

Nutzerzentrierte Evaluation einer Mensch-Maschine-Schnittstelle zur KI-basierten multivariaten statistischen In-Prozess Kontrolle in der Fertigung

Nina THEOBALD¹, Tobias BIEGEL², Tim STEINEBACH¹, Philip JOISTEN¹

¹ *Technische Universität Darmstadt, Fachbereich Maschinenbau,
Institut für Arbeitswissenschaft,
Otto-Berndt-Straße 2, D-64287 Darmstadt*

² *Technische Universität Darmstadt, Fachbereich Maschinenbau,
Institut für Produktionsmanagement, Technologie und Werkzeugmaschinen,
Otto-Berndt-Straße 2, D-64287 Darmstadt*

Kurzfassung: Dieser Beitrag präsentiert die Ergebnisse einer nutzerzentrierten Evaluation einer Mensch-Maschine-Schnittstelle (MMS) zur KI-basierten multivariaten statistischen In-Prozess Kontrolle (MSPC) in der Fertigung. Die Ergebnisse zur Usability (Gebrauchstauglichkeit) zeigen, dass Maschinenbediener*innen der Integration der MMS positiv gegenüberstehen und die MMS ihnen hilft, das Vorhandensein bzw. Auftreten von Anomalien zu erkennen. Das subjektive Beanspruchungsempfinden in der Dimension der geistigen Anforderungen der Maschinenbediener*innen weist jedoch darauf hin, dass die entwickelte MMS Verbesserungspotenzial und weiteren Forschungs- und Entwicklungsbedarf in der Unterstützung bei der Ursachenanalyse von Anomalien aufweist.

Schlüsselwörter: Statistische Prozesskontrolle, Qualitätsmanagement, Künstliche Intelligenz, Mensch-Maschine-Schnittstelle, Nutzerstudie

1. Einleitung

Ein Produktionsprozess unterliegt zwei Arten von Variabilität (International Organization for Standardization 2013): Zum einen zufälligen, unkontrollierbaren Abweichungen, die inhärenter Bestandteil des Prozesses sind, wie bspw. Temperaturschwankungen und Messungenauigkeit, und nicht ohne Veränderung des Prozesses zu eliminieren sind. Zum anderen systematischen, kontrollierbaren Abweichungen, die bspw. durch Werkzeugverschleiß, maschinelle Defekte oder menschliches Versagen bedingt sind und als nicht inhärenter Bestandteil des Prozesses eliminiert werden können. Ein Prozess ist statistisch kontrolliert, wenn er ausschließlich zufälligen Abweichungen unterliegt (International Organization for Standardization 2019).

Das Ziel der statistischen Prozesskontrolle (SPC) ist die Überwachung von statistisch kontrollierten Prozessen zur Detektion, Lokalisation und Elimination von systematischen Abweichungen (Ferrer 2007; Kourti & MacGregor 1996). Die konventionelle, von Walter A. Shewhart im Jahr 1924 entwickelte SPC der diskreten Fertigung stellt eine univariate statistische Post-Prozess Kontrolle (USPC) dar (Ferrer 2007; International Organization for Standardization 2019). Hierbei wird in regelmäßigen Zeitabständen eine Stichprobe von fertig produzierten Teilen entnommen und an einem Qualitätsmessplatz hinsichtlich ausgewählter univariater Qualitätsmerkmale

vermessen (Montgomery 2019). Gewisse statistische Kenngrößen werden berechnet und in eine sogenannte Shewhart Regelkarte eingetragen, die mit Eingriffsgrenzen versehen ist, innerhalb derer der Prozess als kontrolliert gilt. Werden diese Grenzen überschritten, liegt eine Anomalie vor. Das Personal führt dann eine Ursachenanalyse durch, um den Fehler im Fertigungsprozess zu identifizieren und zu beheben (Montgomery 2019).

Diese konventionelle Form der SPC, die USPC, hat einige Nachteile: (1) Es besteht ein Zeitversatz zwischen dem Auftreten einer Anomalie im Prozess und der Detektion am physischen Bauteil. (2) Der Prozess wird retrospektiv anhand von Qualitätsdaten am fertiggestellten Bauteil bewertet, anstatt diesen während der Bearbeitung anhand von realen Prozessdaten zu untersuchen. (3) Die Betrachtung der Qualitätsmerkmale erfolgt häufig univariat, d. h. Zusammenhänge zwischen einzelnen Qualitätsmerkmalen werden vernachlässigt. (4) Die Regelkarte gibt lediglich den Hinweis auf das Vorliegen einer Anomalie, unterstützt aber nicht die Ursachenanalyse.

Die zunehmende Menge an verfügbaren Sensor- bzw. Prozessdaten und die Möglichkeiten der Signalverarbeitung mittels Methoden der künstlichen Intelligenz (KI) führen zu einem wachsenden Interesse der Fertigungsindustrie an der sogenannten KI-basierten multivariaten statistischen In-Prozess Kontrolle (MSPC), die die zuvor genannten Nachteile der USPC adressieren kann (Carroccia et al. 2016; Maggioni et al. 2014). Dabei kommt es jedoch u. a. aufgrund der Parallelität von Fertigung und Kontrolle zu einer Veränderung der Arbeitsorganisation von Maschinenbediener*innen, die zudem in der Lage sein müssen, die KI-verarbeiteten hochfrequenten multivariaten Prozessdaten zu interpretieren. Dafür wurde ein Demonstrator als Prototyp einer Mensch-Maschine-Schnittstelle (MMS) entwickelt, der die Prozessdaten in Echtzeit so aufbereiten und darstellen soll, dass Maschinenbediener*innen bei der Prozessüberwachung, d. h. dem Erkennen des Vorliegens bzw. Auftretens von Anomalien und der Ursachenanalyse der Anomalien, optimal unterstützt werden (Biegel et al. 2023). Dieser Demonstrator zur KI-basierten MSPC wurde in einer Nutzerstudie hinsichtlich der Usability (Gebrauchstauglichkeit) sowie dem subjektiven Beanspruchungsempfinden von Maschinenbediener*innen evaluiert und mit der USPC verglichen. Das Konzept sowie die Ergebnisse der nutzerzentrierten Evaluation des Demonstrators werden in diesem Beitrag präsentiert und diskutiert.

2. Methodik

Der betrachtete Fräsprozess an einer DMC 50H Fräsmaschine in der Prozesslernfabrik CiP (Center für industrielle Produktivität) der Technischen Universität Darmstadt (TUDa) produziert Komponenten für die Herstellung eines Pneumatik-Zylinders. Die über die Sensoren der DMC 50H Fräsmaschine erfassten und mithilfe von KI-verarbeiteten multivariaten Prozessdaten werden auf einem Demonstrator abgebildet. Der Demonstrator besteht aus einer Haupt- und einer Detailseite (siehe Abbildung 1; Biegel et al. 2023): Die Hauptseite zeigt als digitale Regelkarte an, ob ein Prozess außer Kontrolle ist. Durch Anwählen eines Prozesses wird die Detailseite aufgerufen, die die verschiedenen Sensordaten über die Prozesszeit, d. h. als Zeitreihe, aufgeteilt in die einzelnen Bearbeitungsschritte des Fräsprozesses, darstellt. Zeitfenster, in denen eine Anomalie erkannt wird, werden farblich hervorgehoben, wodurch eine zeitliche Lokalisierung der Anomalie im Prozess ermöglicht wird.




Abbildung 1: Links: Hauptseite des Demonstrators mit der digitalen Regelkarte, Rechts: Detailseite des Demonstrators mit der Zeitreihe der Sensordaten (Biegel et al. 2023)

Die Versuchsdauer betrug ca. 3 Stunden je Versuchsperson. Zunächst wurden in einem Online-Fragebogen demografische Daten und die Erfahrung bezogen auf die DMC 50H Fräsmaschine erfasst.

In der Prozesslernfabrik CiP der TUDa durchliefen die Versuchspersonen den Modus der USPC und den Modus der KI-basierten MSPC. In beiden Modi wurden jeweils drei Szenarien durchlaufen, d. h. drei Bauteile – ein normales Bauteil und zwei anomale Bauteile – gefertigt. Die getesteten Anomalien waren: (1) ein in die Fräsmaschine falsch eingespanntes Bauteil und (2) ein in die Fräsmaschine eingespanntes zu kurz abgesägtes Bauteil. Sowohl die Reihenfolge der Modi als auch die Reihenfolge der Szenarien innerhalb der Modi wurden permutiert und in randomisierter Reihenfolge von den Versuchspersonen durchlaufen.

Die Aufgabe der Versuchspersonen startete mit Übergabe der gefertigten Bauteile aus der DMC 50H Fräsmaschine. Im Modus der USPC wurden die drei gefertigten Bauteile nacheinander am Qualitätsmessplatz hinsichtlich ausgewählter Qualitätsmerkmale vermessen und eine Regelkarte mithilfe der Software Q-DAS qs-STAT erstellt. Im Modus der KI-basierten MSPC wurde die Ausgabe der KI-verarbeiteten Daten auf dem Demonstrator für jedes der drei Bauteile nacheinander betrachtet.

Als Maß für die Usability diente zum einen die Güte der Anomaliedetektion. Dazu füllten die Versuchspersonen pro Szenario ein Arbeitsblatt aus, auf dem sie eintrugen, ob eine Anomalie vorlag oder nicht. Wenn eine Anomalie erkannt wurde, wurde zudem die vermutete Ursache der aufgetretenen Anomalie angegeben. Zum anderen füllten die Versuchspersonen nach dem Durchlaufen der drei Szenarien pro Modus die System Usability Scale (SUS; Brooke 1996) aus, mit der sie die Usability des gesamten Modus bewerteten. Das subjektive Beanspruchungsempfinden der Versuchspersonen in beiden Modi wurde über den NASA Task Load Index (NASA-TLX; Hart 2006) erfasst, der ebenfalls nach dem Durchlaufen der drei Szenarien pro Modus ausgefüllt wurde.

Abschließend wurden in einem Interview die getesteten Anomalien erklärt, beide Modi vergleichend bewertet und Verbesserungspotenziale für den Demonstrator zur KI-basierten MSPC herausgearbeitet.

3. Ergebnisse

3.1 Versuchspersonen

Acht männliche Maschinenbediener im Alter zwischen 20 und 26 Jahren (Mittelwert (MW) = 23,5 Jahre; Standardabweichung (SD) = 1,8 Jahre) nahmen als Versuchspersonen an der Evaluation teil. Die Versuchspersonen waren zum Zeitpunkt der Evaluation in der Prozesslernfabrik CiP der TUDa beschäftigt und an der DMC 50H Fräsmaschine und am Qualitätsmessplatz geschult. Jeweils vier Versuchspersonen hatten weniger als ein halbes Jahr und zwischen einem halben und einem Jahr Erfahrung an der DMC 50H Fräsmaschine.

3.2 Usability der USPC und KI-basierten MSPC

Der durchschnittliche SUS-Wert 60,9 (SD = 13,2) der USPC ist niedriger als der durchschnittliche SUS-Wert 76,3 (SD = 18,8) der KI-basierten MSPC.

Die Quote der korrekten Erkennung aufgetretener Anomalien lag sowohl in der USPC als auch in der KI-basierten MSPC bei 100 %, d. h. in allen Fällen wurde korrekt bestimmt, ob eine Anomalie vorlag oder nicht. Die Ursache der Anomalien wurde in der USPC in 62,5 % und in der KI-basierten MSPC in 31,3 % der Fälle korrekt bestimmt. Die Anomalie „Bauteil falsch eingespannt“ wurde in der USPC in 87,5 % der Fälle und in der KI-basierten MSPC in 25,0 % der Fälle richtig erkannt. Die Anomalie „Bauteil zu kurz abgesägt“ wurde in beiden Modi der Qualitätskontrolle in 37,5 % der Fälle korrekt als solche identifiziert.

3.3 Subjektives Beanspruchungsempfinden in der USPC und KI-basierten MSPC

Die Ergebnisse des NASA-TLX zum subjektiven Beanspruchungsempfinden der Maschinenbediener in der USPC und KI-basierten MSPC sind in Tabelle 1 dargestellt.

Bei der Betrachtung des Gesamtwerts, des Raw-TLX, wird ein vergleichbares subjektives Beanspruchungsempfinden in der USPC und KI-basierten MSPC deutlich.

Bei der Detailbetrachtung der einzelnen Beanspruchungsarten zeigt sich, dass die geistigen Anforderungen in der KI-basierten MSPC gegenüber der USPC höher sind. Demgegenüber sind sowohl die körperlichen als auch die zeitlichen Anforderungen in der KI-basierten MSPC gegenüber der USPC geringer.

Tabelle 1: Vergleich des NASA-TLX der USPC und der KI-basierten MSPC (N = 8)

	USPC		KI-basierte MSPC	
	MW	SD	MW	SD
Geistige Anforderungen	26,3	21,5	42,5	29,4
Körperliche Anforderungen	24,4	20,6	5,6	9,4
Zeitliche Anforderungen	26,9	25,5	18,1	18,1
Leistung	66,3	27,5	67,5	21,9
Anstrengung	23,1	16,5	22,5	24,9
Frustration	30,0	32,3	31,3	27,9
Raw-TLX	32,8	11,4	31,3	13,8

Anmerkung: 0 = sehr gering, 100 = sehr hoch

Legende: MW = Mittelwert, SD = Standardabweichung, USPC = univariate statistische Post-Prozess Kontrolle, KI-basierte MSPC = KI-basierte multivariate statistische In-Prozess Kontrolle

3.4 Ergebnisse der Interviews

Aus Gründen der Zeitersparnis und der Möglichkeit zur kontinuierlichen Prozessüberwachung können sich alle Versuchspersonen vorstellen, den Demonstrator zukünftig im Rahmen der Qualitätskontrolle zu nutzen. Die Aufteilung des Demonstrators in die Regelkarte auf der Hauptseite und die Zeitreihe auf der Detailseite wird als sinnvoll empfunden. Nach Aussagen von sechs Versuchspersonen wird das Erkennen des Vorliegens bzw. Auftretens von Anomalien durch den Demonstrator erleichtert und ist nach einer kurzen Einweisung in den Demonstrator möglich. Dennoch würden sechs Versuchspersonen in der Einführungsphase des Demonstrators zunächst den Qualitätsmessplatz beibehalten wollen, um die Zuverlässigkeit KI-basierter Anomaliedetektionen überprüfen zu können und dadurch das Vertrauen in die Ergebnisse zu stärken. In der Ursachenanalyse mithilfe des Demonstrators sieht hingegen nur eine Versuchsperson einen Vorteil und nach Angabe von vier Versuchspersonen ist die empfundene geistige Anforderung in der KI-basierten MSPC vor allem auf die Ursachenanalyse zurückzuführen. Drei Versuchspersonen sehen die Notwendigkeit von mehr Erfahrung und Wissen, um im Rahmen der Ursachenanalyse von den Vorteilen der KI-basierten Qualitätskontrolle zu profitieren. Für eine Unterstützung der Ursachenanalyse wünschen sich vier Versuchspersonen hinterlegte Musterbauteile bzw. Beispiele mit angegebenen Ursachen im Demonstrator. Sechs Versuchspersonen wünschen sich eine automatische Ausgabe der Art der Anomalie im Demonstrator. Darüber hinaus wird die Möglichkeit gesehen, nach dem Erkennen des Vorliegens einer Anomalie mithilfe des Demonstrators der KI-basierten MSPC die konkrete Ursache der Anomalie durch den Kontrollschritt am Qualitätsmessplatz zu bestimmen. Zudem wurde der Bedarf geäußert, dem KI-System durch die Auswahl einer Ursache Feedback geben zu können, um dessen Genauigkeit kontinuierlich zu verbessern.

4. Diskussion

Die erhobenen quantitativen und qualitativen Ergebnisse zeigen, dass Maschinenbediener*innen einer Integration des Demonstrators zur KI-basierten MSPC positiv gegenüberstehen. Die Usability der KI-basierten MSPC unter Einbindung des Demonstrators wird besser als die Usability der USPC bewertet. Obwohl das totale Niveau des subjektiven Beanspruchungsempfindens (Raw-TLX) in der KI-basierten MSPC mit dem der USPC vergleichbar ist, weist die Detailbetrachtung der einzelnen Beanspruchungsarten auf eine Kompensation der in der KI-basierten MSPC gegenüber der USPC reduzierten zeitlichen und körperlichen Anforderungen durch erhöhte geistige Anforderungen hin. Die reduzierten zeitlichen und körperlichen Anforderungen sind auf die Echtzeitdarstellung der Sensordaten während des Fräsprozesses auf dem Demonstrator und den Wegfall des Bauteiltransfers zum Qualitätsmessplatz sowie der Bauteilvermessung im Nachgang der Fertigung zurückzuführen. Die erhöhten geistigen Anforderungen werden in den Interviews mit Schwierigkeiten in der Ursachenanalyse erklärt. Die Quote der korrekten Erkennung aufgetretener Anomalien von 100 % und vergleichsweise geringe Quote der korrekten Ursachenidentifikation von 31,3 % in der KI-basierten MSPC machen deutlich, dass der Demonstrator im aktuellen Entwicklungsstand Maschinenbediener*innen zwar im Erkennen des Vorliegens einer Anomalie, aber nur unzureichend in ihrer Ursachenanalyse unterstützt. Den Aussagen der Versuchspersonen zufolge ist das Erkennen des Vorhandenseins einer Anomalie

mithilfe des Demonstrators auch ohne Erfahrung möglich, die Ursachenidentifikation ist hingegen von dem Wissen der Maschinenbediener*innen zu den Fräsoptionen der Fräsmaschine, den Sensordaten und der Zuordnung von Prozessschritt zu bearbeitetem Teil des Werkstücks abhängig. So wurde die Anomalie „Bauteil falsch eingespannt“ in der USPC in fast 90 % der Fälle richtig erkannt, in der KI-basierten MSPC jedoch nur in einem Viertel der Fälle. Während der Fehler bei der Bauteilvermessung im Rahmen der USPC erkannt wird, sind die im Demonstrator zur KI-basierten MSPC als anomal gekennzeichneten Sensordatenverläufe in dem gehighlighteten Prozessschritt nicht zu interpretieren. Die Anomalie „Bauteil zu kurz abgesägt“ wurde in beiden Modi der Qualitätskontrolle in nur 37,5 % der Fälle korrekt identifiziert, was möglicherweise darauf zurückzuführen ist, dass Fehler aus Prozessschritten vor dem Fräsen bei der Ursachenanalyse durch die Versuchspersonen vernachlässigt wurden.

Die Evaluation des Demonstrators zur KI-basierten MSPC wurde mit einem kleinen und homogenen, aber erfahrenen Stichprobenkollektiv durchgeführt. Es ist zu empfehlen, die Evaluation mit einer größeren Stichprobe und Maschinenbediener*innen mit stärker unterschiedlichen Erfahrungen und Kompetenzen mit Fräsmaschinen und KI durchzuführen. Darüber hinaus übten die Versuchspersonen in der Evaluation nur einen Teil ihrer eigentlichen Arbeitstätigkeit als Maschinenbediener*innen – die Qualitätskontrolle – aus und nicht üblicherweise parallel ausgeführte Arbeitstätigkeiten (wie z. B. das Entfernen von anfallender Metallspäne in der Fräsmaschine). In zukünftigen Evaluationen sollten noch realere Bedingungen geschaffen und die gesamte Arbeitstätigkeit der Maschinenbediener*innen an der Fräsmaschine betrachtet werden.

5. Literatur

- Biegel T, Helm P, Jourdan N, Metternich J (2023) SSMSPC: Self-Supervised Multivariate Statistical In-Process Control in Discrete Manufacturing Processes. *Journal of Intelligent Manufacturing*.
- Brooke J (1996) SUS – A Quick and Dirty Usability Scale. In: Jordan PW, Thomas B, Weerdmeester BA, McClelland IL (Hrsg.) *Usability Evaluation in Industry*. London: Taylor & Francis, 189–194.
- Carroccia A, Grasso M, Maggioni M, Colosimo B (2016) Improved Signal Characterization via Empirical Mode Decomposition to Enhance In-Line Quality Monitoring. *Procedia CIRP* 41: 717–722.
- Ferrer A (2007) Multivariate Statistical Process Control Based on Principal Component Analysis (MSPC-PCA): Some Reflections and a Case Study in an Autobody Assembly Process. *Quality Engineering* 19(4): 311–325.
- Hart S (2006) NASA-Task Load Index (NASA-TLX); 20 Years Later. *Proceedings of the Human Factors and Ergonomics Society Annual Meeting* 50(9): 904–908.
- International Organization for Standardization (2013) ISO 7870-2:2013: Control Chart – Part 2: Shewhart Control Charts. Berlin: Beuth Verlag GmbH.
- International Organization for Standardization (2019) ISO 7870-1:2019: Control Charts – Part 1: General Guidelines. Berlin: Beuth Verlag GmbH.
- Kourti T, MacGregor J (1996) Multivariate SPC Methods for Process and Product Monitoring. *Journal of Quality Technology* 28(4): 409–428.
- Maggioni M, Marzorati E, Grasso M, Colosimo B, Parenti P (2014) In-Process Quality Characterization of Grinding Processes: A Sensorfusion Based Approach. *Engineering Systems Design and Analysis*.
- Montgomery D (2019) *Introduction to Statistical Quality Control*. New Jersey: John Wiley & Sons.

Danksagung: Die Autor*innen sind allein für den Inhalt dieser Veröffentlichung verantwortlich und danken Niklas Bode, Frederic Fries, Dennis Jeckel, Hyobin Lee, Christian Litzinger, Alicja Niekrawietz und Tom Schadt für ihre Unterstützung bei der Durchführung der Evaluation. Die vorliegende Arbeit ist ein Ergebnis des Verbundprojektes KompAKI (Förderkennzeichen 02L19C150), das vom Bundesministerium für Bildung und Forschung (BMBF) aufgrund eines Beschlusses des Deutschen Bundestages gefördert wird.



Gesellschaft für Arbeitswissenschaft e.V.

Arbeitswissenschaft in-the-loop

**Mensch-Technologie-Integration
und ihre Auswirkung auf Mensch,
Arbeit und Arbeitsgestaltung**

70. Kongress der
Gesellschaft für Arbeitswissenschaft e.V.

Institut für Arbeitswissenschaft und
Technologiemanagement IAT
Universität Stuttgart

In Zusammenarbeit mit dem Fraunhofer-Institut für
Arbeitswirtschaft und Organisation IAO

06. – 08. März 2024

GfA-Press

Bericht zum 70. Arbeitswissenschaftlichen Kongress vom 06. – 08. März 2024

Institut für Arbeitswissenschaft und Technologiemanagement (IAT), Universität Stuttgart

In Zusammenarbeit mit: Fraunhofer-Institut für Arbeitswirtschaft und Organisation (IAO), Stuttgart

Herausgegeben von der Gesellschaft für Arbeitswissenschaft e.V.

Sankt Augustin: GfA-Press, 2024

ISBN 978-3-936804-34-8

NE: Gesellschaft für Arbeitswissenschaft: Jahresdokumentation

Als Manuskript zusammengestellt. Diese Jahresdokumentation ist nur in der Geschäftsstelle (s. u.) erhältlich.

Alle Rechte vorbehalten.

© **GfA-Press, Sankt Augustin, Schriftleitung: Prof. Dr. Rolf Ellegast**

im Auftrag der Gesellschaft für Arbeitswissenschaft e.V.

Ohne ausdrückliche Genehmigung der Gesellschaft für Arbeitswissenschaft e.V. ist es nicht gestattet:

- den Kongressband oder Teile daraus in irgendeiner Form (durch Fotokopie, Mikrofilm oder ein anderes Verfahren) zu vervielfältigen,
- den Kongressband oder Teile daraus in Print- und/oder Nonprint-Medien (Webseiten, Blog, Social Media) zu verbreiten.

Die Verantwortung für die Inhalte der Beiträge tragen alleine die jeweiligen Verfasser; die GfA haftet nicht für die weitere Verwendung der darin enthaltenen Angaben.

Geschäftsstelle der GfA

Simone John, Tel.: +49 (0)30 1300-13003, Alte Heerstraße 111, D-53757 Sankt Augustin

info@gesellschaft-fuer-arbeitswissenschaft.de · www.gesellschaft-fuer-arbeitswissenschaft.de

Screen design und Umsetzung

© 2024 fröse multimedia, Frank Fröse,

office@internetkundenservice.de, www.internetkundenservice.de