

Entwicklung und Evaluation eines Wiegesystems für Forstkräne auf Basis von künstlichen neuronalen Netzen

Chris Geiger, Daniel Greff, Michael Starke, Marcus Geimer

Sowohl in der Hackschnitzel- als auch Rundholzlogistik fehlen oft wichtige Referenzmengen für den dispositiven Einsatz, welche zumeist mit unzureichend genauen Schätzwerten vervollständigt werden. Um die Informationsqualität über die bewegten Holzmengen zu verbessern, können optional Kranwaagen zwischen Teleskopauge und Greifer am Kran des Forwarders montiert werden. Dies beeinflusst jedoch die Krankinematik und Manövrierfähigkeit negativ, bei zeitgleich sinkender Maschinenproduktivität aufgrund einer zur Messung notwendigen Unterbrechung des Ladeprozesses.

In diesem Beitrag wird eine datenbasierte Methode präsentiert, welche einen dynamischen Wiegeprozess im kontinuierlichen Ladevorgang bei modernen Forstkränen ermöglicht, ohne dass eine zusätzliche Hardware-Komponente auf der Maschine verbaut werden muss. Bei dieser Methode wird ein Ladezyklus automatisiert erkannt und die geladene Masse anhand eines künstlichen neuronalen Netzwerkes (KNN) abgeschätzt. Als Eingangsgrößen dienen Signale von Sensoren, die auf modernen Forwardern serienmäßig installiert sind. Für die Verarbeitung von zeitbasierten Sensordaten in einem neuronalen Netz hat sich die Long-Short-Term-Memory(LSTM)-Architektur bewährt. Basierend auf LSTM-Zellen wurde ein entsprechendes Netzwerk entworfen, trainiert und anschließend optimiert. Im Test zeigt sich für einen einzelnen Ladezyklus ein mittlerer Gesamtskalenfehler von 1,5 %, bezogen auf 1.000 kg. Für einen voll beladenen Forwarder resultiert dies in einem Gesamtmassenfehler kleiner 1,2 %.

Schlüsselwörter

Künstliche neuronale Netze, Kranwaage, Forstmaschinen, Forwarder

Bei der Rohholzbereitstellung werden je nach Ausgangslage und Sortimentsaushaltung unterschiedliche Holzernteverfahren angewendet. Vor allem bei geringeren Durchmesserklassen und für die Bereitstellung von Kurz- und Industrieholz-Sortimenten wird die Holzernte vollmechanisiert ausgeführt (BERG et al. 2012). Dabei arbeitet ein Harvester die Bäume auf und legt diese an der Rückegasse ab. Anschließend werden die ausgehaltenen Sortimente mit dem Forwarder von der Einschlagsfläche zur Forststraße gerückt und dort gepoltert (HEINIMANN 1994, CACOT et al. 2006, NURMINEN et al. 2006, ERLER et al. 2010, KUPTZ et al. 2015, MANNER et al. 2016).

Diese Maschinenkombination ermöglicht es, über das Harvestermaß (Durchmesser- und Längendaten der aufgearbeiteten Stämme) umfassende Sortimentsinformationen zum aktuellen Hieb zu erhalten. Anhand der automatischen Aufzeichnung der Sortimentsinformationen und der zusätzlichen Erfassung des räumlichen Bezugs ist eine nachfolgende Zuordnung zum Forwarder möglich (MANNER

et al. 2016). Dadurch steht die Information der gerückten Holzmenge zur Produktivitätserfassung des Arbeitsschritts oder auch für dispositive Zwecke zur Verfügung.

Sortimente, die nicht durch den Harvester aufgearbeitet und erfasst wurden, müssen zusätzlich vermessen werden. Besonders deutlich ist der Anteil der nicht erfassten Mengen bei Hackgutsortimenten für die Bereitstellung von Waldhackschnitzeln. Diese Sortimente umfassen neben verarbeiteten Produkten wie Energierundholz vor allem Kronenteile oder auch ganze Bäume mit hohen Anteilen unterhalb der Derbh Holzgrenze, d. h. Rundholz mit einem Mindestdurchmesser von 7 cm mit Rinde (DEUTSCHER FORSTWIRTSCHAFTSRAT E. V. UND DEUTSCHER HOLZWIRTSCHAFTSRAT E. V. 2015). Methoden zur Erfassung dieser Sortimente, die mit dem Harvester unzureichend oder gar nicht dokumentiert werden können, basieren gegenwärtig zumeist auf Schätzverfahren. Aufgrund der meist unzureichenden Genauigkeit führt dies jedoch in der Praxis zu Problemen in der Hackschnitzellogistik (KUPTZ et al. 2015).

Eine Lösungsmöglichkeit bietet hier der Einsatz von Kranwaagen für die Massenermittlung als dispositives Maß, wie sie auch bei der Rundholzbereitstellung bereits in Betracht gezogen wurden (BODELSCHWINGH 2006). Damit können Hackgutsortimente im Gewicht erfasst werden und es kann mit hoher Genauigkeit auf das Volumen geschlossen werden. Die Information über die Größe der gebildeten Hackgutpolter professionalisiert die Hackschnitzellogistik, wodurch die höhere Leistung moderner Hacker auch bei ungünstigen Lager- und Platzverhältnissen optimal erreicht werden kann (KUPTZ et al. 2015). Wenn beim Forstkran des Hackers eine Waage verwendet wird, kann bei ausreichender Genauigkeit ein Überladen der LKW vermieden werden und infolgedessen auch Maschinen- und Straßenschäden sowie Rechtsfolgen für Fahrer und Halter.

Stand der Technik

Gegenwärtig stehen für den genannten Einsatzbereich in der Holzlogistik unter anderem kommerziell erhältliche Kranwaagen zur Verfügung, die zwischen Teleskopauge und Greifer montiert werden können und entweder mit mechanischen oder hydraulischen Kraftaufnehmer ausgestattet sind (KOMATSU 2019, PONSSE 2010). Dabei verändert sich die Krankinematik negativ, da der vergrößerte Schwerpunktabstand von der Greifermitte zum Teleskopauge zu höheren Pendelbewegungen des Greifers führen kann.

Mit einer Kranwaage kann im dynamischen Ladevorgang, bei einer gleichmäßigen, ruhigen Kranbedienung, die Greiferladung vermessen werden. Dabei verringert sich die Genauigkeit im Vergleich zu einer statischen Messung signifikant (KORTEN und KAUL 2012, WIDE 2012). In Kombination mit unterbrochenen Ladeprozessen für exakte Vermessungen führt dies zu einer signifikant verringerten Gesamtproduktivität.

Mehrere Forschungsprojekte untersuchten eine Nutzlastbestimmung in Radladern oder Frontladern, wobei die Fahrzeuge als mechanische Mehrkörpermodelle abgebildet wurden. Basierend auf diesen Mehrkörpermodellen wurde die Masse in der Schaufel unter Modellierung von Reibkräften bestimmt (BENNETT et al. 2014, WALAWALKAR et al. 2016, Yung 2017, WALAWALKAR et al. 2018). Die Güte der Gewichtsbestimmung korreliert jedoch sehr stark mit dem Detaillierungsgrad der Modelle. Aufgrund von Annahmen für Modellparameter wie Bauteilverformungen, Reibung oder Leckagen, welche auf empirischen Erkenntnissen basieren, besteht die Herausforderung darin, das nichtlineare Systemverhalten der Hydraulik korrekt abzubilden. Ein Modell, das die Realität mit hinreichender

Genauigkeit abbildet, kann jedoch nur mit sehr hohem Aufwand bestimmt werden (FREDERIC 2015, FODOR 2017).

Künstliche neuronale Netze zur Bestimmung des Schaufelinhaltes wurden bereits für einen Radlader entwickelt (SAVIA und KOIVO 2002). Aufgrund einer geringeren Anzahl an Freiheitsgraden, einer reduzierten Komplexität im Hydrauliksystem und des variablen Massenschwerpunktes sind die Netzarchitekturen jedoch nicht auf Forstkräne übertragbar. Durch die hohe Komplexität eines Forstkranes mit der großen Anzahl an Freiheitsgraden, welche alle reibungsbehaftet sind, ist die Erstellung von mechanischen Ersatzsystemen zur Gewichtsbestimmung nicht sinnvoll.

Ziele der entwickelten Methode für eine datenbasierte Kranwaage

Mit der im Folgenden präsentierten datenbasierten Methode wird ein dynamischer Wiegeprozess inklusive anschließender Datenverarbeitung realisiert, mit welchem ohne Produktivitätsreduktion eine Informationslücke im Logistikprozess geschlossen werden kann. Die Krankinematik wird dabei nicht durch zusätzliche Komponenten verändert. Die Messung und Datennachbereitung erfolgt vollkommen autonom, wodurch weder eine Interaktion des Forstmaschinenführers mit dem Messsystem notwendig ist noch das Ladeverhalten angepasst werden muss (GEIGER et al. 2018).

Durch den datenbasierten Ansatz ist die aufwändige Modellierung der Krankinematik unter Berücksichtigung der Zylinder- und Gelenkreibungen nicht notwendig. Mit dem abstrahierten Ansatz, den Kran mit einem KNN abzubilden, müssen unbekannte Parameter im Hydrauliksystem, wie spezifische Leckagen oder Reibungen, nicht explizit modelliert werden. Für die Entwicklung und Überprüfung des Wiegesystems wird in dieser Studie Stammholz verwendet, sodass reproduzierbare Bedingungen im Vergleich zu einer Untersuchung von Waldrestholz geschaffen werden.

Physikalisches Grundprinzip und sensorische Erfassung der Eingangsvariablen

Die durch die Masse im Greifer hervorgerufene Gewichtskraft F_G (Abbildung 1) korreliert – idealisiert betrachtet – aufgrund des Momentengleichgewichtes um die Drehachse des Hubarmes mit der Kraft, welche vom Hubzylinder (IBC) aufzubringen ist (Gleichung 1):

$$F_{IBC} \cdot l_{IBC} = F_G \cdot (l_G + l_{IBC}) \quad (\text{Gl. 1})$$

l_{IBC} = Abstand Drehpunkt zu IBC

l_G = Abstand IBC zu Greifermitte

Hierbei lässt sich die Masse m des Greiferinhalts, basierend auf dem Druck im Hubzylinder, analytisch bestimmen, da dieser nur bodenseitig angeschlossen ist (Gleichung 2):

$$m = \frac{p_{IBC} \cdot A_{IBC}}{g} \cdot \frac{l_{IBC}}{l_G + l_{IBC}} \quad (\text{Gl. 2})$$

g = Erdbeschleunigung

A_{IBC} = Bodenfläche Hubzylinder




Abbildung 1: Kraftangriffspunkte am Forstkran

Die Gleichungen 1 und 2 beschreiben eine idealisierte analytische Möglichkeit der Gewichtsbestimmung durch die Erfassung von p_{IBC} sowie des Greiferabstandes l_G ; die im Folgenden entwickelte Methode lehnt sich an diese Idee an. Mit der hohen Anzahl an Gelenken und Zylindern ist eine analytische Berechnung des Greiferinhalts aufgrund der Nichtlinearitäten bei einem Forstkran jedoch nicht möglich. Daher wird mithilfe eines KNN, bei dem die realen Einflussfaktoren berücksichtigt werden, ein Ersatzmodell zur Gewichtsbestimmung entwickelt, welches ebendiese nichtlinearen Zusammenhänge abbildet.

Die primären Eingangsgrößen für das neuronale Netz sind folglich der Druck im Hubzylinder p_{IBC} , die kinematischen Bedingungen, die zum variablen Abstand l_G führen, sowie die Fahrervorgaben. Der Druck wird sowohl direkt als Zeitreihe als auch in gefilterter Form in das Netz eingespeist. Zudem wird das Frequenzspektrum des IBC-Drucks aus einer Fast-Fourier-Transformation (FFT) als weiterer Eingang verwendet. Zusätzlich dienen der Speicherdruck, der Pumpendruck sowie die Ventildrücke in dem hybriden Hydrauliksystem der Versuchsmaschine als Eingangssignale (GEIGER und GEIMER 2017, HOHENLOHER SPEZIAL-MASCHINENBAU 2014). Alle Drücke werden mit CAN-fähigen Drucksensoren mit einer Frequenz von 50 Hz aufgezeichnet. Weiterhin wird die Öltemperatur in das KNN einbezogen.

Der Abstand des Greifers l_G wird über kinematische Beziehungen aus den Winkeln zwischen Kransäule - Hubarm, Hubarm - Wipparm, Schwenkwerk sowie der Länge des Teleskops berechnet. Die dafür notwendigen Sensoren sind serienmäßig im Kran vorinstalliert und über den CAN-Bus auslesbar. Daraus wird die Greifergeschwindigkeit und -beschleunigung berechnet und dem KNN vorgegeben. Der Kran wird mit zwei CAN-fähigen Joysticks gesteuert. Diese Signale liegen somit serienmäßig auf dem CAN-Bus und können direkt erfasst werden, dadurch werden die Sollvorgaben des Fahrers aufgezeichnet.

Phasen im Ladeprozess eines Forstkranes

Aus der Evaluation der Messungen im realen Forsteinsatz ergibt sich eine Aufteilung eines Ladezyklus in vier Ladephasen (GEIGER und GEIMER 2017):

- I. Ausfahrbewegung des Greifers vom Rungenkorb zum Stamm hin
- II. Greifen und Anheben des Stammes
- III. Einfahrbewegung des Greifers mit Stamm zur Rungenkorbmitte
- IV. Positionierung und Ablegen des Stammes im Rungenkorb

Abbildung 2 zeigt die einzelnen Phasen des Ladezyklus in Übereinstimmung mit MORALES et al. (2015). Eine Messung des Greiferinhalts ist in den Phasen II und III sinnvoll, da hier der Stamm zu-
meist ohne Kontakt zu umstehenden Bäumen oder den Rungen über den Rungenkorb bewegt wird. Der Einbezug der Phase IV ist nicht sinnvoll, da der Stamm bei der Positionierung im Rungenkorb auf bereits geladenen Stämmen aufliegt.




Abbildung 2: Phasen im Ladezyklus (GEIGER und GEIMER 2017)

Messdatenerfassung am Applikationsfahrzeug

Grundlage der datenbasierten Methode sind Trainingsdaten, welche den realen Ladevorgang im Forst darstellen und dem trainierten künstlichen neuronalen Netzwerk ermöglichen, die Masse im Greifer aus zukünftigen, unbekanntem Daten genau zu bestimmen. Um die reale Baumstammmasse als Sollgröße in der Trainingsphase nutzen zu können, wurden die Stämme der Baumart Fichte vorher einzeln gewogen und mit einer fortlaufenden Nummer markiert (Abbildung 3). Die Waage zur Ermittlung der Realmasse wies eine Messungenauigkeit von 0,5 kg auf. Die Massen der Einzelstämme lagen im Bereich von 100 bis 600 kg, die Mitteldurchmesser erstreckten sich zwischen 20 und 50 cm bei einer Stammlänge von 5,20 m. Durch das simultane Laden mehrerer Baumstämme erstreckte sich der Messbereich auf bis zu 1.000 kg.



Abbildung 3: Sammeln der Trainingsdaten (© C. Geiger)

Der Fahrer der Maschine wurde angewiesen, die Baumstämme randomisiert zu laden. Parallel zum Laden wurde die jeweilige Baumstammnummer notiert, um anschließend die Lademasse berechnen zu können. Dem Forstmaschinenführer wurde die Option gewährt, auch zeitgleich mehrere Baumstämme im Greifer zu laden, um den Vorgang im Forst möglichst genau zu simulieren. Insgesamt wurden mit dieser Vorgehensweise 500 Ladezyklen aufgezeichnet, wobei 25 Ladezyklen circa einem vollständig gefüllten Rungenkorb von 10 Festmeter Ladevolumen und 11 Tonnen Nutzlast entsprechen.

Netzarchitektur zur Bestimmung der Stammmasse

Ein künstliches neuronales Netz bildet mithilfe der verdeckten Schicht einen Eingangsvektor auf einen Ausgangsvektor ab. In der Trainingsphase werden die einzelnen Parameter des KNN angepasst, um die Eingangsgrößen in einen gewünschten Ausgang umzuwandeln. Die gewichteten Verbindungen zwischen den Eingangsneuronen, den Neuronen der verdeckten Schicht und den Ausgangsneuronen lassen sich individuell durch den Lernalgorithmus des KNN einstellen. Dieser besteht aus einer Verkettung von Backpropagation und des stochastischen Gradientenverfahrens (GOODFELLOW et al. 2016).

Die einzelnen Ladevorgänge liegen als Zeitreihen vor und bilden denselben Ladezyklus ab, jedoch weisen sie Unterschiede in der Bewegung im Raum und in ihrer Gesamtdauer auf. Jeder Ladezyklus ist somit einzigartig in seinem Ablauf der Signale. In einem klassischen KNN ist die Länge des Eingangsvektors zwar frei wählbar, jedoch unveränderbar.

Um sequenzielle Informationen zu verarbeiten, haben sich rekurrente neuronale Netzwerke (RNN) als sinnvoll erwiesen. Der weitreichende Vorteil eines RNN liegt in den zyklischen Verbindungen der Zellen innerhalb der verdeckten Schicht. Dies ermöglicht es dem Netzwerk, basierend auf dem derzeitigen Eingangsvektor sowie unter Einbezug aller vorherigen Zeitschritte, einen Ausgangsvektor für den aktuellen Zeitschritt zu bestimmen. Die Daten aus der Vergangenheit nehmen damit direkt Einfluss auf die Gewichtsbestimmung in der Gegenwart. Somit kann ein RNN komplizierte, lokal versetzte Zusammenhänge in Daten erlernen und ein abstraktes Systemverständnis generieren (GRAVES 2012, GOODFELLOW et al. 2016). Eine spezielle Variante des RNN ist die Long-Short-Term-Memory(LSTM)-Architektur (HOCHREITER und SCHMIDHUBER 1997). Diese ermöglicht es dem Netzwerk, den Gedächtniseffekt innerhalb eines längeren Zeitraums zu verstärken und idealerweise präzise auf vorherige sowie aktuelle Eingangsgrößen zu reagieren. Während der Trainingsphase lernt das Netzwerk, welche Eingangssignale es sich merken muss und welche keinen Einfluss auf die Zielgröße haben oder nur im aktuellen Zustand relevant sind (GRAVES 2012).

Abbildung 4 zeigt die Struktur des Netzwerkes für die Gewichtsbestimmung bei einem Forstkran auf Basis der LSTM-Architektur. Die Eingangsgrößen für den jeweiligen Zeitschritt (orange) werden an die LSTM-Zellen (grün) weitergeleitet. Dort kommen die Ausgänge der LSTM-Zellen des vorherigen Zeitschrittes dazu (rot), welche die zyklischen Verbindungen des Netzwerkes wiedergeben. Gleichzeitig übernimmt jede einzelne LSTM-Zelle den inneren Zustand aus dem vorherigem Zeitschritt (grau). Die Zelle verrechnet diese drei Eingangssignale miteinander und gibt anschließend ein Signal an die verdeckte Neuronenschicht (blau) aus (HOCHREITER und SCHMIDHUBER 1997). Diese bildet für den jeweiligen Zeitschritt die Ausgänge der verdeckten Schicht auf das Ausgangsneuron (gelb) des RNN ab. Diese Schritte wiederholen sich innerhalb der Datenreihe bis zum Ende.

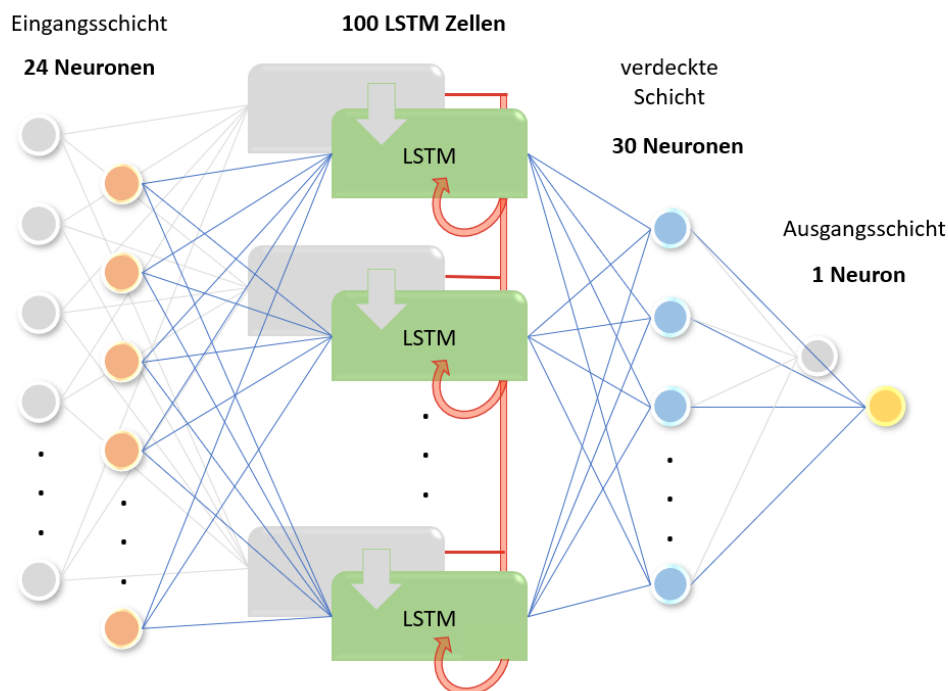


Abbildung 4: Verwendete Netzstruktur samt LSTM-Zellen

Als Hyperparameter werden Parameter bezeichnet, deren Wert vor Beginn des Trainings festgelegt werden müssen. Sie nehmen Einfluss auf den Trainingsprozess an sich und die endgültige Lösungsqualität. Abgesehen von den Hyperparametern zur Datenvorbereitung der Eingangsgrößen, wie z. B. der Filterbreite, die Kombination der möglichen Signale oder die zeitliche Auflösung der Signale, existieren weitere Hyperparameter, welche die Netzstruktur, die Initialisierung oder die Trainingsphase beeinflussen. Daraus resultierend hat sich die in Abbildung 4 dargestellte Netzwerkstruktur als ideal herausgestellt. Es werden dabei 24 Eingangsneuronen, 100 LSTM-Zellen, 30 Neuronen in der verdeckten Schicht sowie ein Neuron als Ausgang verwendet.

Im stochastischen Gradientenverfahren erfolgt die Variation der Netzwerkgewichte durch eine Mittelung des Änderungsgradienten für zufällig ausgewählte Teilmengen der Trainingsdaten. Diese sprunghafte Änderung des Gradienten ermöglicht es dem Algorithmus, Sattelpunkte zu verlassen und in lokale Minima von höherer Qualität zu konvergieren. Die Schrittgröße innerhalb des Lösungsraums entlang des Gradienten wird als Lernrate bezeichnet. Ziel der Entwurfsphase ist es, die Hyperparameter wie die Lernrate oder die Größe der parallelen Chargen optimal zu bestimmen. Dadurch wird eine Lösung generiert, bei welcher der Fehler innerhalb des Zielbereiches liegt (GE et al. 2015, MASTERS und LUSCHI 2018).

Um den Fehler auf Testdaten zu reduzieren, wird die Kapazität des Netzwerkes in der Trainingsphase durch einen sogenannten Dropout künstlich eingeschränkt (HINTON et al. 2012). Im Netzwerk wurde hierzu ein Wert von 0,5 verwendet, welcher dazu führte, dass während des Trainings die Hälfte der LSTM-Ausgänge zu jedem Zeitschritt randomisiert wegfallen, also auf Null gesetzt werden. Sinn dieser Maßnahme ist die Prävention von Ko-Adaptionen zwischen den einzelnen Neuronen. Die ein-

zelenen Zellen sind hierdurch gezwungen, selbstständig Informationen aus den Eingangssignalen zu gewinnen (HINTON et al. 2012).

Die notierte Baumstammmasse dient als Sollgröße für den jeweiligen Ladezyklus. Das RNN benötigt für die Berechnung jedoch einen Zielwert zu jedem Zeitschritt. Um diesen Vektor zu generieren, wurde angenommen, dass die Greiferladung mit ihrer vollen Gewichtskraft auf den Kran wirkt, sobald sie sich in der Luft befindet. In der Greifphase (Phase II) wird der Massenvektor (Abbildung 5, schwarz gestrichelt) als linear steigend angenommen. Abbildung 5 zeigt darüber hinaus den Startpunkt des Massenvektors bei ca. 7 Sekunden und veranschaulicht den weiteren Verlauf auf Basis der vorigen Annahmen. Explizit wird die Steigung über den Gradienten der Greiferhöhe nach dem Greifen des Baumstammes bestimmt. Überschreitet die Greiferhöhe einen Schwellenwert, erfolgt die Annahme, dass die Ladung sich komplett in der Luft befindet. Zwischen dem Startpunkt und dem Endpunkt wird der Zielmassenvektor linear interpoliert.




Abbildung 5: Zielmassenvektor samt linearem Anstieg

Die Analyse der Eingangsgewichte der LSTM-Zellen ermöglicht es, das Verhalten des Netzwerkes abzuschätzen. Den physikalischen Grundlagen entsprechend hat sich gezeigt, dass vor allem der IBC-Druck, ungefiltert und mittels eines Savitzky-Golay-Filters gefiltert, sowie der l_G -Abstand relevante Eingangsgrößen für das Netzwerk sind. Weitere signifikante Eingangsgrößen sind die z-Position des Greifers, das Joysticksignal des Hubarmzylinders und der Winkel zwischen Hauptarm und Kransäule.

Automatisierter Wiegeprozess im Sortimentsverfahren

Um die Akzeptanz und Anwendbarkeit der dargestellten Methode zur Wiegung des Greiferinhalts zu erreichen, muss ebendiese benutzerfreundlich sein. Aufgrund der großen Datenmengen, die während eines Arbeitstages entstehen, ist es daher erforderlich, den Prozess der einzelnen Gewichtsschätzungen zu automatisieren. Abbildung 6 veranschaulicht den Ablauf des automatisierten Wiegeprozesses, bei welchem die geladenen Massen eines kompletten Arbeitstages in einem Postprocessing-Verfahren ermittelt werden.

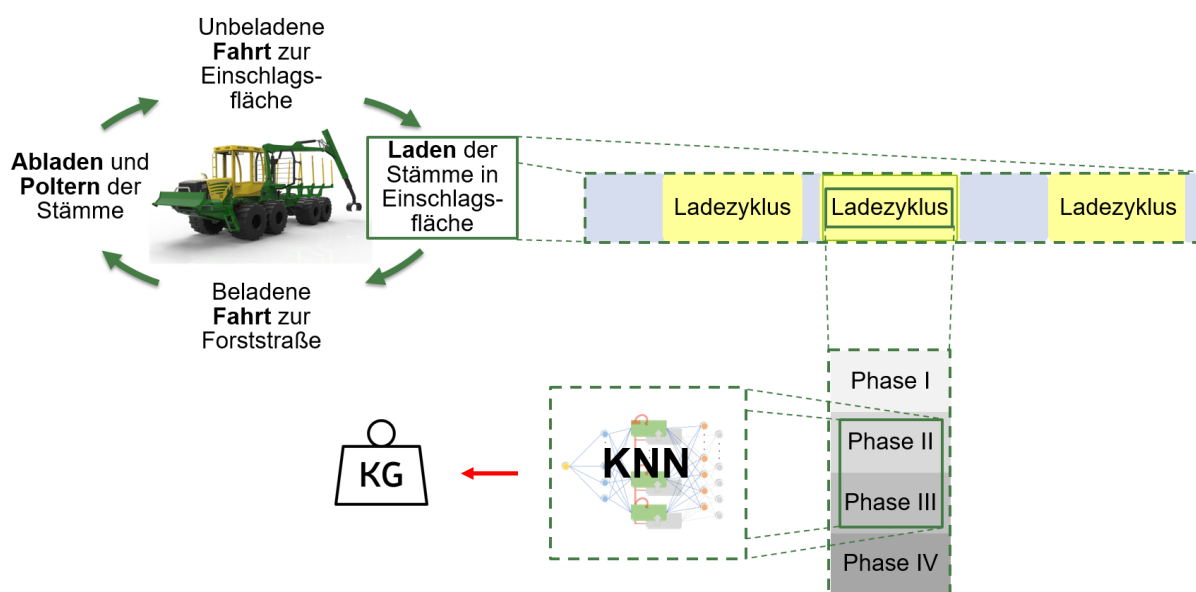


Abbildung 6: Ablaufdiagramm des automatisierten Wiegeprozesses bei einem Forwarder

Da der Forwarder sich im Verlauf eines Arbeitstages mehrmals in der Rückegasse befindet, müssen diese Zeiträume im ersten Schritt extrahiert werden. Anschließend erfolgt die Erkennung der einzelnen Ladezyklen in der Rückegasse. Daraufhin werden für jeden erkannten Ladezyklus die vier Phasen im Ladeprozess ermittelt und alle aufgezeichneten Signale für die Phase II und Phase III abgespeichert, da diese Zeitreihen anschließend die Eingänge für das RNN bilden. Im trainierten Netz wird die Masse zum jeweiligen Ladezyklus geschätzt und anschließend ausgegeben. Nachfolgend sind die einzelnen Schritte der erläuterten Methode im Detail erklärt.

Schritt 1: Detektion der Maschine auf der Rückegasse

Der Arbeitsprozess des Ladens, also der Zeitraum, in dem sich der Forwarder auf der Rückegasse befindet, muss zunächst ermittelt werden, um die Datenmenge für die nachfolgenden Algorithmen zu minimieren. Damit dieser Prozess möglichst schnell und mit minimaler Rechenleistung abläuft, werden nur die Signale des Schwenkwinkels und des Zylinderdrucks des Greifers betrachtet. Das Laden kann zwar leicht von den Arbeitsprozessen des beladenen und unbeladenen Fahrens unterschieden werden (Abbildung 6), eine Differenzierung zum Abladen und Poltern ist jedoch anspruchsvoll. Für diese Unterscheidung wurde ein Algorithmus entwickelt, welcher die Ladezyklen des Forwarders detektiert. Hierzu wird der Zylinderdruck des Greifers beim Schwenken des Greifers in Richtung Runnenkorb betrachtet. Dieser ist bei einem Ladezyklus signifikant höher als beim Entladen, da der Grei-

fer leer zum Rungenkorb zurückgeschwenkt wird. Nach der Detektion möglicher Ladezyklen werden zeitlich zusammenhängende Ladezyklen zu Intervallen zusammengefasst, in denen der Forwarder auf der Rückegasse ist. In diesen Zeiträumen werden für die weiteren Schritte alle Eingangssignale zur weiteren Auswertung herangezogen.

Schritt 2: Detektion der einzelnen Ladezyklen und der Greifphase

Die einzelnen Ladezyklen werden über die Greiferposition erkannt, explizit über den seitlichen Abstand zwischen Greiferspitze und Kransäule. Der für die Waage relevante Teil des Ladezyklus beginnt mit dem Verlassen des Rungenkorbs. Hierzu werden alle eingehenden Zyklen hinsichtlich ihrer Druckverläufe im Hauptarmzylinder untersucht. Ist der Druck beim Verlassen des Korbes niedriger als beim Wiedereintritt liegt ein Ladezyklus vor. Die Greifphase und die anschließende Einfahrbewegung des Krans samt Ladung enthalten die Informationen, welche das RNN für den Wiegeprozess nutzt. Die Position der Greifphase im Ladezyklus wird durch eine Analyse der Joysticksignale, des IBC-Druckes und der Greiferposition im Raum ermittelt (Abbildung 5).

Für die Bestimmung der Greifphase werden jedoch nicht die Rohdaten des IBC-Drucks verwendet, da die lokalen Oszillationen eine präzise Analyse erschweren. Durch Filterung des Signals werden die Druckschwankungen reduziert. Nachdem alle gefilterten Druckspitzen im Zyklus detektiert sind, werden alle Positionen, in denen sich der Greifer in einem lokalen Minimum befindet, auf drei Konditionen hin überprüft (Abbildung 5):

- Befindet sich eine Druckspitze in der unmittelbaren Nähe?
- Schließt der Greifer in der unmittelbaren Nähe?
- Steigt die z-Position des Greifers über einen Schwellenwert unmittelbar nach dem Minimum?

Werden alle drei Konditionen erfüllt, wird dieses Minimum als möglicher Startpunkt der Greifphase markiert. Erfüllen mehrere Minima die Anforderungen, wird immer das zeitlich zuletzt auftretende Minimum ausgewählt. Hierdurch wird sichergestellt, dass immer die Masse, welche letztendlich auf das Fahrzeug geladen wird, auch in das Netz eingeht. Dies schließt den Praxisfall des Sammelns mehrerer Stämme mit geringem Durchmesser ein, die dann gemeinsam geladen werden.

Schritt 3: Wiegeprozess mit RNN

Nach der Detektion der Greifphase werden die entsprechenden Signale des Ladezyklus als Eingangsdaten für das RNN verwendet. Jedes Eingangssignal liegt hierbei in Form einer Zeitreihe vor. Das trainierte RNN übernimmt nun die Rolle der Modellierung und errechnet zu jedem Zeitschritt, basierend auf allen vorherigen Eingangsdaten, eine Massenprädiktion. Dieser resultierende Massenvektor wird im letzten Schritt durch eine Schätzfunktion zu einem skalaren Wert umgewandelt, welcher der geladenen Stammmasse entspricht.

Abbildung 7 zeigt die Vorhersage des resultierenden Massenvektors durch das RNN exemplarisch für einen Zyklus. Zur Bestimmung einer skalaren Masse aus dieser Prädiktion ist es notwendig, den passenden Abschnitt des Ausgabevektors zu betrachten. Dieser beginnt in diesem Fall zwischen Sekunde 3 und 4. Um diesen Punkt zu bestimmen, wird der Gradient des Massenvektors zugrunde gelegt. Ausgehend vom Beginn des Abschnittes wird das symmetrisch getrimmte Mittel aller nach-

folgenden Datenpunkte errechnet. Im Vergleich zum arithmetischen Mittel eignet es sich als Schätzfunktion, da es lokale Maxima und Minima ausblendet.




Abbildung 7: Prädiktion des Massenvektors über die Zeit

Liegt wie in Abbildung 7 dargestellt eine unsymmetrische Verteilung vor, ist ein symmetrisch getrimmtes Mittel nicht ideal, da valide Datenpunkte an einem Ende des Datenbereichs ausgeblendet werden. Daher muss die Bestimmung der Stammmasse um einen zusätzlichen Schritt erweitert werden. Asymmetrische Ausreißer werden durch einen Abstand zum vorher berechneten getrimmten Mittel bestimmt, indem ein Toleranzbereich eingefügt wird. Dieser ist in Abbildung 7 in Rot dargestellt. Der Mittelwert der rot umkreisten Datenpunkte bildet die endgültige Stammmasse für diesen Ladezyklus ab.

Ergebnisse aus der Messkampagne

Die zufälligen Abläufe in der Trainingsphase und die Initialisierung von künstlichen neuronalen Netzwerken führt dazu, dass jedes RNN sich nach dem Training in einem anderen lokalen Minimum im Lösungsraum befindet. Um den Lösungsraum bestmöglich abzudecken, wurden daher nach der Entwurfsphase 120 RNN trainiert. Da jedes RNN unterschiedliche finale Gewichte besitzt, führt dies zu Stärken und Schwächen in der Prädiktionsqualität. Eine Verbesserung des Ergebnisses ergibt sich nach der Theorie durch eine Vereinigung der unterschiedlichen Prädiktionen zu einer Gesamtprädiktion (PERRONE und COOPER 1995, GOODFELLOW et al. 2016). Die trainierten Netzwerke wurden daher bezüglich ihrer Genauigkeit auf einem Testdatensatz, bestehend aus 25 zufällig ausgewählten Ladezyklen, überprüft. Dieser Testdatensatz wurde unter den gleichen Bedingungen wie der Trainingsdatensatz zusammengestellt, jedoch wurde er nicht zum Training der Netzwerke herangezogen. Der Fehler auf einem – dem Netzwerk unbekanntem – Datensatz gibt Aufschluss darüber, inwieweit das Netzwerk in der Lage war, während des Trainings ein abstraktes Systemverständnis zu generieren.

Für die Qualität des dynamischen Wiegeprozesses ist es wichtig, dass kein kontinuierliches Über- oder Unterschätzen stattfindet. Zudem sollte die Varianz der einzelnen Ladezyklen möglichst gering sein. In Abbildung 8 ist daher der Fehler bei der Massenbestimmung für eine variierende Anzahl an verwendeten Netzwerken dargestellt. Die ideale geschätzte Masse ergibt sich aus dem arithmetischen

Mittel der zwanzig RNN mit dem geringsten Fehler (Abbildung 8, rechts). Dies zeigt sich ebenfalls an der minimalen Varianz im Vergleich zu dem Mittelwert aller RNN (Abbildung 8, links) oder dem RNN mit dem geringsten Fehler (Abbildung 8, Mitte), visuell veranschaulicht durch die geringste Distanz des Datenbereichs im Boxplot. Werden alle RNN hinzugezogen, streckt sich der Fehlerbereich deutlich, was auf die mangelnde Qualität einiger lokalen Optima schließen lässt. Auch der Vergleich zum einzelnen RNN mit dem geringsten Fehler stützt die These der Stärken und Schwächen der einzelnen RNN. Hierbei ist festzustellen, dass sich der Median bei diesen beiden unmerklich unterscheidet.

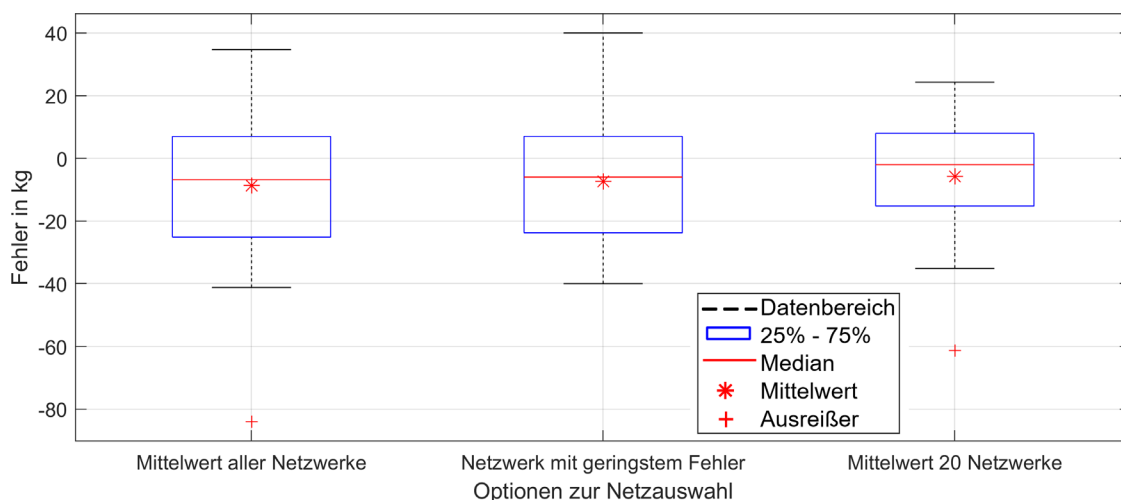


Abbildung 8: Übersicht der Fehler auf den Testzyklen bei unterschiedlicher Netzauswahl

Mit dem Netzwerkensemble der 20 RNN mit geringstem Fehler ist es möglich, auf Basis vorher unbekannter Daten eine durchschnittliche Genauigkeit von 15 kg je Ladezyklus zu erzielen, welches einem absoluten mittleren Gesamtskalenfehler von 1,5 % bezogen auf 1.000 kg entspricht. Abbildung 9 veranschaulicht die realen Stammmassen der einzelnen Ladezyklen und die dazugehörige geschätzte Masse des Netzwerkes.




Abbildung 9: Resultat der Netzwerkprädiktion für vorher unbekannte Testzyklen

Die Qualität der Schätzungen über den gesamten Skalenbereich ist gleichbleibend, und es liegt nur ein einziger Ladezyklus vor, der nicht in der Nähe der Ideallinie liegt. Dieser Ausreißer ist als solcher auch in Abbildung 8 im rechten Boxplot zu erkennen. Die prädizierte Masse weicht damit bei dem vollbeladenen Forwarder mit 11.974 kg Zuladung um 143 kg ab, was einem Massenfehler von 1,19 % entspricht.

Schlussfolgerungen

Auf der Grundlage eines RNN ist eine Massenbestimmung des Greiferinhalts während eines dynamischen Ladevorgangs in einem Offline-Verfahren unter reproduzierbaren Bedingungen mit Stammholz möglich. Das arithmetische Mittel der 20 RNN mit dem geringsten Fehler eignete sich am besten für eine optimale Bestimmung dieser Masse. Die datenbasierte Methode eignet sich, um Informationen über die im Tagesverlauf gerückte Masse zu erhalten.

Die Kranwaage wurde unter reproduzierbaren Bedingungen auf ebener Fläche mit einer limitierten Anzahl an Stammholzabschnitten entwickelt und getestet. Eine Funktionalitätsprüfung der Waage innerhalb eines realen forstlichen Einsatzes mit stärker variierenden Sortimentseigenschaften oder Fahrzeugneigungen steht noch aus. Für die zukünftige Verwendung eines Wiegesystems auch im traditionellen Volumenmaß, müssen für Waldhackschnitzel entsprechende Umrechnungsfaktoren bereitgestellt werden, welche u. a. den Feuchtegehalt oder den Anteil grüner Biomasse des Sortiments berücksichtigen und es ermöglichen, die Volumenanteile vom Gewicht abzuleiten. Der vorgestellte Ansatz basiert auf einer Auswertung der Daten am Ende eines Arbeitstages. Zukünftig soll die Methode dahingehend weiterentwickelt werden, dass die Bestimmung der aktuellen Masse im Greifer mithilfe eines Convolutional Neural Networks (CNN) online möglich ist und der Fahrer das Gewicht somit in Echtzeit ablesen kann.

Durch die Verwendung eines solch konfigurierten Trägerfahrzeugs bei der Bestückung von mobilen Hackern wird es beispielsweise möglich sein, im Hackschnitzelprozess eine optimale Zuladung von LKW für den Weitertransport sicherzustellen. Eine brachenübergreifende Erweiterung des Systems ist damit denkbar.

Literatur

- Bennett, N.; Walawalkar, A.; Schindler, C. (2014): Payload Estimation in Excavators: Model-Based Evaluation of Current Payload Estimation System. In: Proceedings of the 3rd Commercial Vehicle Technology Symposium (CVT2014)
- Berg, S.; Fischbach, J.; Brüchert, F.; Poissonnet, M.; Pizzirani, S.; Varet, A.; Sauter, U.H. (2012): Towards assessing the sustainability of European logging operations. *European Journal of Forest Research* 131(1), S. 81–94, <https://doi.org/10.1007/s10342-011-0561-x>
- Bodelschwingh, E. v. (2006): Analyse der Rundholzlogistik in der Deutschen Forst- und Holzwirtschaft – Ansätze für ein übergreifendes Supply Chain Management. Dissertation, TU München
- Cacot, E.; Bigot, M.; Cuchet, E. (2006): Developing full-mechanized harvesting systems for broadleaved trees: a challenge to face the reduction of the manual workforce and to sustain the supply of hardwood industries. In: 2006 Council on Forest Engineering (COFE) Conference Proceedings: "Working Globally – Sharing Forest Engineering Challenges and Technologies Around"
- Deutscher Forstwirtschaftsrat e. V. und Deutscher Holzwirtschaftsrat e. V. (2015): Rahmenvereinbarung für den Rohholzhandel in Deutschland (RVR)
- Erlor, J.; Purfürst, T.; Dög, M. (2010): Präzise Forstwirtschaft. Reihe Technikmanagement in der Forstwirtschaft, Tharandt, Fachinstitut für Waldarbeit

- Fodor, S. (2017): Towards semi-automation of forestry cranes. Automated trajectory planning and active vibration damping. Dissertation, Department of applied physics and electronics, Umeå University
- Frederic, B. (2015): Dynamic, Continuous, and Center of Gravity Independent Weighing with a Loader. Dissertation, Technischen Universität Kaiserslautern
- Ge, R.; Huang, F.; Jin, C.; Yuan, Y. (2015): Escaping From Saddle Points – Online Stochastic Gradient for Tensor Decomposition. In: JMLR: Workshop and Conference Proceedings, Conference on Learning Theory, 3–6 July 2015, Paris, France vol 40, pp. 797–842
- Geiger, C.; Geimer, M. (2017): Efficiency Optimisation of a Forestry Crane by Implement Hydraulics with Energy Recovery. In: VDI-MEG – 75th International Conference on Agricultural Engineering, LAND.TECHNIK AgEng 2017 - The Forum for Agricultural Engineering Innovations, Hannover, 10–11 November 2017, pp. 117–125
- Geiger, C.; Starke, M.; Greff, D.; Geimer, M. (2018): The potential of a weight detection system for forwarders using an artificial neural network. In: FORMEC 2018 – Improved Forest Mechanisation: mobilizing natural resources and preventing wildfires, Proceedings
- Goodfellow, I.; Bengio, Y.; Courville, A. (2016): Deep Learning. Cambridge, USA, MIT Press
- Graves, A. (2012): Supervised Sequence Labelling with Recurrent Neural Networks. Springer Verlag
- Heinimann, H.R. (1994): Beiträge zur forstlichen Verfahrenstechnik. Tagungsbericht über das 28. Internationale Symposium „Mechanisierung der Waldarbeit“ vom 28.08.–02.09.1994 in Langnau i.E., Schweiz, Zürich, Verl. der Fachvereine an den schweizer. Hochschulen u. Techniken
- Hinton, G.E.; Srivastava, N.; Krizhevsky, A.; Sutskever, I.; Salakhutdinov, R.R. (2012): Improving neural networks by preventing co-adaptation of feature detectors. <https://arxiv.org/pdf/1207.0580.pdf>, Zugriff am 19.09.2019
- Hochreiter, S.; Schmidhuber, J. (1997): Long Short-Term Memory. *Neural Computation* 9(8), pp. 1735–1780, <https://doi.org/10.1162/neco.1997.9.8.1735>
- Hohenloher Spezial-Maschinenbau GmbH & Co. KG. (2014): DE 202014006861, Hohenlohe, F.
- Komatsu (2019): Options Forwarders. <https://www.komatsuforest.com/forest-machines/our-forwarders/forwarder-options>, Zugriff am 13.04.2019
- Korten, S.; Kaul, C. (2012): Optimierung der Transportprozesse bei Holzernte und Rundholztransport durch den Einsatz von Wechselbrücken. Schlussbericht, Lehrstuhl für Forstliche Arbeitswissenschaft und Angewandte Informatik der TU München
- Kuptz, D.; Turowski, P.; Hartmann, H.; Schulmeyer, F. (2015): Optimale Bereitstellungsverfahren für Holzhackschnitzel. Berichte aus dem TFZ, Technologie- und Förderzentrum (TFZ) im Kompetenzzentrum für Nachwachsende Rohstoffe
- Manner, J.; Palmroth, L.; Nordfjell, T.; Lindroos, O. (2016): Load level forwarding work element analysis based on automatic follow-up data. *Silva Fennica* 50(3), <https://doi.org/10.14214/sf.1546>
- Masters, D.; Luschi, C. (2018): Revisiting Small Batch Training for Deep Neural Networks. CoRR, <https://arxiv.org/pdf/1804.07612.pdf>, Zugriff am 19.09.2019
- Morales, D.O.; La Hera, P.; Westerberg, S.; Freidovich, L.B.; Shiriaev, A.S. (2015): Path-Constrained Motion Analysis: An Algorithm to Understand Human Performance on Hydraulic Manipulators. *IEEE Transactions on Human-Machine Systems* 45(2), pp. 187–199, <https://doi.org/10.1109/THMS.2014.2366873>
- Nurminen, T.; Korpunen, H.; Uusitalo, J. (2006): Time consumption analysis of the mechanized cut-to-length harvesting system. *Silva Fennica* 40(2), <https://doi.org/10.14214/sf.346>
- Perrone, M.P.; Cooper, L.N. (1995): When networks disagree: Ensemble methods for hybrid neural networks. In: How We Learn; How We Remember: Toward an Understanding of Brain and Neural Systems – Selected Papers of Leon N Cooper. World Scientific Series in 20th Century Physics: Volume 10, pp. 342–358, https://doi.org/10.1142/9789812795885_0025
- Ponsse (2010): Ponsse attachments add value to your machine. http://www.toimilgruas.com/pdf/Attachment_ENGL.pdf, Zugriff am 13.04.2019
- Savia, M.; Koivo, H. (2002): On-line payload determination of a moving loader using neural networks. *IFAC Proceedings Volumes* 35(1), pp. 37–42, <https://doi.org/10.3182/20020721-6-ES-1901.01157>

- Walawalkar, A.; Heep, S.; Schneider, F.; Schüßler, J.; Schindler, C. (2016): A method for payload estimation in excavators. In: Proceedings of the 4th Commercial Vehicle Symposium (CVT 2016), 8–10 March 2016, University of Kaiserslautern, Germany, pp. 424–437
- Walawalkar, A.; Heep, S.; Schindler, C.; Leifeld, R.; Frank, M. (2018): Validation of an analytical method for payload estimation in excavators. In: Commercial Vehicle Technology 2018, Eds. Berns K. et al., Proceedings, Springer Vieweg, Wiesbaden, pp. 3–16
- Wide, M.I. (2012): Väg rätt redan i skogen. Skogforsk, https://www.skogforsk.se/cd_48e558/contentassets/d161ed005cd04d9dbcbb3302102a39ae/nr15_jh_4s_high.pdf, Zugriff am 19.09.2019
- Yung, I. (2017): Automation of Front-End Loaders. Electronic Self Leveling and Payload Estimation. Dissertation, Umeå University

Autoren

Chris Geiger, M.Sc. ist wissenschaftlicher Mitarbeiter, **Daniel Greff, B.Sc.** war studentischer Mitarbeiter und **Prof. Dr.-Ing. Marcus Geimer** ist Leiter des Teilinstituts Mobile Arbeitsmaschinen (Mobima) am Karlsruher Institut für Technologie (KIT), Rintheimer Querallee 2, 76131 Karlsruhe, E-Mail: chris.geiger@kit.edu.

M.Sc. Michael Starke ist wissenschaftlicher Mitarbeiter an der Berner Fachhochschule (BFH), Hochschule für Agrar-, Forst- und Lebensmittelwissenschaften, Länggasse 85, 3052 Zollikofen, Schweiz

Danksagungen

Dieses Projekt wurde im Rahmen des Fördervertrags Nr. 727883 aus dem Forschungs- und Innovationsprogramm der Europäischen Union Horizon 2020 finanziert.