

Der Nutzen einer Fahr- und Arbeitszustandserkennung am Beispiel eines Radladers

M.Sc. **Lars Brinkschulte**, M.Sc. **Kevin Daiß**,
Prof. Dr.-Ing. **Marcus Geimer**,
Karlsruher Institut für Technologie (KIT), Mobima, Karlsruhe

Kurzfassung

Im Rahmen des Beitrages wird eine Methode zur Erkennung von wiederkehrenden Arbeitsspielen einer mobilen Arbeitsmaschine und deren Nutzen vorgestellt. Dies geschieht am Beispiel eines Radladers bei der Durchführung von Verladeprozessen nach dem Y-Zyklus. Ziel der Methode ist die von Fahrer und Umwelt unabhängige Erkennung von vollständigen Arbeitsspielen während eines Arbeitseinsatzes und die Zuordnung von Maschinen- und Betriebszuständen in jedem dieser Arbeitsspiele. Die hierdurch zur Verfügung stehenden Informationen können sowohl in die Betriebsstrategie der Maschine einfließen, als auch dazu genutzt werden, um nach erfolgtem Arbeitseinsatz Arbeitsspiele einzelner Fahrer automatisiert zu analysieren. Dies ermöglicht eine Extraktion von fahrerindividuellen Prozesseigenschaften. Messdaten aus knapp 150 Einzelarbeitsspielen von 7 verschiedenen Fahrern dienen der Parametrierung und Validierung der für die Methode notwendigen Modelle.

Abstract

In this article, a method for recognition of recurring work cycles of a mobile machine is presented. This is done using the example of a wheel loader when carrying out loading cycles based on the Y-cycle. The aim of the method is the recognition of complete work cycles during a measurement run and the assignment of machine and operating states in each of these work cycles, independent of driver and environment. The information thus available can be incorporated into the operating strategy of the machine and can also be used to automatically analyze work cycles of individual drivers after they have completed their work. This enables the extraction of driver-specific process characteristics.

Measurement data concerning almost 150 individual workcycles of 7 different drivers are used to parameterize and validate the models required for status detection.

1. Einleitung und Stand der Technik

Durch sich wiederholende Arbeitsaufgaben kommt es bei mobilen Arbeitsmaschinen zu immer wiederkehrenden Prozessen und Bewegungsabläufen. Beispiele für typische Verladeprozesse sind der Y-Zyklus [1] beim Radlader oder Traktor sowie der Ladeprozess beim Forwarder [2]. Das Verständnis über die Eigenschaften der dabei ausgeführten Bewegungen kann einer Reihe von multidisziplinären Anwendungen dienen. Das Maschinendesign, das Fahrzeugmanagement und die Informationstechnologie sind hier nur einige Beispiele. Dabei ist das messtechnische Protokollieren dieser Prozesse eine gängige Methode zur Quantifizierung und Qualifizierung der durchgeführten Bewegungen. Messungen mittels Stoppuhr, Videoaufnahmen oder über den Timer des Maschinencomputers sind heute noch weit verbreitete Lösungen [2–5]. Auf Basis von Expertenwissen können durch die Aufnahme von Zustandsgrößen (z.B. Kräfte und Geschwindigkeiten, Drücken und Volumenströme) und Steuergrößen (Gaspedal- und Joystickstellung) markante Ereignisse in einem Prozess getriggert und diese durch logische Verknüpfungen und Aneinanderreihungen zu Zyklen zusammengefasst werden. Die dabei notwendigen einzupflegenden Regeln setzen einen hohen Aufwand in der Vorverarbeitung von Messdaten voraus [6]. Neben diesen wissensbasierten Expertensystemen können auf Basis statistischer Ansätze, wie z.B. durch Hidden-Markov-Modelle [7–11] oder Template-Matching-Verfahren [10], Zustände in einer mobilen Arbeitsmaschine erkannt werden. Die Güte derartiger Verfahren reicht soweit, dass eine Vorhersage zukünftiger Bewegungsabläufe möglich ist. Schwachstellen der Verfahren sind die für die Zustandsbestimmung notwendigen hohen Rechenressourcen.

Im ersten Teil des Beitrages wird ein auf Bagged-Trees basierendes selbstlernendes Verfahren zur Fahr- und Arbeitszustandserkennung vorgestellt, mit welchem es möglich ist, auf Prototyping Systemen in Echtzeit fahrerunabhängige Bewegungsabläufe eines Radladers einzelnen Fahr- und Arbeitszuständen zuzuordnen. Im zweiten Teil werden mögliche Nutzen einer derartigen Zustandserkennung für unterschiedlichste Anwendungsfälle vorgestellt und diskutiert.

2. Y-Zyklus – ein typisches Ladespiel eines Radlers

Eine der typischen Aufgaben eines Radladers ist das Transportieren von Schüttgut zwischen zwei Haufwerken. Bei dieser Tätigkeit stellt sich eine immer wiederkehrende Abfolge von Bewegungsschritten ein. Bild 1 zeigt einen solchen Ladevorgang. Hierbei ist die dem Y-Zyklus [1] namensgebende Y-förmige Gestalt der Fahrbewegung zu erkennen.

Grundlage einer Zustandserkennung ist die Einteilung des betrachteten Y-Zyklus in unterschiedliche Zustände. Um Aussagen zum Zustand der Arbeitshydraulik treffen zu können, wird

hier eine Einteilung auf Basis der Schaufelbewegung gewählt. Je nach gewünschter Anwendung sind auch andere Einteilungen denkbar, z. B. anhand des Ortes, an dem sich das Fahrzeug gerade befindet.



Bild 1: Y-Zyklus für Verladetätigkeiten bei Radladern

Anhand der Schaufelbewegung wird der Arbeitszyklus zunächst in die Zustände „Fahren“ und „Laden“ aufgeteilt. Der Zustand „Laden“ zeichnet sich hierbei dadurch aus, dass die Schaufel sich bewegt. Der Zustand „Fahren“ liegt hingegen dann vor, wenn die Schaufel still steht. Der Zustand „Laden“ lässt sich weiter in „Beladen (BL)“ und „Abladen (AL)“ unterteilen. Entsprechend lässt sich der Zustand „Fahren“ in „Transportfahrt (TF)“, also die Fahrt vom Beladen zum Abladen und „Leerfahrt (LF)“, also die Fahrt vom Abladen zum Beladen unterteilen.

Durch die Definition der Zustände ausschließlich über die Schaufelbewegung kann der Fahrzustand zwischen zwei Ladezuständen entfallen, wenn der Fahrer den gesamten Zeitraum zwischen den Ladeplätzen zur Schaufelbewegung nutzt.

3. Zustandserkennung

Als Eingänge für die Zustandserkennung werden Signale verwendet, welche die momentane Schaufelposition, die zurückliegende Schaufelbewegung und den Fahrzustand des Fahrzeugs beschreiben, vgl. Bild 2.

Um Informationen über den Ladezustand des Fahrzeugs zu erhalten, wird zusätzlich noch der Druck im Kolben des Hubzylinders verwendet.

Beim Ausgangssignal der Zustandserkennung handelt es sich um den erkannten Zustand. Zusätzlich zu den vier beschriebenen Zuständen, die dem Y-Zyklus angehören, gibt es hier noch den Zustand „Sonstige Tätigkeiten (ST)“. Dieser liegt vor, wenn das Fahrzeug Tätigkeiten verrichtet, die nicht zum Y-Zyklus gehören.

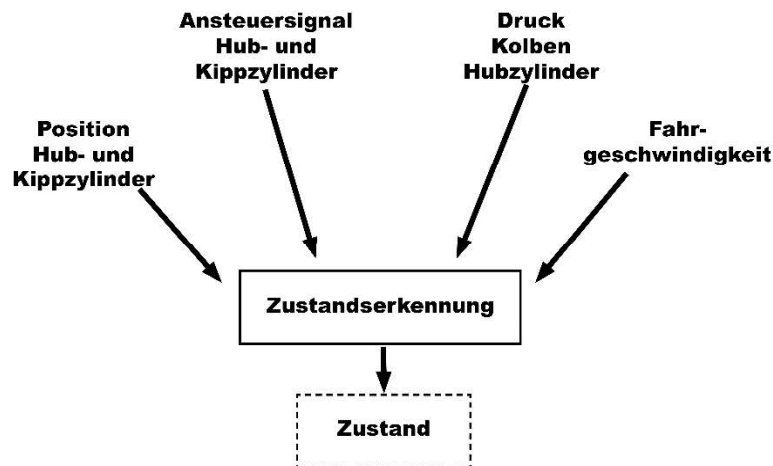


Bild 2: Signale für die Zustandserkennung

Zur Zustandserkennung wird Machine-Learning (ML) eingesetzt. Trainingsdaten werden generiert, indem Versuchsfahrten aufgezeichnet und im Nachhinein gelabelt werden.

Als ML-Algorithmus kommt Bagged-Trees [12] zum Einsatz. Hierbei handelt es sich um ein Verfahren, bei dem mehrere Entscheidungsbäume kombiniert werden. Die Kombination mehrerer Entscheidungsbäume hat den Vorteil, dass diese parallelisiert verarbeitet werden können, was sowohl das Training des Modells, als auch die Auswertung beschleunigt. Dieses Verfahren kommt im Vergleich zu der Mehrheit anderer ML-Ansätze mit einer moderaten Menge an Trainingsdaten aus. Dem ML-Algorithmus nachgelagert ist ein Filter, der die kausale Abfolge der Zustände berücksichtigt. So kann das Fahrzeug beispielsweise erst abgeladen werden, wenn es vorher beladen wurde.

Zunächst liegen nur die Eingangssignale zum aktuellen Zeitpunkt vor. Dies genügt nicht um den Zustand eindeutig zu erkennen. Hierfür muss die Zeithistorie der Signale berücksichtigt werden. Für jeden dieser Zeitabschnitte wird daraufhin der Mittelwert der Eingangssignale ermittelt. Diese Mittelwerte dienen ebenfalls als Eingangssignale für den Bagged-Trees-Algorithmus. Für den betrachteten Einsatzfall hat sich die Berücksichtigung von 15 zurückliegenden, über 0,2 s Zeitdauer gemittelten, Zeitschritten bewährt.

Das Verfahren wurde anhand von Versuchsfahrten getestet. Hierfür wurde eine für Radlader typische Verladeaufgabe nachgestellt. Bewegt wurde Erde zwischen zwei Haufwerken. Der

Abstand der Haufwerke betrug hierbei näherungsweise 25 m. Als Fahrzeug wurde ein mit entsprechender Sensorik ausgestatteter Radlader L 509 Speeder der Firma Liebherr verwendet. Die Fahrten wurden von 7 unterschiedlichen Fahrern durchgeführt, wobei im Folgenden lediglich 4 dieser Fahrer nähere Betrachtung finden. Hierbei wurden bewusst Personen ausgewählt, die im Umgang mit Radladern unterschiedlich geübt sind. Die von den Autoren gewählte Unterscheidung der Fahrerqualifikation ist dabei wie folgt gewählt:

- Level 1: Anfänger – fährt selten bis gar nicht Radlader (Fahrer 1 & Fahrer 3)
- Level 2: Fortgeschrittener – fährt regelmäßig Radlader (Fahrer 2 & Fahrer 4)
- Level 3: Profi – hauptberuflicher Radladerfahrer

Bild 3 zeigt Ein- und Ausgangssignale der Zustandserkennung exemplarisch für eine Versuchsfahrt. Zusätzlich sind die Zustände aus dem Labeling-Prozess dargestellt. Bei der Messung handelt es sich um eine Messfahrt, die nicht im Trainingsdatensatz enthalten ist.

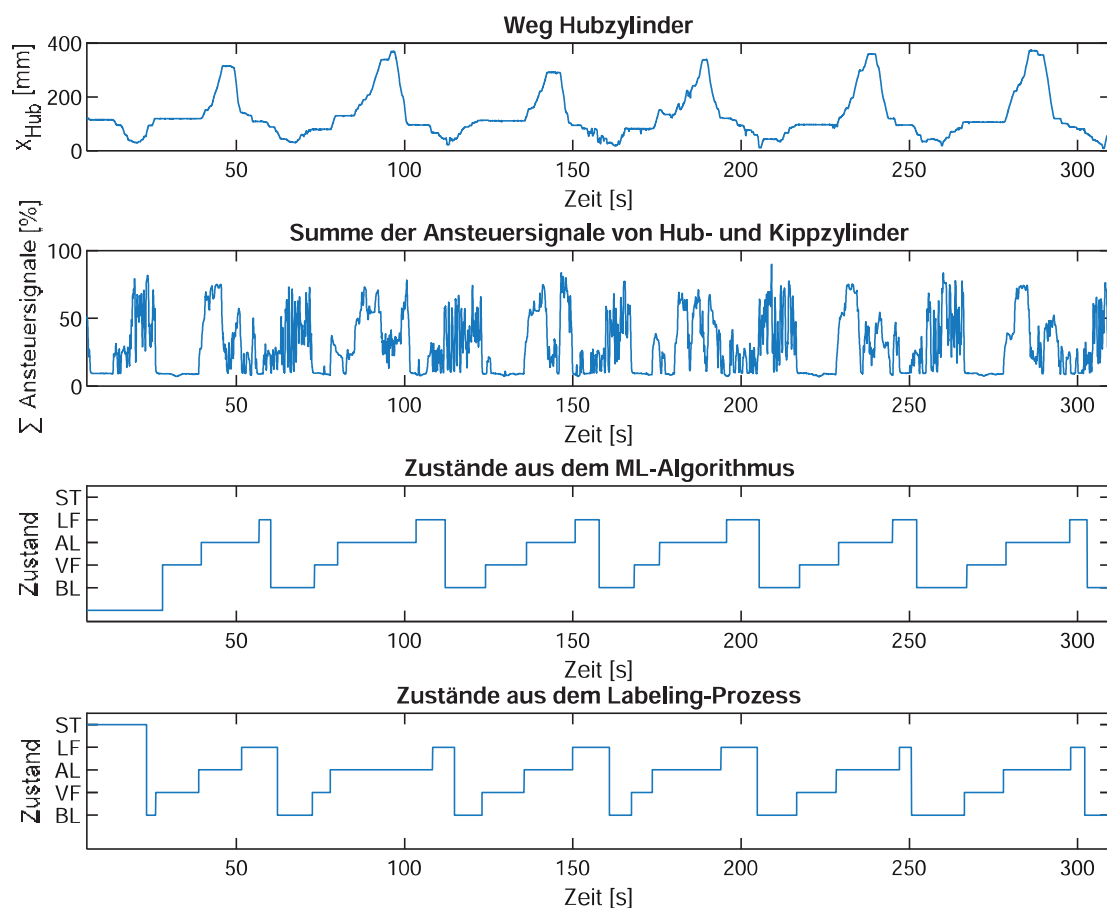


Bild 3: Zustandserkennung am Beispiel einer Messfahrt von Fahrer 4

Die einzelnen Zustände bei der Durchführung des Ladezyklus werden mehrheitlich richtig erkannt. Eine Erkennung des Zustandes BL zeigt sich dabei als am zuverlässigsten. Der Übergang von Zustand AL nach Zustand LF zeigt hingegen das größte Fehlerpotential auf.

Bild 4 zeigt die Auswertung der Güte der Zustands- und nachgelagerten Zyklenerkennung für verschiedene Fahrer. Hierbei zeigt sich, dass die höher qualifizierten Fahrer (Fahrer 2 und Fahrer 4) eine bedeutend höhere Güte in der Erkennung der einzelnen Zustände aufweisen. Für Fahrer bei denen Messdaten zum Trainieren des Algorithmus zur Verfügung (Fahrer 3 und Fahrer 4) stehen, ist die die Erkennungsgüte des Algorithmus über 10 % höher, als für Fahrten von Fahrern, welche keine Daten für den Trainingsdatensatz stellen.




Bild 4: Ergebnis der Zustandserkennung für verschiedene Bediener

4. Nutzen der Zustandserkennung

Der Nutzen der entwickelten Zustandserkennung ist vielseitig und lässt sich dabei in die folgenden Fachbereiche unterteilen:

- Ableitung und Entwicklung von Fahr- und Arbeitszyklen für den Entwicklungsprozess
- Eingriff in die Betriebsstrategie der Maschine
- Bereitstellung von fahrer- und prozessspezifischen Kennzahlen
-

Ableitung und Entwicklung von Zyklen für den Entwicklungsprozess

Kernpunkte bei der Entwicklung mobiler Arbeitsmaschinen sind die Kosten, die Leistungsfähigkeit und die Zuverlässigkeit der Maschine. Für die Auslegung einer Konstruktion ist dabei

die Definition typischer Lastfolgen unter Berücksichtigung von Einflussfaktoren wie der Arbeitsaufgabe, der Umwelt und des Fahrers von grundlegender Bedeutung. Mittels der automatisierten Zustandserkennung und Klassifizierung von Lastzyklen können so aus einem großen Stichprobenumfang reale Lastzyklen abgeleitet und zielführend eingesetzt werden. Bild 5 zeigt die jeweiligen Zustandszeitanteile bei der Durchführung der gleichen Arbeitsaufgabe von vier verschiedenen Fahrern unterschiedlicher Fahrerqualifikation.

Die einzelnen Zeitanteile, sowie der Einfluss der Fahrerqualifikation können so Einsatz- und Baureihenindividuell in die Auslegung einer mobilen Arbeitsmaschine mitgebracht werden.

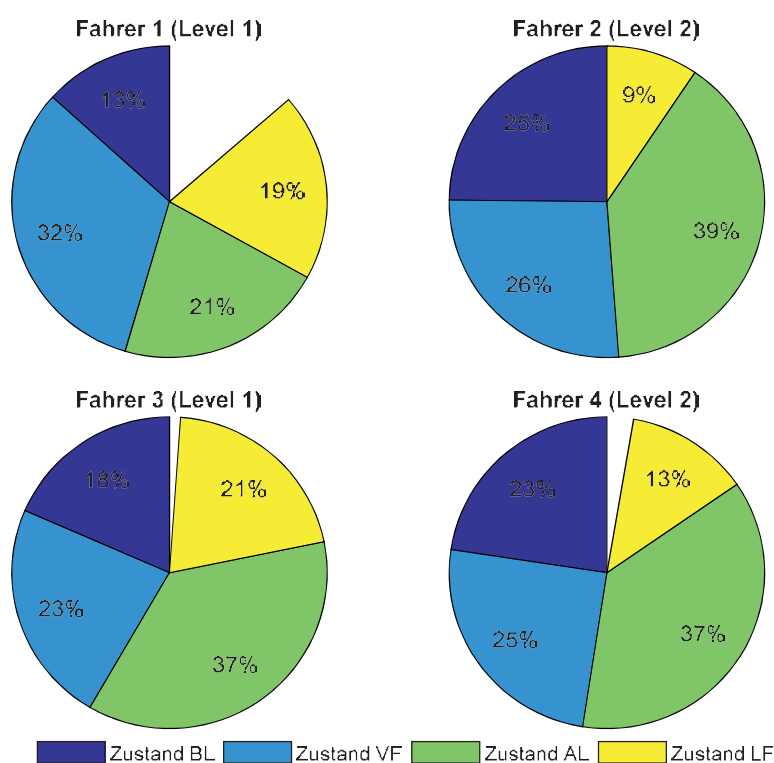


Bild 5: Zustandszeitanteile unterschiedlicher Fahrer bei der Durchführung des Y-Zyklus

Eingriff in die Betriebsstrategie einer mobilen Arbeitsmaschine

In einem erkannten Zustand können insbesondere dem unerfahrenen Fahrer, je nach Kostenfunktion, Hinweise zur Bedienung gegeben werden. Diese Empfehlungen können von der Empfehlung des Betätigens des InChpedals in Zustand BL und Zustand AL, über Hinweise zur Optimierung der Joystickbewegung beim Grabprozess bis hin zu Sicherheitshinweisen bezüglich der Standsicherheit führen.

In einzelnen Zuständen können gezielt Neben- bzw. Arbeitsaggregate abgekoppelt werden, sodass der notwendige Energiebedarf in diesen Aggregaten reduziert oder gar eliminiert wer-

den kann. So kann beispielsweise der Arbeitsantrieb in Zustand VF und LF ausgekoppelt werden, was insbesondere bei langen Arbeitsspielen zu einer bedeutenden Energieersparnis führen kann.

In besonders bauteilbelastenden Betriebszuständen können gezielt Steuerungsparameter angepasst und so Lastspitzen und damit die Bauteilschädigung reduziert werden.

Bereitstellung von fahrer- und prozessspezifischen Kennzahlen

Für den Betreiber lassen sich anhand der Zustands- und Zyklenerkennung charakteristische personenspezifische Kennzahlen für jeden Fahrer ableiten. Tabelle 1 zeigt eine mögliche Auswertung der Arbeitsspiele nach durchschnittlicher Zykluszeit und durchschnittlich eingebrachter Energie pro Zyklus. Zur besseren Darstellung wurden Zykluszeit und Energieanteile auf die hier jeweils maximal vorliegenden Werte normiert.

Tabelle 1: Fahrerspezifische Kennzahlen am Beispiel Zykluszeit und Energie pro Zyklus

	Level 1		Level 2	
	Fahrer 1	Fahrer 3	Fahrer 2	Fahrer 4
Relative durchschnittliche Zykluszeit in %	100	80	47	51
Relative durchschnittlich eingebrachte Energie pro Zyklus in %	28	41	57	100

Anhand dieser Kennzahlen ist es möglich die Qualifikation eines jeweiligen Fahrers zu bestimmen. Bei der Durchführung der identischen Arbeitsaufgabe ist die Zykluszeit antiproportional zur Qualifikation des Fahrers, die durchschnittlich eingebrachte Energie hingegen proportional. Die Divergenz in der eingebrachten Energie bei den beiden Fahrern der Level 2 Qualifikation lässt sich durch das aggressivere Fahrverhalten von Fahrer 4 erklären. Durch die Ergänzung der Masse des transportierten Guts pro Zyklus lässt sich die Effektivität eines einzelnen Bedieners bestimmen und somit die individuelle Arbeitsleistung für zukünftige Arbeitsprozesse prognostizieren.

Weitere Anwendung ist z.B. eine mögliche zu prognostizierende akkumulierte Schädigung von Komponenten der Maschine in Abhängigkeit des Bedieners und die damit verbundene mögliche Bestimmung der Restlebensdauer einzelner Komponenten zur optimalen Planung von Wartungsintervallen.

5. Zusammenfassung und Ausblick

Der Beitrag zeigt die Ergebnisse einer selbstlernenden Zustands- und Zyklenerkennung am Beispiel von Verladeprozessen mittels eines Radladers. Durch die hohe Erkennungsgüte der einzelnen Zustände (bis zu 87 %) ergeben sich vielseitige Einsatzmöglichkeiten. Diese reichen von der Erstellung von einsatztypischen Lastkollektiven für den Entwicklungsprozess, über Betriebsstrategieoptimierungen bis hin zur Möglichkeit der besseren Planung von Wartungsintervallen.

Das entwickelte Verfahren soll sich in Zukunft durch seine Vielseitigkeit bei der Erkennung von Zuständen in unterschiedlichen Arbeitsprozessen auszeichnen. Hierfür ist durch die Implementierung weiterer Tätigkeiten, wie z.B. das Transportieren und Verdichten, das Durchführen weiterer Messfahrten notwendig. Die Einbindung von Langzeitaufnahmen realer Baustellen- und Hofeinsätze würde die Einsatzmöglichkeit für den realen Betrieb validieren. Eine Übertragung der Methode auf andere mobile Arbeitsmaschinen, z.B. Forstmaschinen, könnte der Prüfung der Robustheit des Ansatzes dienen.

6. Literaturverzeichnis

- [1] Filla, R.: Quantifying Operability of Working Machines. Linköping 2011.
- [2] Tiernan, D.; Zeleke, G.; Owende, P.M.O.; Kanali, C.L.; Lyons, J. und Ward, S.M.: Effect of Working Conditions on Forwarder Productivity in Cut-to-length Timber Harvesting on Sensitive Forest Sites in Ireland, *Biosystems Engineering* 87 (2004) H. 2. S. 167–177.
- [3] Manner, J.; Nordfjell, T. und Lindroos, O.: Effects of the number of assortments and log concentration on time consumption for forwarding, *Silva Fennica* 47 (2013) H. 4.
- [4] Nurminen, T.; Korpunen, H. und Uusitalo, J.: Time consumption analysis of the mechanized cut-to-length harvesting system, *Silva Fennica* 2006 (2006) H. 40. S. 335–363.
- [5] Ovaskainen, H.; Uusitalo, J. und Väättäin, K.: Characteristics and Significance of a Harvester Operators' Working Technique in Thinnings, 2004 (2004).
- [6] Nilsson, T.; Nyberg, P.; Sundström, C.; Frisk, E. und Krysander, M.: Robust driving pattern detection and identification with a wheel loader application, *International Journal of Vehicle Systems Modelling and Testing* 9 (2014) H. 1. S. 56.
- [7] Tervo, K.; Palmroth, L. und Koivo, H.: Skill Evaluation of Human Operators in Partly Automated Mobile Working Machines, *IEEE Transactions on Automation Science and Engineering* 7 (2010) H. 1. S. 133–142.
- [8] Tervo, K.; Palmroth, L. und Putkonen, A.: A hierarchical fuzzy inference method for skill evaluation of machine operators. 2009 IEEE/ASME International Conference on Advanced Intelligent Mechatronics (AIM) 7/14/2009 - 7/17/2009 Singapore. In: *IEEE/ASME International Conference on Advanced Intelligent Mechatronics, 2009* (2009). S. 136–141. Piscataway, NJ: IEEE 2009.
- [9] Schramm, F.: Erkennung und Prädiktion von Betriebszuständen mobiler Maschinen am Beispiel eines Traktors: Recognition and prediction of operating states of mobile machines exemplified by a tractor. In: *Land-Technik 2016* (2016). S. 145–151. Düsseldorf: VDI Verlag GmbH 2016.
- [10] Technische Universität Dresden, Professur für Baumaschinen: Methode zur online Prozessmustererkennung für die Ermittlung von Kundenkollektiven an mobilen Baumaschinen (processAssist) 31.12.2016.
- [11] Tervo, K.: Human adaptive mechatronics methods for mobile working machines (2010).
- [12] Géron, A.: *Praxiseinstieg Machine Learning mit Scikit-Learn und TensorFlow: Konzepte, Tools und Techniken für intelligente Systeme*. 1. Auflage. Heidelberg: O'Reilly 2018.