















Kollaborative, modulare Datenanalyse als Werkzeug im Qualitätsmanagement

10

Potenziale von Citizen Data Science im
Qualitätsmanagement zur Erweiterung
der Feldbeobachtung

Martina Ringeln , Sibylle Legner , Sebastian Pähler ,
Katharina John , Andreas Cibis , Ralf Gryga , Lennart Krüger ,
Corinna Osterbrink , Felix Reinhart , Edin Klavic , Ralf Klinkenberg ,
Marius Syberg , Hermann Ferstl , Tanja Sindram, Michael Doukas und
Jochen Deuse 

M. Ringeln (✉) · S. Legner · S. Pähler · K. John · A. Cibis · R. Gryga · L. Krüger ·
C. Osterbrink · F. Reinhart
Miele & Cie. KG, Gütersloh, Deutschland
E-Mail: martina.ringeln@miele.com

S. Legner
E-Mail: sibylle.legner@miele.com

S. Pähler
E-Mail: sebastian.paehler@miele.com

K. John
E-Mail: katharina.john@miele.com

A. Cibis
E-Mail: andreas.cibis@miele.com

R. Gryga
E-Mail: ralf.gryga@miele.com

L. Krüger
E-Mail: lennart.krueger@miele.com

C. Osterbrink
E-Mail: corinna.osterbrink@miele.com

F. Reinhart
E-Mail: felix.reinhart@miele.com

E. Klavic · R. Klinkenberg
RapidMiner GmbH, Dortmund, Deutschland
E-Mail: eklavic@rapidminer.com eklavic@altair.com

10.1 Motivation

Die Vision von industriellen Datenanalysen, Daten entlang der gesamten Wertschöpfungskette mit Daten aus dem Produktlebenszyklus zu vernetzen, beinhaltet großes Potenzial für ganzheitliche Qualitätsverbesserungen. Industrielle Datenanalyse ist ein Sammelbegriff für datenwissenschaftliche Werkzeuge zur faktenbasierten Entscheidungsfindung in industriellen Anwendungsfällen (West et al., 2021a, S. 131). Um dieses zunehmende Potenzial ausschöpfen zu können, bedarf es vor allem zielgerichteter Werkzeuge und Strategien für Datenwissenschaften sowie der Befähigung von Expertinnen und Experten im Qualitätsmanagement (siehe Kap. 2). Diese entwickeln sich somit in die Rolle von sogenannten *Citizen Data Scientists*, welche Werkzeuge der Datenwissenschaften gewinnbringend verwenden, weiterentwickeln oder bei der Weiterentwicklung mitarbeiten (Schwenken et al., 2023, S. 84). Gleichzeitig bedeutet dies auch, dass die bekannten und etablierten Methoden und Systeme des Qualitätsmanagements mit Methoden der Datenwissenschaften in Einklang gebracht werden müssen (siehe hierzu Schäfer et al., 2018, S. 190 ff.). In diesem Kapitel wird beschrieben, wie mithilfe von modularen Analysebausteinen eine Lösung zur Unterstützung der Feldbeobachtungen bei Miele entwickelt wurde. Die Zielsetzung war hierbei herauszufinden, wie das für konkrete Fragestellungen aus der Praxis mit Hilfe des für solche Aufgaben konzipierten Referenzbaukastens im Forschungsprojekt AKKORD konkret gelingen kann (siehe Kap. 4).

R. Klinkenberg

E-Mail: rklinkenberg@rapidminer.com; rklinkenberg@altair.com

M. Syberg

Technische Universität Dortmund, Dortmund, Deutschland

E-Mail: marius.syberg@ips.tu-dortmund.de

H. Ferstl · T. Sindram · M. Doukas · J. Deuse

mosaic GmbH, München, Deutschland

E-Mail: hermann.ferstl@mosaic.com

T. Sindram

E-Mail: tanja.sindram@mosaic.com

M. Doukas

E-Mail: michael.doukas@mosaic.com

J. Deuse

E-Mail: jochen.deuse@ips.tu-dortmund.de

10.2 Datenwissenschaft und Feldbeobachtung im Qualitätsmanagement

Der Anwendungsfall ist im Bereich der Feldbeobachtung im Qualitätsmanagement angesiedelt, dessen wichtigste Aspekte im Folgenden kurz erläutert werden.

10.2.1 Datenwissenschaft im Qualitätsmanagement

Seit jeher arbeiten im Unternehmen Miele, genauso wie in anderen Unternehmen, Expertinnen und Experten mit verschiedenen fachlichen Hintergründen gemeinsam an der Sicherung der Qualität von Produkten und Prozessen. Qualität entsteht dabei nicht vorwiegend im Qualitätsmanagement, sondern beispielsweise in der Entwicklung oder der Produktion. Wobei das Qualitätsmanagement als Führungsinstrument für die gesamte Organisation fungiert und dabei als technischer Controller dient. Dies lässt sich z. B. aus den grundlegenden Anforderungen der ISO 9001 für ein Qualitätsmanagementsystem ableiten (DIN EN ISO 9001: 2015-11). Hierin werden Unternehmen dazu aufgefordert, ihre gesamte Organisation und die Prozesse auf die Erfüllung der Kundenanforderungen auszurichten und damit die gewünschte Qualität zu erreichen.

Vorreiter beim Thema Data Science sind Entwicklung, Service und Produktion. Dort werden unter der Überschrift „Internet of Things“ (IoT) bzw. „Industrial Internet of Things“ (IIoT), neue Produkte und Features für Endanwender bzw. neue, effiziente Fertigungstechnologien ermöglicht. Aus der zentralen Sicht des Qualitätsmanagements entstehen durch die Verfügbarkeit besserer und umfangreicherer Daten und Methoden einzigartige Möglichkeiten, Qualität ganzheitlicher über den gesamten Produktlebenszyklus zu bewerten (Schmitt & Pfeifer, 2015, S. 36). Die Expertise der Mitarbeitenden im Qualitätsmanagement als Daten- und Informationsvernetzer zu Qualitätsthemen, mit Erfahrung in der Einschätzung und Bewertung von Daten aus unterschiedlichen Kontexten, ist bei der Umsetzung solcher Themen unerlässlich.

10.2.2 Feldbeobachtung

Die Daten aus der Nutzungsphase der Produkte, die Gegenstand der Feldbeobachtung sind, stammen klassischerweise aus der Auswertung von Kundendienst-Einsätzen (VDA QMC, 2009). Inhalt der Feldbeobachtung ist, neben der Erfüllung der Produktbeobachtungspflichten (§ 823 BGB und ProdHaftG), die Beobachtung der erlebten Produktqualität im Feld, mit dem Ziel, mögliche Qualitätsabweichungen schnell zu erkennen und langfristig abzustellen. Darüber hinaus lassen sich Erkenntnisse über die erlebte Qualität beim Kunden auch für Neuentwicklungen nutzen (Schmitt & Pfeifer, 2015, S. 249 ff.).

Da sich sehr unterschiedliche Einflüsse, z. B. von Produktausprägung, Produktionsmengen und Produktnutzung, in den Felddaten niederschlagen, erfordert die Analyse und Auswertung dieser Daten, oft in Form von Zeitreihen, Expertenwissen. Eine Besonderheit der Feldbeobachtung erwächst daraus, dass hier Daten mit potenziellem Kundenbezug betrachtet werden. Diese Daten und Informationen sind sehr wertvoll, da sie direkte Rückschlüsse auf die erlebte Qualität beim Kunden erlauben (Schmitt & Pfeifer, 2015, S. 97 ff.). Gleichzeitig schränkt die Berücksichtigung von Datenschutzanforderungen die Möglichkeiten für Auswertungen und Datenverknüpfungen stark ein. In diesem Kontext stellt die Feldbeobachtung beim Qualitätsmanagement hohe Anforderungen an eine durchgängige Qualität der zu analysierenden Daten (West et al., 2021, S. 131 ff.).

Für die Feldbeobachtung stehen zunehmend weitere Datenquellen zur Verfügung, insbesondere Daten aus vernetzten IoT-Geräten (Ewerszumrode et al., 2021). Außerdem ermöglichen es neue Werkzeuge, aber auch die wachsende Qualität und Verfügbarkeit von Daten aus Datenbanken, systematische Analysen auf weitere bekannte Datenquellen auszuweiten.

10.3 Zielsetzung im Forschungsvorhaben

„Wie können die Experten im Umfeld der Feldbeobachtung dazu befähigt werden, die Potenziale von neuen und bekannten Daten mittels Datenwissenschaften optimal zu heben?“ – so lässt sich die Fragestellung des Anwendungsfalls an AKKORD grob umreißen. Während der Anwendungsfall in Kap. 2 bereits kurz dargestellt wurde, wird nachfolgend die Unterstützung, die der Referenzbaukasten hinsichtlich der konkreten Problemsetzung bietet, detaillierter beschrieben.

10.3.1 Befähigung und gezielte Qualifikation von Mitarbeitern

Die Mitarbeitenden aus dem Qualitätsmanagement haben zwar eine hohe Expertise im Umgang mit Daten auf ihrem Gebiet sowie zu Qualitätsthemen und relevanten Prozessen, aber meist keine Erfahrung mit Datenwissenschaften. Das zeigte auch die qualitative Befragung, die zur Erstellung von sogenannten *Personas* im Rahmen des Anwendungsfalls durchgeführt wurde. Damit diese Mitarbeitenden in die Rolle als Citizen Data Scientists hineinwachsen können, war es ein Anliegen, Instrumente zur Qualifikation der Mitarbeitenden in der entwickelten *Work&Learn-Plattform* zur Verfügung zu haben. Eine ausführliche Beschreibung dieser Plattform findet sich weiterführend in Kap. 7 und 11. Dabei zeigte sich, dass eine Weiterbildung sowohl zu reinen Datenthemen als auch zu Vorgehensmodellen und Methoden sehr hilfreich ist. Das u. a. für die Verwendung des Referenzbaukastens entwickelte Vorgehensmodell wird darüber hinaus beschrieben in Kap. 16.

10.3.2 Niederschwelliger Einstieg in Datenanalysen für konkrete Anwendungsfälle

Wie in Abschn. 10.4.1 näher ausgeführt wird, ähneln sich viele Fragestellungen an Zeitreihendaten (siehe Schlegl et al., 2022, S. 52 ff.; West et al., 2021a, S. 762 ff.), die beispielsweise auch in der Feldbeobachtung relevant sind, sehr. Daher war ein Anliegen aus dem Anwendungsfall, Analysebausteine, die in bekannten Zusammenhängen erfolgreich erprobt wurden, zur Nutzung in anderen Kontexten zur Verfügung stellen zu können.

Die im Referenzbaukasten umgesetzte Lösung begegnet genau diesen Anforderungen (siehe Kap. 6). Ein für den hier beschriebenen Anwendungsfall sehr nützlicher Bestandteil ist die im Vorhaben entwickelte *AI-Toolbox*. Diese bietet die Möglichkeit, Analysen auf einer Web-Oberfläche bereitzustellen, sodass die Berechnungen auf anderen Datensätzen durchgeführt werden können, ohne den „Umweg“ über eine dezidierte Software oder Programmierung. Um die Nutzbarkeit auch im Umfeld von potenziell sensiblen Daten aus dem Unternehmen zu gewährleisten, ist es dabei wichtig, dass die Plattform auch in der geschlossenen IT-Umgebung innerhalb des Unternehmens nutzbar ist.

10.4 Einsatz Industrieller Datenanalysen in der Feldbeobachtung

Im Rahmen des Forschungsprojekts wurden Analysen zu verschiedenen Datenquellen erarbeitet, mit dem Ziel, die serienbegleitende Qualitätsüberwachung zu erweitern und zu vereinfachen. Für das Forschungsprojekt wurden u. a. Daten aus den Ersatzteilverkäufen und anonymisierte Daten aus vernetzten IoT-Geräten gewählt. Diese beiden Datensätze sind nicht direkt mit anderen Daten verknüpfbar und nicht personenbezogen, was in Hinblick auf den Datenschutz und die Vereinfachung von Fragestellungen in diesem Zusammenhang hilfreich ist.

Ein weiterer Anwendungsfall mit internationalen Kundendienst-Daten diene ebenfalls der Validierung.

Die wesentlichen Ergebnisse und Erkenntnisse werden im Folgenden vorgestellt.

10.4.1 Inhaltliche und Methodische Umsetzung

In datenwissenschaftlichen Projekten beruht die Erstellung von erfolgreichen Analysen und Modellen stets auf einem Verständnis der Daten und des Anliegens der Nutzer, auch Geschäftsverständnis genannt, sowie einer entsprechenden Evaluation der Ergebnisse (Chapman et al., 2000, S. 13). Die Personen, die im hier betrachteten Anwendungsfall geeignete Analysebausteine erstellten, brachten bereits sehr gute Vorkenntnisse in diesen Bereichen ein. Die vorgesehenen Akteurinnen und Akteure sind angelehnt an das erarbeitete Rollenkonzept des Forschungsvorhabens (Schwenken et al., 2023, S. 84).

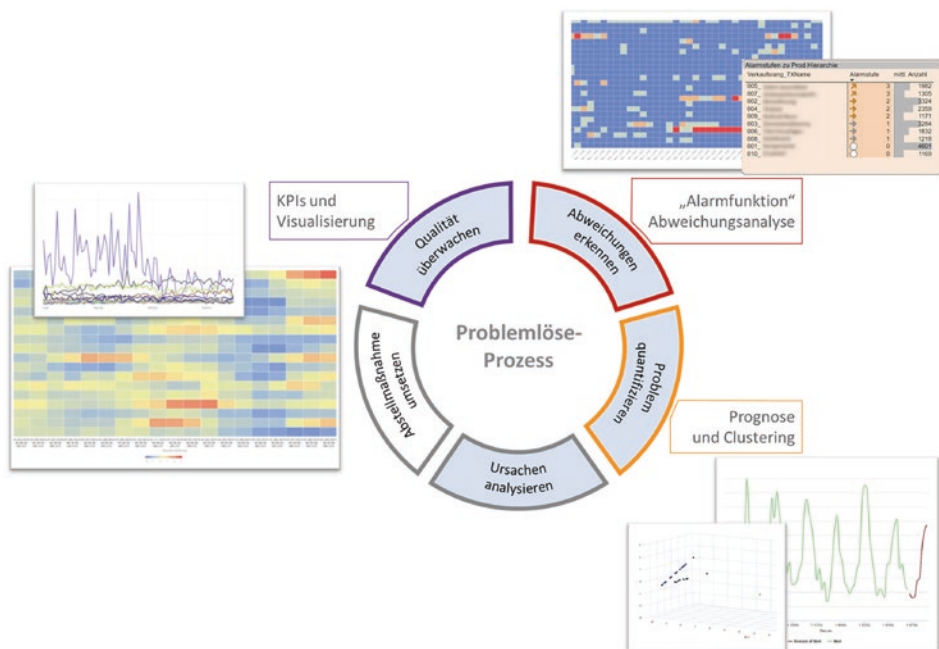
Es zeigte sich, dass ein Vorgehen mit wenigen, passenden Methoden die Projektarbeit strukturiert, die Ergebnisse objektiviert sowie die Akzeptanz und Sichtbarkeit der Arbeit erhöht. Folgender Ansatz wurde in zwei Anwendungsfällen (Ersatzteilverkäufe und internationale Kundendienst-Daten) erfolgreich erprobt:

- **Datenverständnis:** Daten und deren Zusammenhänge wurden in Informationsmodellen bzw. in einem Business Glossar charakterisiert. Die entsprechenden Datenstrukturen wurden auch zum Abgleich als Anwendungsbeispiel für das Datenbackend in AKKORD zur Verfügung gestellt (siehe Kap. 5).
- **Geschäftsverständnis und Nutzerbezug:** Die wichtigsten Nutzergruppen von Ergebnissen der Felddatenanalyse wurden befragt und in Form von 7 Personas charakterisiert. Personen aus diesen Nutzergruppen wurden zusätzlich vor der Modellbildung über Fragebögen zu ihren Einschätzungen und Priorisierungen der Anwendungsfälle befragt.
- **Evaluation:** Die o. g. Nutzergruppen wurden in die Evaluation der Ergebnisse, wieder über Fragebögen, mit einbezogen. Zusätzlich wurde das Gesamtergebnis immer anhand historischer Befunde auf Plausibilität geprüft.

Inhaltlich bezieht der Anwendungsfall seine Analyse-Fragestellungen aus der serienbegleitenden Qualitätsüberwachung, in der Hinweise auf Qualitätsabweichungen aufgenommen und bewertet werden. Für vorhandene Qualitätsabweichungen werden in diesem Bereich auch Abstellmaßnahmen erarbeitet und umgesetzt. Dieser Prozess wird in einem interdisziplinären Team durchgeführt.

In einer vereinfachten Darstellung dieses Vorgehens, in Abb. 10.1 analog zum Six Sigma DMAIC Zyklus skizziert, ist gut erkennbar, dass viele wichtige Analysefragestellungen unabhängig von der betrachteten Datenquelle sehr ähnlich sind: Um mögliche Probleme zu erkennen, wird typischerweise eine Analyse von Abweichungen in Zeitreihendaten benötigt. Die so gefundenen Auffälligkeiten sollten dann näher charakterisiert und quantifiziert werden. Typische Fragestellungen in diesem Themenbereich sind die nach Prognose-Szenarien oder nach möglichen Clustern mit ähnlichen Attributen. Und, nachdem Maßnahmen umgesetzt wurden, werden Visualisierungen von Kenngrößen als Tool zur Überwachung der Qualität benötigt, die dann auch wieder bei der Erkennung von Abweichungen unterstützen können.

In diesen Kategorien sind in der Projektlaufzeit verschiedene generalisierte Analysebausteine für konkrete Anwendungsfälle bei Miele und durch das Projektteam von Miele mit Unterstützung von RapidMiner entstanden. Ergänzend widmete sich das IPS der Aufgabe, solche Bausteine speziell für den allgemeineren Gebrauch auf der AI-Toolbox zu erstellen, und nutzte dazu anonymisierte Daten aus vernetzten IoT-Geräten (siehe Kap. 6). So befinden sich heute unterschiedliche Bausteine zur Visualisierung von Daten als Liniendiagramme, zur Prognose mit unterschiedlichen Verfahren, zur vergleichenden



10.4.2 Technische und strategische Einbindung

Einige Rahmenbedingungen, um nicht nur weiterhin Citizen Data Science im Qualitätsmanagement zu betreiben, sondern diese Initiativen noch ausbauen zu können, wurden bereits in der Projektlaufzeit gesetzt: Auf der technischen Seite steht die Sicherstellung der Geheimhaltung und des Datenschutzes durch eine Version der *AI-Toolbox* in Form von Docker containern. Diese wird innerhalb der IT-Landschaft der Firma betrieben und erhöht damit die Praxistauglichkeit der *AI-Toolbox* auch für andere Firmen. Die strategische Einbindung erfolgt über Change-Maßnahmen. Hier wurde im Projekt unter Federführung von mosaiaic ein Nutzenvideo erstellt, das die Motivation aus AKKORD für Miele und den Use Case illustriert und den Rollout begleiten soll. Näheres zu den Hintergründen und zum Change-Management in AKKORD ist in Kap. 16 zu finden.

10.5 Fazit

Auch nach Abschluss des Projekts bei Miele sollen alle Ergebnisse aus dem Forschungsprojekt weiterhin genutzt und weiterentwickelt werden. Mit dem Rollout und durch die strategische Ausrichtung im Qualitätsmanagement bei Miele ist zu erwarten, dass sich der Anwender- und Nutzerkreis erweitern wird. Die Konzepte und Bausteine, die im Anwendungsfall erarbeitet wurden, wurden auch immer in Hinblick auf Übertragbarkeit und Generalisierbarkeit hin entwickelt und sind daher in ähnlichen Kontexten allgemein nutzbar.

Durch die sehr gute Kombination und Vernetzung von Wissensaufbau, Datenwissenschaften, Mitarbeiterereinbindung und Change Aktivitäten konnte für den Themenkomplex „Industrial Data Science“ ein hohes Bewusstsein mit gleichzeitiger Akzeptanz geschaffen werden. Dieser Umstand wird uns als QM im vernetzten Miteinander in der Miele Organisation entlang der kompletten Wertschöpfungskette, von der Idee bis zur Nutzungsphase, in die Lage versetzen, zukünftig einfach und gemeinsam Data-Science-Projekte durchzuführen. Ein weiterer wichtiger Aspekt ist die Verfestigung des Wissens und der Akzeptanz an der Basis. Die gesamte Organisation wird somit in die Lage versetzt Ideen für Data Science Aktivitäten zu entwickeln.

Darüber hinaus wurden im interdisziplinären Team bei Miele, befeuert durch das Forschungsvorhaben AKKORD, Gruppen und Initiativen entwickelt, die von allen Funktionen genutzt werden können. In Kap. 20 wird dazu eine tiefergehende Analyse der bevorstehenden Weiterentwicklung industrieller Datenanalysen im Zusammenspiel von Mensch, Technik und Organisation dargestellt.

Literatur

- Chapman, P., Clinton, J., Kerber, R., Khabaza, T., Reinartz, T., Shearer, C., & Wirth, R. (2000). CRISP-DM 1.0. Step-by-Step data mining guide, CRISP-DM consortium.
- DIN EN ISO 9001:2015-11, Qualitätsmanagementsysteme - Anforderungen (ISO_9001:2015); Deutsche und Englische Fassung EN_ISO_9001:2015.

- Ewerszumrode, J., Schöne, M., Godt, S., & Kohlhase, M. (2021). Assistenzsystem zur Qualitätssicherung von IoT-Geräten basierend auf AutoML und SHAP. In H. Schulte, F. Hoffmann, & R. Mikut (Hrsg.), *Proceedings – 31. Workshop computational intelligence*: Berlin, 25.–26. November 2021. KIT Scientific Publishing. (S 285–305).
- Schäfer, F., Zeiselmaier, C., Becker, J., & Otten, H. (2018). Synthesizing CRISP-DM and quality management: A data mining approach for production processes *IEEE International Conference on Technology Management, Operations and Decisions (ICTMOD)*, Marrakech, Morocco. (S. 190–195). <https://doi.org/10.1109/ITMC.2018.8691266>.
- Schlegl, T., Tomaselli, D., Schlegl, S., West, N., & Deuse, J. (2022). Automated search of process control limits for fault detection in time series data. *Journal of Process Control*, 117, 52–64. <https://doi.org/10.1016/j.jprocont.2022.07.002>.
- Schmitt, R., & Pfeifer, T. (2015). *Qualitätsmanagement: Strategien, Methoden, Techniken* (5. Aufl.). Hanser.
- Schwenken, J., Klupak, C., Syberg, M., West, N., Walker, F., & Deuse, J. (2023). Development of a transdisciplinary role concept for the process Chain of industrial data science. In A. Khanna, Z. Polkowski, & O. Castillo (Hrsg.), *Proceedings of data analytics and management. Lecture notes in networks and systems* (Bd. 572). Springer. https://doi.org/10.1007/978-981-19-7615-5_7.
- VDA QMC Verband der Automobilindustrie und Qualitätsmanagement-Center. (2009). *Schadteilanalyse Feld: Vermarktung und Kundenbetreuung* (1. Aufl.). VDA QMC.
- West, N., Gries, J., Brockmeier, C., Göbel, J. C., & Deuse, J. (2021a). Towards integrated data analysis quality. Criteria for the application of industrial data science. *IEEE International Conference on Information Reuse and Integration for Data Science (IRI)*, 22(1), 131–138. <https://doi.org/10.1109/IRI51335.2021.00024>.
- West, N., Schlegl, T., & Deuse, J. (2021b). Feature extraction for time series classification using univariate descriptive statistics and dynamic time warping in a manufacturing environment. In *IEEE 2nd International Conference on Big Data, Artificial Intelligence and Internet of Things Engineering* (S. 762–768). <https://doi.org/10.1109/ICBAIE52039.2021.9389954>.

Open Access Dieses Kapitel wird unter der Creative Commons Namensnennung 4.0 International Lizenz (<http://creativecommons.org/licenses/by/4.0/deed.de>) veröffentlicht, welche die Nutzung, Vervielfältigung, Bearbeitung, Verbreitung und Wiedergabe in jeglichem Medium und Format erlaubt, sofern Sie den/die ursprünglichen Autor(en) und die Quelle ordnungsgemäß nennen, einen Link zur Creative Commons Lizenz beifügen und angeben, ob Änderungen vorgenommen wurden.

Die in diesem Kapitel enthaltenen Bilder und sonstiges Drittmaterial unterliegen ebenfalls der genannten Creative Commons Lizenz, sofern sich aus der Abbildungslegende nichts anderes ergibt. Sofern das betreffende Material nicht unter der genannten Creative Commons Lizenz steht und die betreffende Handlung nicht nach gesetzlichen Vorschriften erlaubt ist, ist für die oben aufgeführten Weiterverwendungen des Materials die Einwilligung des jeweiligen Rechteinhabers einzuholen.

