



# Qualitätsprognosen zur Engpassentlastung in der Injektorfertigung unter Einsatz von Data Mining

Jochen Deuse<sup>1</sup>, Jacqueline Schmitt<sup>1</sup>, Marco Stolpe<sup>2</sup>, Mario Wiegand<sup>1</sup>, Katharina Morik<sup>2</sup>

<sup>1</sup> Institut für Produktionssysteme, Technische Universität Dortmund

<sup>2</sup> Lehrstuhl für Künstliche Intelligenz, Technische Universität Dortmund

*Vor dem Hintergrund eines steigenden Wettbewerbsdrucks ist das Angebot qualitativ hochwertiger Produkte ein wesentlicher Erfolgsfaktor zur langfristigen Sicherung von Wettbewerbsvorteilen. Die Sicherstellung fehlerfreier Produkte durch umfassende Qualitätsprüfungen ist daher unerlässlich. Da die Qualitätsprüfung durch ihren hohen Prüfaufwand zum Engpass des Produktionssystems werden kann, stellt dieser Beitrag eine Methodik vor, wie durch den Einsatz Data Mining-basierter Qualitätsprognosen die Qualitätsprüfung entlastet und somit die Produktivität des Produktionssystems gesteigert werden kann.*

## 1. Einleitung

Im Spannungsfeld von Zeit, Kosten und Qualität sehen sich produzierende Unternehmen einem stetig steigenden Wettbewerbsdruck ausgesetzt. Das Angebot qualitativ hochwertiger Produkte kann dabei einen wesentlichen Wettbewerbsvorteil bedeuten, sodass eine umfassende Qualitätsprüfung der Fertigprodukte häufig unerlässlich ist.

Am Beispiel der Qualitätsprüfung in der Großserienproduktion von Injektoren wird ersichtlich, dass diese unter den besonderen Herausforderungen einer sehr hochfrequenten Prüfung und einem erheblichen Prüfaufwand zum Engpass des Produktionssystems werden kann. Nach Roser et al. (2015) verfügt jedes Gesamtsystem über mindestens eine Ressource, welche die Leistung des Systems begrenzt und den Eng-

pass darstellt. Um die Kapazität zu erhöhen und einen möglichen Engpass zu beseitigen, können verschiedene Maßnahmen ergriffen werden. Diese umfassen die Parallelisierung von Abläufen, die sequentielle Aufteilung, Automatisierung sowie Duplizierung von Prozessen. Im Hinblick auf den heutigen Stand der Technik der Qualitätsprüfung in der Injektorfertigung zeigt sich jedoch, dass das Potenzial dieser Maßnahmen zur Engpassbeseitigung bereits gänzlich erschlossen oder nur begrenzt auszuschöpfen ist, da die Maßnahmen mitunter mit erheblichen Investitionskosten verbunden sind. Es gilt daher, neue Methoden zu erschließen, welche unter Einsatz moderner Informations- und Kommunikationstechnologien, datengetriebene Prozessoptimierungen und Strategien zur Engpassentlastung ermöglichen. Durch das Industrial Internet of Things wird hierbei die Nutzung von Sensordaten ermöglicht und es bieten sich Potenziale zur Effizienzsteigerung lernender Verfahren, um diese echtzeitnah in Produktions- und Prüfprozesse integrieren zu können.

Der Einsatz von Data Mining im industriellen Produktionsumfeld bietet erhebliches Potenzial für die Erarbeitung und Implementierung von Strategien zur Optimierung von Produkten und Produktionsprozessen (vgl. Eickelmann et al. 2015a). Durch den Einsatz überwachter und unüberwachter Lernverfahren des Data Mining werden auf Modellen basierende Analysen ermöglicht. Durch die Anwendung statistischer Methoden können in strukturierten und unstrukturierten Datenbeständen Muster identifiziert werden, um bisher unbekanntes Wissen und Gesetzmäßigkeiten aus den Daten zu extrahieren (Hastie et al. 2009; Fayyad et al. 1996). Dies befähigt zur Entwicklung von Prognosemodellen für die datenbasierte und rechnergestützte Vorhersage zukünftiger Ereignisse und Auswirkungen (Eickelmann et al. 2015b).

Zur strukturierten Durchführung von Data Mining-Projekten hat sich das branchenübergreifende Prozessmodell des CRISP-DM (Cross Industry Standard Process for Data Mining) (Chapman P. et al. 2000) als Industriestandard etabliert. Der CRISP-DM setzt sich aus sechs iterativen Phasen zusammen:

1. Business Understanding (Prozessverständnis)
2. Data Understanding (Datenverständnis)
3. Data Preparation (Datenvorverarbeitung)
4. Modeling (Modellierung)
5. Evaluation (Evaluierung)

## 6. Deployment (Bereitstellung)

Dieser Beitrag präsentiert Ansätze zur Entwicklung von Strategien zur Engpassentlastung in der Qualitätsprüfung der Injektorfertigung durch den Einsatz von Prognosemodellen zur Vorhersage von Prüfmerkmalen auf Basis von zeitlich vorgelagerten Prüfmerkmalen. Die Gliederung des Beitrags orientiert sich dabei an der Vorgehensweise des CRISP-DM.

### 2. Einsatz von Data Mining zur Engpassentlastung in der Qualitätsprüfung der Injektorfertigung

#### 2.1. Prozessverständnis

Um ein grundlegendes Prozessverständnis zu erlangen, wird im Folgenden die Injektorfertigung sowie die finale Qualitätsprüfung der Injektoren kurz vorgestellt.

In der Fertigung der Injektoren werden zunächst die Hauptteile des Injektors (Injektorkörper, Düsen, Steuerungseinheiten und Aktoren) hergestellt. Anschließend wird die Steuereinheit auf dem Injektorkörper montiert. Nachfolgend werden Komponenten nach eingehender Reinigung und Qualitätskontrolle verbaut und der Injektor zum Schutz vor luftgetragenen Partikeln in einem Reinraum vollständig montiert. Die Montageanlagen weisen dabei einen hohen Automatisierungsgrad auf, sodass sich manuelle Tätigkeiten auf Überwachungs-, Störungsbehebungs-, Bestückungs- und logistische Funktionen beschränken. In der abschließenden Qualitätsprüfung wird der Injektor auf seine Funktionalität geprüft. Die Zykluszeit der Qualitätsprüfung einer Prüfstation beträgt dabei je nach Prüfprogramm das 5- bis 6-fache der Taktzeit der Produktionslinie, sodass mehrere Parallelstationen zur 100%-Prüfung der Injektoren eingesetzt werden müssen, um eine akzeptable Ausbringung der Linie zu gewährleisten.

Für die Qualitätsprüfung von Injektoren existieren typenspezifische Prüfprogramme. Für einen Injektor besteht dieses Programm dabei aus einer Vielzahl verschiedener Prüfmerkmale, welche die charakteristischen Betriebsbedingungen, insbesondere in Bezug auf Mengendurchlauf und Einspritzdruck, widerspiegeln. Die erhobenen Messwerte werden während des kontinuierlich ablaufenden Programms prozessbegleitend dokumentiert und in einer Fertigungsdatenbank gespeichert. Jedes dieser Prüfmerkmale ist mit engen Toleranzen spezifiziert, welche im Rahmen der Prüfung eingehalten werden müssen. Sobald die Messwerte eines Merkmals die geforderten Grenzwerte unter- bzw. überschreiten, wird

der Injektor aus dem Produktionsprozess ausgeschleust. Der Injektor wird anschließend in einer Nachprüfung untersucht und nach Abschluss einer fehlerbildspezifischen Nacharbeit erneut der finalen Qualitätsprüfung unterzogen.

Da das Potenzial herkömmlicher Strategien zur Engpassentlastung in der Injektorfertigung bereits erschlossen oder nur unter hohem Kostenaufwand zu realisieren ist, bietet der Einsatz von Data Mining neue Möglichkeiten zur Entwicklung von Strategien zur Engpassentlastung der Qualitätsprüfung. Entsprechend lassen sich vier Strategien zur Engpassentlastung ableiten, welche im Folgenden skizziert werden.

Einerseits können Zusammenhänge zwischen einzelnen Prüfmerkmalen der Qualitätsprüfung durch den Einsatz von Korrelationsanalysen identifiziert werden. Auf Basis dieser Ergebnisse können stark korrelierte Merkmale aus dem Prüfplan eliminiert werden. Diese Dimensionsreduktion kann zu deutlichen Prüfzeiteinsparungen führen, jedoch erfordert sie eindeutige und statistisch signifikante Zusammenhänge zwischen den Merkmalen.

Eine weitere Strategie bildet die Prognose einzelner Prüfmerkmale für jedes Produkt auf Basis anderer Prüfmerkmale, die in der Qualitätsprüfung zeitlich vorgelagert erfasst werden. Beim Vorliegen einer ausreichend hohen Konfidenz kann die physische Messung dieser Merkmale durch die Vorhersage produktindividuell substituiert werden. Hierdurch kann auf eine 100%-Prüfung dieser Merkmale verzichtet und somit eine Prüfzeiteinsparung erzielt werden.

Eine andere Möglichkeit besteht darin, das Prognosemodell so zu trainieren, dass der Schlupf des Modells minimiert bzw. eliminiert wird. Dadurch sind die prognostizierten Prüfmerkmale nur noch bei als fehlerhaft klassifizierten Produkten physisch nachzumessen. Bei den prognostizierten fehlerfreien Produkten ist hingegen keine Messung dieser Merkmale erforderlich, da das Prognosemodell hierfür zuverlässige und ausreichend genaue Vorhersagen liefert. Häufig führt eine Minimierung des Schlupfes jedoch zu einer Erhöhung der Pseudofehlerrate, sodass die zu erreichenden Prüfzeiteinsparungen durch die Stärke dieses Effekts begrenzt wird.

Eine Erweiterung bildet die Strategie, für die Prognose der Prüfmerkmale neben den Merkmalen zeitlich vorgelagerter Prüfschritte auch Prozessparameter aus der Produktion zu verwenden. Durch eine Hinzunahme von Prozessparametern für das Modelltraining kann die Progno-

següte der Modelle ggf. weiter verbessert und die Konfidenz der Klassifikation erhöht werden. Hierdurch können einerseits die zuvor beschriebenen positiven Auswirkungen auf die Prüfzeit verstärkt werden, andererseits kann durch die prozessbegleitende Qualitätsprognose im Sinne einer prozessimmanenten Qualitätskontrolle der Engpass weiter entlastet werden, indem als fehlerhaft klassifizierte Teile bereits vor der finalen Qualitätsprüfung aus dem Produktionsprozess ausgeschleust werden.

## 2.2. Datenverständnis

Entlang der Wertschöpfungskette der Injektorfertigung werden zahlreiche Fertigungs-, Montage- und Prüfdaten mittels moderner Messtechnik und Sensorik erfasst und in Fertigungsdatenbanken gespeichert. Die Form der erhobenen Daten reicht hierbei von hoch aggregierten, statistischen Prozessgrößen, wie beispielsweise einem mittleren Anzugsmoment, bis hin zu hochfrequenten Daten, wie beispielsweise Maschinenvibrationen. Aufgrund des Mengengerüsts in der Großserienfertigung fallen bereits über wenige Tage große Datenmengen an, die effizient verarbeitet und analysiert werden müssen.

Im Rahmen dieses Beitrags wurden zunächst Prognosemodelle ausschließlich auf den Prüfdaten aus der finalen Qualitätsprüfung trainiert und hinsichtlich ihrer Eignung zur produktindividuellen Substitution von Prüfmerkmalen evaluiert. Die Prüfdaten, d.h. die Ausprägungen der Prüfmerkmale, werden im Rahmen einer kontinuierlichen Messung über zahlreiche Sensoren, z.B. zur Erfassung von Druck, Temperatur oder Zulaufmenge, als Zeitreihe erfasst. An definierten Haltepunkten werden die Ausprägungen bestimmter Merkmale, z.B. das Anzugsmoment, gemessen. Anschließend werden die über den Verlauf der Prüfung aufgenommenen Einzelwerte für jedes Merkmal zu einem statistischen Kennwert aggregiert und in der Fertigungsdatenbank abgespeichert.

Da die Verwendung der primären Sensordaten zu Beginn der Analyse weniger zielführend erscheint, werden zunächst die aggregierten Kenngrößen aus der Fertigungsdatenbank als Datenbasis für die Modellbildung und Evaluation herangezogen.

Der analysierte Datenauszug umfasst somit 120 vorwiegend numerische Merkmale und 217.632 Injektoren, von denen 4,4% fehlerhaft (n.i.O.) und entsprechend 95,6% fehlerfrei (i.O.) waren. Da einige Merkmale übermäßig viele Fehlwerte aufwiesen, eigneten sich Imputationen zur Vervollständigung der Datensätze nicht, sodass diese zunächst entfernt wurden, wodurch die Anzahl der Merkmale auf 81 reduziert werden konnte.

	Fehlerfrei	Fehlerhaft	Gesamt
Anzahl Beobachtungen	217.632	10.100	227.732
Anteil	95,6%	4,4%	100%

*Tabelle 1: Struktur des analysierten Datenauszugs*

### 2.3. Datenvorverarbeitung und Modellbildung

Die Vorverarbeitung von Daten ist oft eng verbunden mit der Modellbildung, da abhängig von der Verfahrensauswahl unterschiedliche Maßnahmen erforderlich sind, um gute Ergebnisse erzielen zu können und den anwendungsfallspezifischen Herausforderungen zu begegnen.

Eine besondere Herausforderung im Rahmen der Modellbildung besteht im vorliegenden Anwendungsfall in der Anforderung einer sehr hohen Klassifikationsgenauigkeit des Modells sowie einer annähernd echtzeitfähigen Vorhersage der Funktions- und Qualitätserfüllung von Injektoren in der Produktion. Eine hohe Vorhersagegenauigkeit ist für jedes Data Mining-Modell eine zentrale Forderung, jedoch muss diese vergleichbar mit der Mess- und Prozessfähigkeit des jeweiligen Prüfschritts sein, um den realen Prüfvorgang des entsprechenden Merkmals ohne Qualitätseinbußen ersetzen zu können.

Zunächst wurden Naive Bayes, Entscheidungsbäume und Support Vector Maschine (SVM) als Standardverfahren des Data Mining zur Vorhersage der Injektorqualität verwendet.

Naive Bayes ist eine statistische Klassifikationsmethode, welche auf dem Satz von Bayes über bedingte Wahrscheinlichkeiten basiert und die Wahrscheinlichkeit vorhersagt, mit der ein Objekt einer bestimmten Klasse angehört (Aggarwal 2015). Der Vorteil von Naive Bayes-Klassifikatoren besteht in ihren meist guten bis sehr guten Klassifikationsergebnissen auf großen Datenmengen, ihrer hohen Trainings- und Klassifizierungsgeschwindigkeit sowie der Verbesserung des Klassifikators durch jedes neu klassifizierte Objekt. Nachteilig ist hingegen, dass Abhängigkeiten zwischen Merkmalen nicht berücksichtigt werden können, sodass die theoretisch mögliche Klassifikationsgenauigkeit eingeschränkt wird und die Klassifikatoren bei hochdimensionalen Attributen nicht mehr effizient sind.

Entscheidungsbäume sind hierarchische Modelle des überwachten Lernens, welche sowohl für die Regression als auch die Klassifikation genutzt werden können. Erzeugt wird hierbei ein hierarchisches Regelwerk, welches den Merkmalsraum durch sequentielle Überprüfung der Merkmalsausprägungen in achsenparallele Abschnitte teilt (Aggarwal 2015). Vorteile von Entscheidungsbäumen liegen in ihrer einfachen Interpretierbarkeit, ihrer hohen Genauigkeit und vielseitigen Anwendbarkeit. Nachteilig ist hingegen, dass Entscheidungsbäume nicht robust gegenüber verrauschten Daten sind und eine Tendenz zum Overfitting aufweisen.

Die SVM stellt eine Erweiterung der linearen Klassifikation dar, welche durch eine Transformation des Instanzraumes eine Implementierung nichtlinearer Klassengrenzen durch lineare Modelle erlaubt (Witten et al. 2011). Vorteile der SVM zeigen sich in einer hohen Generalisierungsfähigkeit, der Möglichkeit einer schnellen Klassifikation sowie der Möglichkeit zur Verarbeitung hochdimensionaler Datenätze. Nachteile der SVM sind, dass sie für neu hinzukommende Daten neu trainiert werden muss und der Umgang mit nicht linear separierbaren Problemen entsprechend tiefergehende Fachkenntnisse erfordert.

Zur Bewertung der Klassifikationsgüte der eingesetzten Verfahren eignen sich Konfusionsmatrizen und verschiedene statistische Gütekriterien. Eine Konfusionsmatrix besteht aus  $n$  Zeilen und Spalten, wobei  $n$  die Anzahl der zu analysierenden Klassen angibt. In der Diagonalen der Matrix stehen die jeweils richtig klassifizierte Objekte und in den übrigen Einträgen der Matrix entsprechend die Objekte, die der falschen Klasse zugeordnet wurden. Im vorliegenden Fall einer binären Klassifikation werden richtig zugeordnete Objekte als „True Positive“ (TP) bzw. „True Negative“ (TN) und falsch zugeordnete Objekte als „False Positive“ (FP) bzw. „False Negative“ (FN) bezeichnet (siehe Tabelle 2). Ähnlich der Anwendung in der Medizin werden im vorliegenden Anwendungsfall problematische Fälle, d.h. die fehlerhaften Injektoren, als zu identifizierende Klasse (Positive) bezeichnet.

In der Qualitätsprüfung im industriellen Produktionsumfeld werden „False Positive“-Entscheidungen auch als Pseudofehler bezeichnet, da Teile als fehlerhaft prognostiziert werden, obwohl sie tatsächlich fehlerfrei sind. „False Negative“-Entscheidungen werden in diesem Rahmen auch als Schlupf bezeichnet, da fehlerhafte Teile durch eine Falschklassifikation in der Prüfung nicht als solche erkannt werden.

Basierend auf den Angaben der Konfusionsmatrix können verschiedene statistische Gütekriterien in Form von bedingten Wahrscheinlichkeiten



ermittelt werden, welche eine Bewertung der Klassifikationsgüte ermöglichen (siehe Tabelle 2). Die Kriterien unterscheiden sich in ihrer Grundgesamtheit und erlauben verschiedene kontextbezogene Interpretationen der Klassifikationsgüte.

		True Label		
		Positive (TP+FN)	Negative (FP+TN)	
Prediction	Positive (TP+FP)	True Positive (TP)	False Positive (FP) <b>Pseudofehler</b>	Precision $= \frac{TP}{TP + FP}$
	Negative (FN+TN)	False Negative (FN) <b>Schlupf</b>	True Negative (TN)	Negative Predictive Value (NPV) $= \frac{TN}{FN + TN}$
		Recall $= \frac{TP}{TP + FN}$	Specificity (SPC) $= \frac{TN}{FP + TN}$	Accuracy $= \frac{TP + TN}{TP + TN + FP + FN}$

Tabelle 2: Konfusionsmatrix und statistische Gütemaße

Bei der Qualitätsprognose der Injektoren muss insbesondere sichergestellt werden, dass fehlerhafte Injektoren mit hoher Konfidenz identifiziert werden, d.h. dass der Schlupf möglichst gering ist. Zur Bewertung der Verfahren im vorliegenden Anwendungsfall eignet sich daher insbesondere der Recall, welcher die Anzahl korrekt als fehlerhaft klassifizierter Injektoren ins Verhältnis zur Grundgesamtheit aller tatsächlich fehlerhaften Injektoren setzt (siehe Tabelle 2). Vor dem Hintergrund der Strategie, lediglich als fehlerhaft klassifizierte Injektoren physisch zu prüfen, ist es ebenfalls sinnvoll, die Precision der Verfahren zu berücksichtigen. Die Precision gibt dabei an, welcher Anteil der als fehlerhaft prognostizierten Injektoren tatsächlich fehlerhaft war. Da einer Minimierung des Schlupfs jedoch deutlich größere Bedeutung zugemessen wird als einer Reduzierung von Pseudofehlern, wird eine geringere Precision im Vergleich zu einem besseren Recall in Kauf genommen. Ebenso ist

die Accuracy zwar ein guter Indikator für die Klassifikationsgüte der Verfahren, jedoch ist auch diese im Vergleich zum Recall nur nachrangig zu berücksichtigen.

Da die Daten eine hohe Ungleichverteilung der Klassen (fehlerhafte Injektoren und fehlerfreie Injektoren) aufweisen und die Auswirkungen von Schlupf und Pseudofehlern im zugrundeliegenden Anwendungsfall stark divergieren, wurde neben den oben beschriebenen Lernverfahren das MetaCost Verfahren mit einer problemangepassten Kostenmatrix für das Modelltraining verwendet. Das MetaCost Verfahren behandelt den Klassifikator als Black Box und kann unabhängig vom eingesetzten Klassifikationsverfahren eingesetzt werden (Domingos 1999). Durch das Umschließen des Klassifikators durch ein Verfahren zur Kostenminimierung wird dieser hinsichtlich der Kosten einer Fehlklassifikation sensitiviert. Durch die unterschiedliche Gewichtung der durch Fehlklassifikationen entstehenden Kosten kann eine zuverlässige Prognose, insbesondere fehlerhafter Injektoren, sichergestellt werden (Elkan 2001). Die Kostenmatrix kann bei der Optimierung von Hyperparametern und der Evaluation in eine entsprechende Kostenfunktion überführt werden, die sich unabhängig vom verwendeten Lernverfahren auswerten lässt.

		True Label	
		Positive	Negative
Prediction	Positive	0 (TP)	1 (FP)
	Negative	10 (FN)	0 (TN)

*Tabelle 3: Kostenmatrix mit 10-facher Gewichtung von False Negative*

Bei dem MetaCost Verfahren handelt es sich um eine sogenannte Ensemble-Strategie, welche verschiedene Modelle zu einem komplexen Gesamtmodell kombiniert. Neben dem MetaCost Verfahren bieten sich insbesondere auch Boosting-Methoden aufgrund ihrer hohen Klassifikationsgenauigkeit als weitere Vertreter der Ensemble-Strategien an (Schapire 1999), die Daten iterativ so umgewichten, dass zukünftige Klassifikatoren sich auf Beobachtungen fokussieren, die durch vorhergehende Klassifikatoren falsch vorhergesagt wurden. Hierzu zählen

weiter auch Gradient Boosted Trees und Random Forests, welche mehrere Entscheidungsbäume kombinieren, um bestmögliche Prognoseergebnisse zu erzielen.

Eine weitere Maßnahme zur Verbesserung des Recall kann im Rahmen der Vorverarbeitung durch den Ausgleich der hohen Ungleichverteilung zwischen fehlerhaften und fehlerfreien Injektoren ergriffen werden. Wie sich auch im analysierten Datenauszug zeigt, liegen übliche Fehlerquoten in der heutigen Injektorfertigung im Bereich weniger Prozent, woraus sich zwangsläufig eine hohe Ungleichverteilung zwischen fehlerhaften und fehlerfreien Injektoren ergibt. Im Data Mining existieren verschiedene Ansätze, um diese Herausforderung zu bewältigen. Eine Möglichkeit zum Umgang mit einem großen Ungleichgewicht der Verteilung von Klassen besteht darin, die Anzahl der Beobachtungen der seltenen Klasse durch Replikation bzw. synthetische Generierung zu erhöhen (engl. oversampling) oder die Anzahl der Beispiele der häufig vorkommenden Klasse mittels zufälliger Auswahl zu senken (engl. undersampling) (Elkan 2001). Die Strategie des Undersamplings wird hierbei bevorzugt eingesetzt, da diese zu kleineren Datenmengen führt, welche sich effizienter analysieren lassen (Aggarwal 2015). Beide Formen des Samplings können ebenso wie MetaCost unabhängig vom verwendeten Lernverfahren eingesetzt werden.

#### 2.4. Evaluierung und Bereitstellung

Für die Evaluierung der eingesetzten Verfahren wurde der Datensatz zunächst in eine Trainingsmenge (70%) und eine Testmenge (30%) geteilt. Durch diese Teilung wird eine bessere Schätzung der Prognosegüte ermöglicht. Aufgrund der vorliegenden großen Datenmenge konnte dabei auf Verfahren wie die Kreuzvalidierung zur Teilung der Daten verzichtet werden und eine zufällige Teilung bei gleichbleibendem Verhältnis von fehlerhaften und fehlerfreien Injektoren innerhalb der Teilmengen vorgenommen werden.

Im Rahmen der Evaluierung zeigten die ausgewählten Grundverfahren zwar eine gute Accuracy, lieferten jedoch einen schlechten Recall. Bei Verwendung von Naive Bayes beispielsweise konnte eine Accuracy von 96,15% erzielt werden, wohingegen der Recall lediglich bei 33,83% lag (siehe Tabelle 4).

		True Label		
		Fehlerhaft	Fehlerfrei	
Prediction	Fehlerhaft	1.021	635	Precision 61,65%
	Fehlerfrei	1.997	64.667	NPV 97,00%
		Recall 33,83%	SPC 99,03%	Accuracy 96,15%

Tabelle 4: Konfusionsmatrix bei Verwendung von Naive Bayes

Ein höherer Recall konnte durch Verwendung der Ensemble-Strategie MetaCost in Verbindung mit einer  $k$ -fachen Gewichtung der Fehlklassifikation fehlerhafter Injektoren in der Kostenmatrix erzielt werden (siehe Tabelle 5).

k	Accuracy	Precision	NPV	Recall	SPC
10	97,17%	84,60%	97,46%	43,87%	43,87%
30	97,00%	78,38%	97,47%	44,20%	99,44%
100	4,43%	4,42%	100%	100%	0,02%

Tabelle 5: Gütemaße bei Verwendung von MetaCost mit  $k$ -facher Gewichtung von Fehlklassifikationen fehlerhafter Injektoren

Wie Tabelle 5 zeigt, konnte durch eine 30-fache Gewichtung der Fehlklassifikation fehlerhafter Injektoren in der Kostenmatrix der Recall auf 44,20% bei einer Accuracy von 97,00% erhöht werden.

Eine höhere Gewichtung (z. B. 100-fach) würde zwar einen Recall von 100% ermöglichen, führt jedoch zu einer drastischen Senkung der Accuracy auf 4,43% und der Spezifität auf 0,02%.

Durch die Verwendung der Ensemble-Strategie Random Forests konnte der Recall auf 61,93% bei einer Accuracy von 98,03% erhöht werden. Dieses Ergebnis konnte schließlich durch den Einsatz von Gradient Boosted Trees in Verbindung mit einer Optimierung der Hyperparameter

und Undersampling, einer zufälligen Entfernung von ca. 50% der Beobachtungen fehlerfreier Injektoren zum Ausgleich des hohen Klassenungleichgewichts, weiter auf einen Recall von 81,20% auf der Testmenge bei einer Accuracy von 97,74% verbessert werden.

Vor dem Hintergrund der eingangs vorgestellten Strategien zur Engpassentlastung in der Qualitätsprüfung der Injektorfertigung sowie aus Sicht des Data Mining sind diese Ergebnisse lediglich als Resultat einer ersten Machbarkeitsstudie und Potenzialanalyse zu bewerten. Die vorgestellten Ergebnisse demonstrieren, dass Datensätze, die eine hohe Ungleichverteilung der Beobachtungen verschiedener Klassen aufweisen, eine spezielle Behandlung erfordern. Die Kombination von Undersampling und Boosting mittels Ensemble-Methoden erscheint im vorliegenden Fall vielversprechend.

Die Vorhersagegüte hängt meist nicht nur vom verwendeten Lernverfahren, sondern insbesondere vom richtigen Umgang mit den gegebenen Merkmalen ab. In einem nächsten Schritt sollen daher verschiedene Verfahren für die vorgängige Selektion, Gewichtung und Transformation von Merkmalen getestet werden. Es kann auch sein, dass Untergruppen der Beispiele unterschiedlich gut klassifiziert werden können. In weiteren Schritten soll darum die Menge der Beobachtungen manuell und automatisch mittels Clustering-Verfahren in sinnvolle Gruppen eingeteilt werden, deren Beobachtungen dann mit verschiedenen Modellen klassifiziert werden können. Es ist auch möglich, dass die starke Aggregation der Prozessparameter zum Verlust von Information führt, die für eine korrekte Klassifikation benötigt wird. In Zukunft ist folglich zu prüfen, ob durch Heranziehen der ursprünglich während der Produktion aufgezeichneten Sensorwerte bessere Klassifikationsergebnisse erzielt werden können. Hier besteht die Herausforderung für das Data Mining in einer effizienten Extraktion relevanter Merkmale aus großen Mengen zeitlich geordneter Sensorwerte in Echtzeit (Stolpe et al. 2016).

### 3. Zusammenfassung und Ausblick

Die Qualitätsprüfung in der Großserienfertigung von Injektoren stellt viele Herausforderungen an den Einsatz von Data Mining zur Engpassentlastung mittels Qualitätsprognosen. Potenziale bestehender Verfahren zur Engpassentlastung in Form einer Reduktion der Prüfdauer sind jedoch bereits ausgeschöpft, sodass neue datengetriebene Methoden, z. B. der Einsatz von Data Mining, erschlossen werden müssen.

Im vorliegenden Anwendungsfall wurden für das Data Mining zunächst aggregierte Prüfmerkmale für die Modellierung verwendet. Wie die vorgestellten Ergebnisse erster Analysen zeigen, reichen die bisher erzielte Precision und Recall jedoch noch nicht aus, um die Qualitätsprognose in den Prüfprozess zu integrieren und diesen Engpass zu entlasten. Es bestehen jedoch weitere Möglichkeiten, um diese Ergebnisse zu verbessern. Da während der Aggregation der Daten gewöhnlich ein Informationsverlust auftritt, ist im Rahmen weiterer Analysen folglich zu prüfen, ob auf den unverarbeiteten Zeitreihen bessere Ergebnisse erzielt werden können. Dies gilt im Besonderen für die Parameter der Endprüfung, da die diskreten Prüfmerkmale bereits eine Vereinfachung einer zeitkontinuierlichen Messung darstellen. Zukünftig muss daher eine Merkmalsselektion durchgeführt werden, um zu identifizieren, welche Produktionsschritte bzw. Prüfmerkmale von besonderer Relevanz für die Qualitätsprognose sind. Im Ausblick stehen daher die Anwendung weiterer Data Mining Verfahren sowie Parameteroptimierungen auf den unvorverarbeiteten Daten, um eine prozessfähige Qualitätsprognose mit entsprechender Prognosegüte zu erzielen. Können die Prognoseergebnisse durch Anwendung dieser Maßnahmen verbessert werden, kann die Qualitätsprognose anschließend für die Erstellung produktindividueller Prüfpläne herangezogen werden. Weiterhin kann durch die Anwendung von Verfahren zur Schlupf-Minimierung eine Stichprobenprüfung der Injektoren realisiert und folglich die Gesamtprüfdauer weiter reduziert werden.

Ein weiterführender Ausblick umfasst die prozessimmanente Qualitätskontrolle zur Entlastung der Qualitätsprüfung der Injektoren. Durch die prozessbegleitende Prognose und Kontrolle der Qualität besteht die Möglichkeit, die Wertschöpfung an fehlerhaften Bauteilen frühzeitig abubrechen bzw. durch eine entsprechende Prozessregelung die Qualität der Injektoren in den nachfolgenden Produktionsschritten so zu beeinflussen, dass das finale Qualitätsniveau den Anforderungen entspricht. Hierdurch erfolgt nicht nur eine Engpassentlastung der finalen Qualitätsprüfung, sondern es bietet sich ebenso ein großes Einsparungspotenzial für Fehlerkosten und Mehrkosten durch zusätzliche Wertschöpfung an fehlerhaften Injektoren.

## Literatur

- Aggarwal, Charu C. (2015): *Data Mining. The Textbook*. Cham: Springer International Publishing.
- Chapman Pete; Clinton, Julian; Kerber, Randy; Khabaza, Thomas; Reinartz, Thomas; Shearer, Colin; Wirth, Rüdiger (2000): *CRISP-DM 1.0. Step-by-step data mining guide*: SPSS Inc.
- Domingos, Pedro (1999): *Metacost: A general method for making classifiers cost-sensitive*. Proceedings of the fifth ACM SIGKDD international conference on Knowledge discovery and data mining. ACM.
- Eickelmann, Michel; Schallow, Julian; Jalali Sousanabady, Reza; Deuse, Jochen (2015a): *Lebenszyklusübergreifende Qualitätsservices. Cloudbasierte Service-Plattform zur intelligenten Prognose qualitäts-bestimmender Daten*. In: Zeitschrift für wirtschaftlichen Fabrikbetrieb 110 (4), S. 167–171.
- Eickelmann, Michel; Wiegand, Mario; Konrad, Benedikt; Deuse, Jochen (2015b): *Die Bedeutung von Data-Mining im Kontext von Industrie 4.0*. In: Zeitschrift für wirtschaftlichen Fabrikbetrieb 110 (11), S. 738–743.
- Elkan, Charles (2001): *The Foundations of Cost-sensitive Learning*. In: Proceedings of the 17th International Joint Conference on Artificial Intelligence - Volume 2. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc (IJCAI'01), S. 973–978.
- Fayyad, Usama; Piatetsky-Shapiro, Gregory; Smyth, Padhraic (1996): *From Data Mining to Knowledge Discovery in Databases*. In: AI Magazine 17 (3), S. 37–54.
- Hastie, Trevor; Tibshirani, Robert; Friedman, Jerome (2009): *The Elements of statistical learning. Data mining, inference, and prediction*. 2nd ed. New York: Springer.
- Roser, Christoph; Lorentzen, Kai; Deuse, Jochen (2015): *Reliable Shop Floor Bottleneck Detection for Flow Lines through Process and Inventory Observations. The Bottleneck Walk*. In: Logistics Research 8 (7), S. 1–9.
- Schapire, Robert E. (1999): *A Brief Introduction to Boosting*. In: Proceedings of the 16th International Joint Conference on Artificial Intelligence - Volume 2. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc (IJCAI'99), S. 1401–1406.
- Stolpe, Marco; Blom, Hendrik; Morik, Katharina (2016): *Sustainable Industrial Processes by Embedded Real-Time Quality Prediction*. In: Jörg Lässig, Kristian Kersting und Katharina Morik (Hg.): Computational Sustainability, Bd. 645. Cham: Springer International Publishing (Studies in Computational Intelligence), S. 201–243.
- Witten, Ian H.; Frank, Eibe; Hall, Mark A. (2011): *Data mining. Practical machine learning tools and techniques*. Third edition, transferred to digital printing in 2013. Burlington, MA: Morgan Kaufmann.