsstufen nach FIR e.V. an der RWTH Aachen	16
Abbildung 2-2: Data-Analytics-Kategorien	18
Abbildung 2-3: Die fünf Lean-Prinzipien	25
Abbildung 2-4: Gegenüberstellung der Verbesserungstypen Kaizen und Kaikaku	27
Abbildung 2-5: Strukturierte Vorgehensweise auf dem Weg vom Ist zur Vision	29
Abbildung 2-6: Ablauf des Problemlösezyklus	31
Abbildung 2-7: Zustandsraum gelöster (Brett-)Spiele durch Systeme	33
Abbildung 2-8: Jährliche Größe der existierenden Datenmengen, IDC, Nov.2018	35
Abbildung 2-9: Hierarchische Anordnung der Begriffswelt	37
Abbildung 2-10: Erweitertes Venn-Diagramm zur Einordnung der Begriffswelt	38
Abbildung 2-11: Ein-/Ausgangsgrößen eines intelligenten Agenten zur Lösung von Lernproblemen	41
Abbildung 2-12: Kategorien, Fähigkeiten und Technologien von Künstlicher Intelligenz	42
Abbildung 2-13: Übersicht der Vorgehensweise im KDD-Prozess	45
Abbildung 2-14: Übersicht der Vorgehensweise im CRISP-DM	47
Abbildung 2-15: Übersicht wichtiger Aufgaben und Methoden des Data Mining	50

Abbildung 2-16: Vorgehen zum Aufbau eines Prognosemodells	53
Abbildung 2-17: Entscheidungsbaum für Prognosemodelle	54
Abbildung 2-18: Grundstruktur mehrschichtiger Neuronaler Netze	61
Abbildung 2-19: Schematischer Informationsverarbeitungsprozess eines Neurons	62
Abbildung 2-20: Auswahl von Propagierungsfunktionen Neuronaler Netze	63
Abbildung 2-21: Auswahl von Aktivierungsfunktionen Neuronaler Netze	64
Abbildung 2-22: Typen von Künstlichen Neuronalen Netzen	65
Abbildung 2-23: Vergleich Deep Learning mit Ansätzen anderer Teilgebiete der KI	66
Abbildung 2-24: Ablaufschritte zur Auslegung und Kalibrierung Künstlicher Neuronaler Netze	67
Abbildung 2-25: Funktionsprinzip des Backpropagation-Algorithmus	69
Abbildung 2-26: Beispielhafte Punktelwolke mit Regressionsgerade	72
Abbildung 2-27: Analysephasen beim Verarbeiten von natürlicher Sprache	74
Abbildung 2-28: Arten von Recommender Systems und die dafür nötigen Daten	76
Abbildung 2-29: Verknüpfung und Aufbau von Expertensystemen	79
Abbildung 3-1: Herausforderungen bei Unsicherheit im Produktionsumfeld	85
Abbildung 3-2: Handlungsbedarf aus der Praxis	89
Abbildung 3-3: Von den Herausforderungen abgeleitete Bewertungskriterien	90
Abbildung 3-4: Business Process Modell des „digital CI“-Ansatzes	94
Abbildung 3-5: Schritte und Werkzeuge des QM-CRISP-DM Zyklus	95
Abbildung 3-6: Architekturkonzept der Advanced-Manufacturing-Analytics- Plattform	98
Abbildung 3-7: MaxCept Architektur für Ausnahmeskalation in der Produktion	100
Abbildung 3-8: Architektur des graph-based analytics frameworks	101
Abbildung 3-9: Konzept der Fehlervorhersage für die Planung von Arbeitsabläufen	102
Abbildung 3-10: Elemente und Aufgaben von Process Mining	104

Abbildung 3-11: Zusammenfassende Bewertung ausgewählter Ansätze	106
Abbildung 4-1: Inhaltliches Anforderungsprofil an die Methodik	112
Abbildung 4-2: Partialmodelle und begleitender Ordnungsrahmen der Methodik	117
Abbildung 4-3: Einordnung der Schritte des Grobkonzepts zum Vorgehen zum Aufbau eines Prognosemodells	118
Abbildung 4-4: Grobkonzept zur kontinuierlichen Verbesserung mittels Prescriptive Analytics	119
Abbildung 4-5: Mit Formeln vorkonditioniertes Künstliches Neuronales Netz	123
Abbildung 4-6: Mustererkennung des aktuellen Problems und Auswahl bzw. Adaption einer bisherigen Verbesserungsidee	125
Abbildung 5-1: Gliederung und Vorgehensweise der Methodik zur kontinuierlichen Verbesserung mittels Prescriptive Analytics	127
Abbildung 5-2: Ermittlung und Aufbereitung von User Stories	128
Abbildung 5-3: Vorgehen zur Ermittlung und Aufbereitung von User Stories	129
Abbildung 5-4: Erarbeitung von Domänenwissen und Prozessverständnis zur Bewertung und Auswahl geeigneter Prozessketten	130
Abbildung 5-5: Generische Dateninfrastruktur	133
Abbildung 5-6: Anforderungen an den Datentopf: Prozessparameter	134
Abbildung 5-7: Vorverarbeitung des Datentopfes: Prozessparameter	136
Abbildung 5-8: Aufbau und Format des Datentopfes: Prozessparameter	138
Abbildung 5-9: Anforderungen an den Datentopf: User Stories	139
Abbildung 5-10: Aufbau und Format des Datentopfes: User Stories	141
Abbildung 5-11: Retrospektive Ermittlung der Ursache-Wirkungsbeziehungen und Prognose	142
Abbildung 5-12: Vorgehen zur retrospektiven Ermittlung der Ursache- Wirkungsbeziehungen und Prognose im erweiterten Wirkmodell	143
Abbildung 5-13: Vergleich von Korrelationskoeffizienten	144
Abbildung 5-14: Aufbereitung der Korrelationsmatrix und Vorauswahl	146

Abbildung 5-15: Darstellung von Scatterplots zur Beurteilung der Korrelation	148
Abbildung 5-16: Einfluss und Struktur der zu inkorporierenden Gewichte	150
Abbildung 5-17: Vorgehen zur Inkorporation der Ursachen-Wirkbeziehungen	151
Abbildung 5-18: Ergebnisse eines beispielhaften, trainierten Netzes mit zusätzlichen Konfigurationen	157
Abbildung 5-19: Ergebnisse eines beispielhaften, trainierten Netzes ohne zusätzliche Konfigurationen	157
Abbildung 5-20: Mustererkennung der User Stories und Ableitung von Verbesserungsansätzen	158
Abbildung 5-21: Vorgehen zur Mustererkennung der User Stories und Empfehlung von adaptierten Verbesserungsansätzen	159
Abbildung 5-22: Prozessauswahl und Erzeugung der unfertigen User Story	161
Abbildung 5-23: Vorgehen zur Abstandsberechnung der Vektoren der gefilterten User Stories	163
Abbildung 5-24: Bestimmung des Clusters mit ähnlichen Mustern	168
Abbildung 5-25: Ablauf zur Prognose von Verbesserungsergebnissen	169
Abbildung 5-26: Aufbau der Rangliste gemäß der Zielerfüllung	171
Abbildung 5-27: Begleitender Ordnungsrahmen	172
Abbildung 5-28: Einmalige Phasen der Implementierungsstrategie	173
Abbildung 5-29: Wiederkehrende Phasen der Implementierungsstrategie	174
Abbildung 5-30: Anwendungsprozess der Methodik	176
Abbildung 5-31: Überblick der Hauptschritte der erarbeiteten Methodik	178
Abbildung 6-1: Produkt- und Produktionsübersicht	180
Abbildung 6-2: Auszug der Prozessabfolge	181
Abbildung 6-3: Vorauswahl anhand der aufbereiteten Korrelationsmatrix	183
Abbildung 6-4: Top-Korrelationen zu spezifischen Attributen	184
Abbildung 6-5: Scatterplott der Korrelation P0210 zu P0520	185
Abbildung 6-6: Scatterplott der Korrelation P0500 zu P0520	186
Abbildung 6-7: Scatterplott der Korrelation P0400 zu P0570	186

Abbildung 6-8: Scatterplott der Korrelation P0400 zu P0510	187
Abbildung 6-9: Prinzip-Skizze zur Verformung durch Crimpen am PRV	187
Abbildung 6-10: Experimentelle Variation der Netzeinstellungen	188
Abbildung 6-11: Ergebnisse des trainierten Netzes (kompletter Datentopf)	189
Abbildung 6-12: Finale Verbesserungsvorschläge für den Prozessschritt Dämpfer-Schweißen	190
Abbildung 6-13: Prozessketten-Charakteristika der Zwischenlösung	191
Abbildung A-1: Bibliotheken-Import, Dateiauswahl	221
Abbildung A-2: Benennungsformatierung, Dateieinlesen, Teil 1	222
Abbildung A-3: Dateieinlesen, Teil 2	223
Abbildung A-4: Dateieinlesen, Teil 3	224
Abbildung A-5: Dateieinlesen, Teil 4	225
Abbildung A-6: Dateieinlesen, Teil 5	226
Abbildung A-7: Dateieinlesen, Teil 6	227
Abbildung A-8: Dateieinlesen, Teil 7	228
Abbildung A-9: Erstellung Datentopf (DataFrame)	229
Abbildung A-10: Konsolidierung Datentopf	230
Abbildung A-11: Individuelle Datenbereinigung, Erstellung Datenreihen	231
Abbildung A-12: Erstellung Korrelationsanalyse	232
Abbildung A-13: Exemplarische Datenanalyse mit Scatterplots, Teil 1	233
Abbildung A-14: Exemplarische Datenanalyse mit Scatterplots, Teil 2	234
Abbildung A-15: Vorbereitung der Daten	235
Abbildung A-16: Kalibrierung Künstliches Neuronales Netz, Teil 1	236
Abbildung A-17: Kalibrierung Künstliches Neuronales Netz, Teil 2	237

Abkürzungen und Formelzeichen

$a(\text{net}_i)$	Aktivierungszustand/-Wert von Neuron i
$a_i(u, f)$:	Einzelabstand von Wertepaar i der Vektoren von u und f
ANN	Artificial Neural Network (Künstliches Neuronales Netz)
β	Steigerungsparameter der Aktivierungsfunktion
BAZ	Bearbeitungszeit
BDE	Betriebsdatenerfassung
bzgl.	Bezüglich
bzw.	Beziehungsweise
CI	Continuous Improvement (kontinuierliche Verbesserung)
CIP	Continuous Improvement Process (KVP)
CNN	Convolutional Neural Network
d	$\text{rg}(x_i) - \text{rg}(y_i)$: Rangunterschied der Werte des i -ten Parameters der Attribute
$d(u, f)$	Gesamtvektorenabstand zwischen Prozess (u) und User Story (f) auf Basis der euklidischen Abstandsberechnung
$D(u, f)$	Jaccard-Abstand zwischen fertigen User Story f und unfertigen u
DB	Datenbank
DNA	Desoxyribonucleic Acid, (Desoxyribonukleinsäure)
ERP	Enterprise-Resource-Planning (-System)
ETL	Extraktion, Transformation, Laden (Data-Warehouse)
I.A.a.	In Anlehnung an
IO	In Ordnung (Bewertung der Qualität eines Bauteils)
J	Jaccard-Koeffizient
KI	Künstliche Intelligenz

KNN	Künstliches Neuronales Netz
KPI	Key Performance Indicator
Kont. Verb.	Kontinuierliche Verbesserung
KVP	Kontinuierlicher Verbesserungsprozess
LSTM	Long-short-term memory (neural network)
$\max(p(u, f))$	Maximaler Einzelabstand von allen parametrischen Wertepaaren
MES	Manufacturing Execution System
Mio.	Million
MJ	Mitarbeiterjahre (Mannjahre)
ML	Machine Learning
MLP	Multi-Layer Perceptron
MSE	Mittlere quadratische Abweichung
n	Anzahl an Datenreihen
net_i	Nettoeingabewert von Neuron i
NLP	Natural Language Processing
NIO	Nicht in Ordnung (Bewertung der Qualität eines Bauteils)
$np(u, f)$	Einzelabstand eines nicht-parametrischen Wertepaars
OEM	Original Equipment Manufacturer
$p(u, f)$	Einzelabstand eines parametrischen Wertepaars
P	Anzahl an Datenpunkten
PDCA	Plan, Do, Check, Act
PKW	Personenkraftwagen
PLZ	Problemlösezyklus
r_p	Pearson-Koeffizient
r_s	Spearman-Rangkoeffizient
RS	Recommender System
SCM	Supply-Chain-Management
SGD	Stochastischen Gradientenabstieg
SIPOC	Supplier, Input, Process, Output, Customer (Werkzeug)
TT	Taktzeit

u.a.	Unter anderem
Vgl.	Vergleiche
$X_{s,i}$	Aktivierungszustand/-Wert von Neuron i auf Schicht s
\hat{X}	Berechneter Ausgabewert der Ausgabeschicht
Z_a	KPI a zum Zeitpunkt nach der Verbesserung
ZR_a :	Zielrichtung für KPI a
$ZRE(u,f)$	Zielrichtungserfüllung von fertiger User Story f zur unfertigen u
z.B.	Zum Beispiel
z.T.	Zum Teil
$\omega_{s-1,j,i}$	Gewicht zwischen den Neuronen j (Schicht $s-1$) und i (s)
θ_i	Schwellwert von Neuron i
μ	Gewünschter Ausgabewert
5W	Fünfmaliges Warum-Fragen (Werkzeug zum PLZ)