

# **Assistenzsystem für einen teilautomatisierten Ladeprozess bei Forwardern**

Zur Erlangung des akademischen Grades eines  
**Doktors der Ingenieurwissenschaften (Dr.-Ing.)**

von der KIT-Fakultät für Maschinenbau des  
Karlsruher Instituts für Technologie (KIT)

genehmigte  
**Dissertation**

von

M.Sc. Chris Geiger

Tag der mündlichen Prüfung:	27. April 2022
Referent:	Prof. Dr.-Ing. Marcus Geimer
Korreferent:	Prof. Dr. Ludger Frerichs



## Kurzfassung

Die komplexe Bedienung eines Forwarders in der forstlichen Arbeitsumgebung stellt hohe Anforderungen an den Maschinenbediener. Vor allem ungeübte Bediener können diese während ihrer Lernphase nicht erfüllen und weisen dadurch eine sehr geringe Produktivität im Betrieb der Maschine auf.

In der vorliegenden Arbeit wird daher zur Unterstützung dieser Bediener ein Assistenzsystem für einen teilautomatisierten Ladeprozess entwickelt, da dieser durch den größten Zeitanteil und Komplexitätsgrad der Arbeitstätigkeit ein hohes Potential zur Effizienzsteigerung aufweist. Hierzu werden mittels Methoden aus dem Bereich des Maschinellen Sehens die zu ladenden Stämme erkannt und anschließend die Stammposition als Input für die Automatisierung bestimmt. Mit Hilfe der entwickelten Kranspitzensteuerung führt das Assistenzsystem die Bewegung des Krans zum Stamm hin aus und greift diesen automatisch. Dabei wird ein Hydrauliksystem mit einem hydraulischen Transformator berücksichtigt, durch welches eine Energieregeneration möglich ist. Für die Gewichtsbestimmung zur Produktivitätsberechnung bei realen Arbeitsbedingungen wurde eine datenbasierte Kranwaage entwickelt.

Die Funktionalität des Assistenzsystems wird mit einer Demonstratormaschine verifiziert und die Effizienz durch reproduzierbare Referenzzyklen evaluiert. Für ungeübte Bediener steigt die Produktivität um bis zu 67 %, während zeitgleich der Energiebedarf um bis zu 29 % reduziert wird.



## **Abstract**

The complex operation of a forwarder in the forestry work environment places high demands on the machine operator. In particular, inexperienced operators are unable to meet these requirements during their learning phase, resulting in very low productivity during operation.

In this thesis, an assistance system for an automated loading process is developed to support the operator, since this process has a high potential for increasing efficiency due to the largest time share and complexity of the work activity. For this purpose, machine vision methods are used to recognize the logs to be loaded and then determine the log position as an input for automation. With the help of the developed boom tip control, the assistance system carries out the movement of the crane to the log and grips it automatically. A hydraulic system with a hydraulic transformer is taken into account, through which energy regeneration is possible. A data-based crane scale was developed to determine the weight for productivity calculation in real working conditions.

The functionality of the assistance system is verified with a demonstrator and the efficiency was evaluated by reproducible reference cycles. For untrained operators, productivity increases up to 67 %, while at the same time energy consumption is reduced by up to 29.8 %.



# Inhaltsverzeichnis

<b>1</b>	<b>Einleitung</b>	<b>1</b>
<b>2</b>	<b>Stand der Technik und Forschung</b>	<b>5</b>
2.1	Forstmaschinen als mobile Arbeitsmaschinen	5
2.2	Assistenzsysteme bei Forstmaschinen	10
2.3	Auswirkungen der Teilautomatisierung von Kranbewegungen	16
2.4	Nutzlastbestimmung	17
2.5	Umfeldererkennung	19
<b>3</b>	<b>Forschungsbedarf und methodisches Vorgehen</b>	<b>25</b>
3.1	Forschungsbedarf	25
3.2	Entwicklung eines Assistenzsystem zur Teilautomatisierung des Ladeprozesses	28
<b>4</b>	<b>Versuchsträger und Entwicklungsumgebung</b>	<b>33</b>
4.1	Arbeitsantrieb einschließlich seiner Messtechnik	33
4.1.1	Forstkran als Arbeitskinematik	33
4.1.2	Hydrauliksysteme für den Forstkran	34
4.2	Versuchsumgebungen	38
4.3	Definition eines Referenzzyklus für die Arbeitsaufgabe Laden	39
<b>5</b>	<b>Informationsmodule</b>	<b>43</b>
5.1	Datenbasierte Kranwaage im Ladeprozess	43
5.1.1	Physikalische Motivation zur datenbasierten Waage	44
5.1.2	Eingangsdaten und deren Vorverarbeitung	46

5.1.3	Architektur des künstlichen Neuronales Netzes . . .	48
5.1.4	Training und Validierung . . . . .	51
5.1.5	Automatisierter Wiegeprozess im Sortimentverfahren	54
5.1.6	Phasenbestimmung des Ladezyklus . . . . .	55
5.2	Objekterkennung im Forst mittels maschinellen Sehens . . .	57
5.2.1	Objekterkennung und semantische Instanzsegmentierung von Stämmen . . . . .	59
5.2.2	Bestimmung der Stammmattribute . . . . .	64
5.2.3	Genauigkeitsanalyse der Merkmalsbestimmung . . .	69
<b>6</b>	<b>Assistenzsysteme für die Kransteuerung . . . . .</b>	<b>71</b>
6.1	Kranspitzensteuerung als Steuermodul . . . . .	71
6.1.1	Kinematik des Forstkrans . . . . .	72
6.1.2	Jacoby-Matrizen für das Serien- und HT-System . .	74
6.1.3	Die Pseudo-Inverse Lösung und ihre Gewichtungsmatrix . . . . .	75
6.1.4	Ventilansteuerung . . . . .	79
6.1.5	Genauigkeit der Kranspitzensteuerung . . . . .	80
6.1.6	Bediener- und umfeldangepasste Kransteuerung . . .	83
6.2	Assistenzsystem AutoLoad: Automatisierter Lade- und Greifprozess . . . . .	83
6.2.1	Initialzustand <i>Idle</i> . . . . .	86
6.2.2	Automatische Kranbewegung <i>AutoCraneDrive</i> . . .	87
6.2.3	Automatisches Greifen <i>AutoGrab</i> . . . . .	89
<b>7</b>	<b>Ergebnisse und Validierung des Assistenzsystems . . . . .</b>	<b>93</b>
7.1	Evaluation der Produktivitätsänderung im Referenzzyklus . .	93
7.2	Evaluation des Energiebedarfs im Referenzzyklus . . . . .	97
7.3	Einfluss des HT-Systems auf den Energiebedarf . . . . .	99
7.4	Genauigkeitsanalyse der Ladungserfassung . . . . .	106
<b>8</b>	<b>Zusammenfassung und Ausblick . . . . .</b>	<b>109</b>

**A Vollständige Liste eigener Publikationen . . . . . 139**



# Symbol- und Abkürzungsverzeichnis

## Abkürzungen

<b>Abkürzung</b>	<b>Bedeutung</b>
AP	Average Precision
mAP	mean Average Precision
B	Bediener
CNN	Convolutional Neural Network
CTL	Cut-to-Lenght
fps	frames per second
HT	Hydro-Transformator
IBC	Hubzylinder
IoU	Intersection over Union
LS	Load-Sensing
LST	Long short-term Memory
LTS	Least-Trimmed-Squares
NN	Neuronales Netzwerk
OBC	Wippzylinder
PCA	Hauptkomponentenanalyse
VF	Vorhersagefehler
VKM	Verbrennungskraftmaschine
VS	Ventilsektion

## Lateinische Symbole

Symbol	Bedeutung	Einheit
A	Fläche	m <sup>2</sup>
F	Kraft	N
f	allgemeine mathematische Funktion	-
l	Länge	m
m	Masse	kg
I	Ventilstrom	mA
II	Einheits-Matrix	-
J	Jacoby-Matrix	m
J <sup>+</sup>	Moore-Penrose Pseudo-Inverse	-
J <sub>W</sub> <sup>+</sup>	gewichtet Pseudo-Inverse	-
p	Druck	bar
Q	Volumenstrom	l/min
W	Gewichtungsmatrix	-
y	Effektorraum	m
x	Zylinderauslenkung	m
$\dot{x}$	Zylindergeschwindigkeit	m/s
r	Radiale Position der Greiferspitze	m
$\dot{r}$	Radiale Geschwindigkeit der Greiferspitze	m/s
z	Vertikale Position der Greiferspitze	m
$\dot{z}$	Vertikale Geschwindigkeit der Greiferspitze	m/s

## Griechische Symbole

Symbol	Bedeutung	Einheit
$\theta$	Gelenkraum	-
$\theta_i$	Gelenkauslenkung	°, m
$\dot{\theta}_i$	Gelenkgeschwindigkeit	m/s, °/s

# 1 Einleitung

**Motivation** Die Waldfläche Deutschlands weist mit 11,4 Millionen Hektar in etwa ein Drittel des Flächenanteils der Bundesrepublik auf [13]. Der Rohstoff Holz steht dabei vor allem als nachhaltiges Baumaterial im Fokus des Bau- und Zellstoffgewerbes, während er zeitgleich als klimaneutrale, regenerative Energiequelle mit dem Vorteil einer wetterunabhängigen Grundlastversorgung genutzt werden kann. Deutschlands Wälder werden zu ebendieser Rohstoffgewinnung nachhaltig bewirtschaftet, indem die jährliche Holznutzung deutlich unter dem Zuwachs von 121,6 Millionen Kubikmeter liegt. Unter Einbezug des natürlichen Absterbens von Bäumen werden 13% des Zuwachses direkt für den Vorratsaufbau genutzt [13]. Bei einem Holzeinschlag wird häufig das Cut-to-Length - Verfahren angewendet. In diesem vollmechanisierten Holzernteverfahren fällt ein Harvester die Bäume und schneidet sie je nach Stammqualität auf eine bestimmte Länge. Anschließend lädt ein Forwarder die Stämme auf und rückt sie vom Einschlagsgebiet zu einer Forststraße. 2020 wurden 80,4 Millionen Kubikmeter Holz eingeschlagen, wobei 75 % der Einschlagsmenge aus Kalamitätsholz bestand [14].

Besonders bei Borkenkäferbefall muss das Kalamitätsholz in kürzester Zeit aus der Einschlagsfläche transportiert werden, um eine weitere Ausbreitung der Schädlinge durch den Befall gesunder Bäume zu vermeiden. Zeitgleich verringern sich durch den Klimawandel die Perioden mit Bodenfrost, in denen sensible Einschlagsflächen bodenschonend befahren werden können [49]. Die daraus resultierenden Spitzen in der Rückemenge müssen durch längere Arbeitszeit, Aushilfsarbeiter oder einen Mehrschichtbetrieb kompensiert werden [53, 44, 12, 21]. Die Situation wird durch eine hohe Mit-

arbeiterfluktuation bei den Forstbetrieben und ein gleichzeitig steigendes Durchschnittsalter der Maschinenbediener verschärft, was aktuell und auch zukünftig zu einem Fachkräftemangel führt [105, 118].

Diese Effekte resultieren darin, dass vermehrt neue, ungeübte und fachfremde Bediener die Aufgabe des Rückens übernehmen müssen. Aufgrund der komplexen Arbeitsumgebung in der Forstwirtschaft dauert die Einarbeitung eines neuen Maschinenbedieners im Durchschnitt 9 Monate [15, 97]. In dieser Zeit weist der Bediener eine verringerte Produktivität auf. Der Mangel an erfahrenen Bedienern führt daher zu einem wirtschaftlichen Defizit in der Forstbranche.

**Zielsetzung** Die vorliegende Arbeit setzt genau an diesem Punkt an. Ziel der Arbeit ist die Entwicklung eines Assistenzsystems für einen teilautomatisierten Ladeprozess bei Forwardern, um die Effizienz von ungeübten Bedienern hinsichtlich Energiebedarf und Produktivität zu steigern. Dies ist ein konsequenter Ansatz zur Unterstützung des Bedieners, da Ladeprozesse den höchsten Komplexitätsgrad und den größten Zeitanteil bei den Arbeitsaufgaben aufweisen [78].

Die Vielzahl der für einen teilautomatisierten Ladeprozess benötigten Software-Komponenten führt zu einer komplexen Herausforderung bei der Entwicklung des Assistenzsystems. Der Anspruch an dieses System ist die sichere und zuverlässige Funktion unter realen Arbeitsbedingungen, wofür es auf einem Versuchsträger implementiert wird. Hierfür wird nach einer literaturbasierten Aufarbeitung und Bewertung des aktuellen Standes der Technik und Wissenschaft der Forschungsbedarf abgeleitet, ein methodisches Vorgehen für die Entwicklung des Assistenzsystems erarbeitet und dessen grundlegende Architektur definiert. Ein Bestandteil des Assistenzsystems ist die Erkennung der zu ladenden Stämme, was mit Methoden des Maschinellen Sehens erreicht wird. Die aus der Objekterkennung resultierende Stammposition wird an einen Zustandsautomaten weitergeleitet, welcher die Kranbewegung zum Stamm hin sowie den Greifprozess dessen

---

automatisch ausführt. Dabei wird eine Kranspitzensteuerung entwickelt, welche das im Versuchsträger integrierte innovative Hydrauliksystem zur Energieregeneration berücksichtigt. Basierend auf Messungen wird zum einen die Funktionalität des Assistenzsystems verifiziert, zum anderen dessen Auswirkungen auf die Effizienz ungeübter Bediener untersucht. Hierzu kann eine im Rahmen dieser Arbeit entwickelte, datenbasierte Nutzlastbestimmung verwendet werden.

In [30, 31, 32, 33, 34, 35] wurden bereits Teilergebnisse der Arbeit veröffentlicht.



## 2 Stand der Technik und Forschung

Für die Automatisierung von Forstmaschinen ist ein Zusammenspiel verschiedener Komponenten notwendig. Die hier vorliegende Arbeit fokussiert die mobile Arbeitsmaschine Forwarder, auch Rückezug genannt, deren Arbeitsaufgabe im Holzernteprozess und der dafür notwendige Arbeitsantrieb nachfolgend beschrieben werden. Darauf aufbauend wird die Automatisierung der Arbeitsaufgabe durch Assistenzsysteme thematisiert, wobei die Kranbewegung einschließlich einer Kranspitzensteuerung im Vordergrund steht. Zudem wird auf die wesentlichen Grundlagen der Objekterkennung basierend auf künstlicher Intelligenz eingegangen und aktuelle Anwendungen in der Forst- und Landwirtschaft dargestellt.

### 2.1 Forstmaschinen als mobile Arbeitsmaschinen

**Arbeitsprozesse** In vollmechanisierten Holzernteprozessen zur Bereitstellung von Industrie- und Kurzholz wird die Maschinenkombination aus Harvester und Forwarder verwendet. Im Holzeinschlag mittels des Cut-to-Lenght (CTL) Prozess fällt der Harvester die Bäume, arbeitet diese auf und legt sie an der Rückegasse ab. Anschließend werden die Stämme sowie das Waldrestholz mittels des Forwarders von der Einschlagsfläche zur Forststraße gerückt und dort sortimentspezifisch zu Rundholzstapel abgeladen (Poltern). Der Zeitaufwand für Laden und Poltern einschließlich der kurzen Fahrten in der Rückegasse zum nächsten Stamm summiert sich dabei auf bis zu 85 % der Arbeitszeit auf, die restliche Zeit wird für die Fahrten zwischen Einschlagsfläche und Polterplatz benötigt. [16, 88, 78, 65]

Abbildung 2.1 stellt die Ergebnisse einer 2019 veröffentlichten Studie zur Produktivitätsanalyse neuer Forwarderbediener im CTL-Prozess dar. Hierzu werden die Produktivitätsdaten von 10 Bedienern über einen Zeitraum von 11 Monaten untersucht, wobei diese in 2 Qualifikationsklassen getrennt sind. Während in den ersten Monaten die Produktivität steigt, erreicht diese in etwa ab dem 9. Monat eine konstante Produktivität. Der charakteristische Verlauf der Lernkurve ist zwischen den beiden Qualifikationsklassen gleich, nur die absolute Produktivität ist bei der höher qualifizierten Klasse 1 größer. [15]

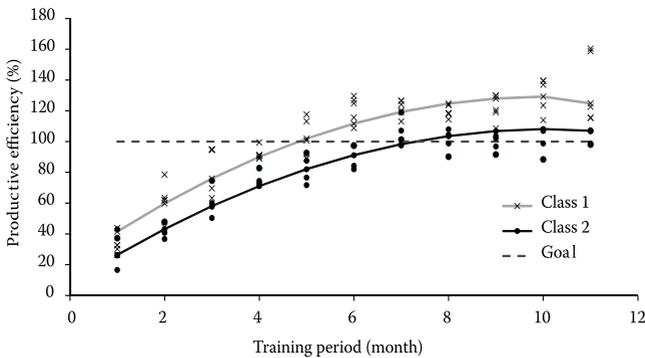


Abbildung 2.1: Produktivitätsverlauf neuer Forwarderbediener [15]

Purfürst [97] untersucht den Bedienerinfluss bei Harvestern. Hierbei zeigt sich, dass das Anlernen eines neuen Maschinenbedieners ebenfalls 9 Monate benötigt. Zudem belegt er mit einem Produktivitätsunterschied von ca. 40% zwischen erfahrenen Bedienern eine hohe Leistungsstreuung zwischen diesen. Die Lernphase für Forstmaschinenbediener beträgt somit im Durchschnitt 9 Monate, wobei vor allem in den ersten Monaten nur eine sehr geringe Produktivität vorliegt. Dies beeinflusst damit die generelle Produktivität in der Forstbranche, da aufgrund des Fachkräftemangels und einer hohen Fluktuation der Mitarbeiter bei Forstdienstleistern oft fachfremde und unerfahrene Bediener zum Einsatz kommen [118, 105].

Besonders die kognitiv herausfordernde Kranarbeit bedeutet für unerfahrene Bediener einen langwierigen Lernprozess. Dabei weist die Arbeit mit dem Kran durch das Abladen mit 25% sowie das Laden mit 45% der kompletten Arbeitszeit den höchsten Anteil an dieser auf [78]. Der Ladezyklus selbst, als Arbeitsaufgabe mit der höchsten Zeitintensität und Komplexität, kann bei Rückezügen in 4 Ladephasen untergliedert werden, vgl. Abbildung 2.2 [30, 43, 81, 25]:

- I Bewegung des Greifers vom Rungekorb zum Stamm hin
- II Greifen des Stammes
- III Bewegung des Greifers mit Stamm zum Rungekorb
- IV Positionieren und Ablegen des Stammes im Rungekorb

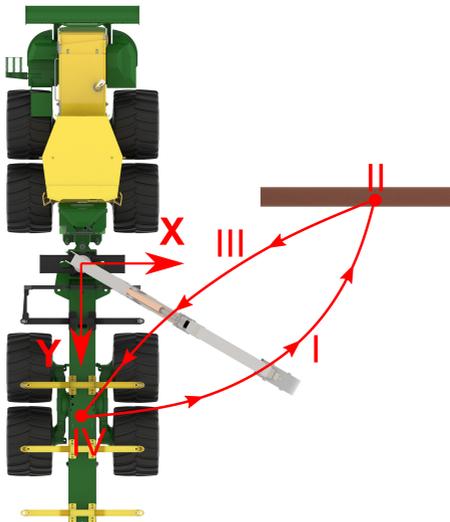


Abbildung 2.2: Unterteilung des Ladezyklus in 4 Ladephasen

**Forwarder** Nach der DIN ISO 6814 [22] ist der Forwarder als mobile, selbstfahrende Arbeitsmaschine definiert, welche Baumstämme tragend bewegt. Neben dieser Beschreibung kann vor allem der wissenschaftliche Ansatz zur Definition einer mobilen Arbeitsmaschine für die Einordnung der Maschine 'Forwarder' verwendet werden, dass zur Erfüllung einer Arbeitsaufgabe sowohl ein Fahr- als auch Arbeitsantrieb vorhanden sein muss, und diese jeweils einen signifikanten Energieanteil aufweisen [36]. Genau das trifft auf Rückzüge mit ihrem oben beschriebenen, wiederkehrenden Arbeitsprozess mit den Elementen Laden, Entladen sowie der Fahrt von und zur Einschlagsfläche zu. Durch den zeitlich hohen Anteil der Krantätigkeiten liegt ein signifikanter Energieanteil im Arbeitsantrieb vor, obgleich die Verbrennungskraftmaschine (VKM) hier im Teillastbereich betrieben wird. Dem gegenüber stehen die zeitlich kürzeren Fahraufgaben, bei welchen aber vor allem bei beladener Fahrt von der Einschlagsfläche zum Polterplatz die Leistungsgrenze der VKM erreicht wird. Dadurch weist der Fahantrieb ebenfalls einen signifikanten Energieanteil im Arbeitsprozess auf.

Ein Forwarder ist ein knickgelenktes Fahrzeug bestehend aus Vorder- und Hinterwagen. Auf dem Vorderwagen ist die VKM mit den angeflanschten Pumpen für den Fahr- und Arbeitsantrieb sowie die Kabine montiert, vgl. Abbildung 2.3. Der Hinterwagen besteht aus dem Rungenkorb, in welchen die Stämme geladen werden, sowie dem Forstkran. Der Fahantrieb ist als hydrostatisches Getriebe ausgeführt.

Der Arbeitsantrieb vereint die Arbeitskinematik bestehend aus dem Schwenkwerk, Hauptarm, Wipparm, Teleskop, Rotator und Greifer mit der Arbeitshydraulik inklusive der Hydraulikzylinder und -motoren, vgl. Abbildung 2.3. Der Forstkran als Arbeitskinematik ist nach [19] ein kinematisch redundantes System, d.h. die Anzahl an Freiheitsgraden ist größer als für eine Bewegung des Endeffektors, in diesem Fall das Teleskopauge oder des daran montierten Greifers, notwendig ist. Vereinfacht dargestellt für

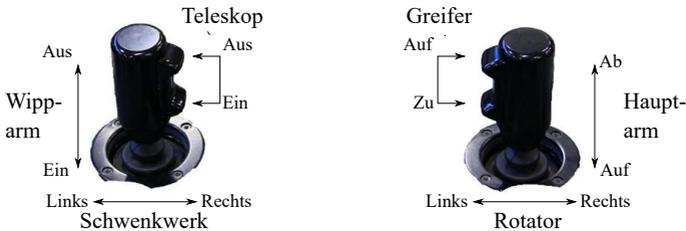
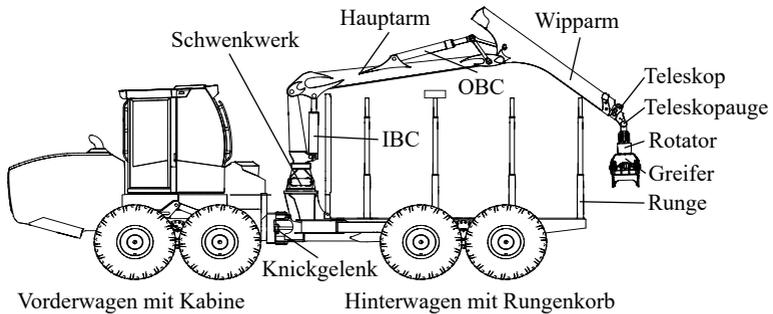


Abbildung 2.3: Forwarder und dessen Joystickbelegung nach [115]

eine zweidimensionale Bewegung besitzt der Gelenkraum bestehend aus Hauptarm, Wipparm und Teleskop die Dimension 3, während der Endeffektorraum mit einer horizontalen oder vertikalen Bewegungsrichtung des Teleskopauges die Dimension 2 aufweist. Dadurch kann auch eine Eigenbewegung der Krankinematik ausgeführt werden, ohne dass sich die Position des Teleskopauges und somit des Greifers ändert [19].

**Hydrauliksystem für den Arbeitsantrieb** Die am weitesten verbreiteten Systeme für die Arbeitshydraulik sind Konstantdruck - und Load-Sensing (LS) - Systeme [36], wobei sich vor allem letztere aufgrund der Effizienzvorteile durchgesetzt haben und bei einem Großteil der Neumaschinen verbaut werden.

Serienmäßig werden LS-Systeme mit vorgeschalteter Druckwaage verbaut [51]. Hierbei treibt die Verbrennungskraftmaschine eine hydraulische Verstellpumpe an. Der benötigte Druck und Volumenstrom stellen sich aufgrund der Geschwindigkeitsvorgaben und der auf die Verbraucher wirkenden Last ein. Jeder Verbraucher wird separat durch eine ihm zugehörige Ventilsektion angesteuert. Die Proportionalventile werden dabei elektrohydraulisch betätigt, die Ventilströme werden vom Steuergerät direkt ausgegeben. Über eine hydraulische LS-Meldekette wird der Druck des lasthöchsten Verbrauchers an die Arbeitspumpe übermittelt [36]. Die Drücke werden durch einstellbare Druckbegrenzungsventile reguliert, um die Spezifikationsbereiche der Hydraulikkomponenten einzuhalten. Die Bedienerschnittstelle ist mittels 2 elektrischer Joysticks ausgeführt. Pro Joystick können 3 Kranfunktionen angesteuert und dieser somit bewegt werden, vgl. Abbildung 2.3.

### 2.2 Assistenzsysteme bei Forstmaschinen

Bisher wurden verschiedene Assistenzsysteme für Rückzüge entwickelt, welche in drei Bereiche eingeteilt werden können. Zum einen wurden Kranspitzensteuerungen entwickelt, um den Endeffektor eines Kranes direkt im kartesischen Koordinatensystem zu bewegen und die dafür notwendige Überlagerung der Zylinderbewegungen automatisch zu berechnen. Des Weiteren wurde die Automatisierung von Prozessschritten betrachtet, vor allem eine automatisierte Kranbewegung bei Be- und Entladevorgängen. Der dritte Bereich umfasst passive Assistenzsysteme zum Produktionsmonitoring.

**Bewegung des Endeffektors** Bereits seit den 1980er Jahren ist die Steuerung des Endeffektors von kinematisch redundanten Manipulatoren Schwerpunkt vieler Forschungsarbeiten. Diese Forschungen hatten ihren

Ursprung in der Robotik und untersuchten die direkte Steuerung des Endeffektors im Allgemeinen.

Die Grundlagen zur Auflösung der Redundanz und damit zur Steuerung eines Endeffektors im kartesischen Koordinatensystem ist die Moore-Penrose Pseudo-Inverse  $\mathbb{J}^+$  [93]. Mit dieser kann basierend auf der Jacoby-Matrix  $\mathbb{J}$  des Kinematiksystems, welche aufgrund der unterschiedlichen Dimensionen von Gelenkraum  $\theta$  und Effektorraum  $y$  nicht invertierbar ist, allgemeingültig die Redundanz von Manipulatoren aufgelöst werden: [107]

$$\dot{\theta} = \mathbb{J}(\theta)^{-1} \cdot \dot{y}$$

$$\dot{\theta} = \mathbb{J}^+ \cdot \dot{y}$$

$$\mathbb{J}^+ = \mathbb{J}^T (\mathbb{J}\mathbb{J}^T)^{-1}$$

Whitney [116] löst die Redundanz von Manipulatoren am Beispiel menschlicher Prothesen unter Berücksichtigung eines Optimierungskriteriums auf, wodurch sich die gewichtet Pseudo-Inverse  $\mathbb{J}_W^+$  mit der Gewichtungsmatrix  $\mathbb{W}$  ergibt:

$$\mathbb{J}_W^+ = \mathbb{W}^{-1} \mathbb{J}^T (\mathbb{J}\mathbb{W}^{-1} \mathbb{J}^T)^{-1}$$

Hollerbach [52] knüpft an dieses Vorgehen an und untersucht im Allgemeinen die Minimierung benötigter Gelenkmomente im Nullraum der Jacoby-Matrix. Dieser Summand erweitert die Inverse Kinematik und führt zu einer Eigenbewegung der Gelenke, ohne dass sich der Endeffektor dabei bewegt:

$$\dot{\theta} = \mathbb{J}^+ \cdot \dot{y} + (\mathbb{I} - \mathbb{J}^+) \dot{y}_0$$

Lieglios nutzt diesen Nullraum, um bei einem Roboterarm eine Bewegung der Gelenke in die jeweiligen mechanischen Grenzen mittels des

Gradienten-Projektionsverfahrens zu vermeiden [71]. Chan und Dubey [17] greifen die Grundidee der Gelenkgrenzvermeidung auf und integrieren diese direkt in die gewichtete Pseudo-Inverse für einen elektrisch aktuierten, 7-achsigen Roboterarm.

Beiner und Mattila wenden diese Methoden erstmals auf einen redundanten hydraulischen Ladekran mit 3 Freiheitsgraden und Hydraulikzylinder als translatorischen Verbrauchern an, um nicht mehr die einzelnen Zylinder anzusteuern, sondern direkt die Geschwindigkeit der Kranspitze vorgeben zu können [4]. Nach einer Beschreibung der kinematischen Zusammenhänge zwischen der Kranspitze und den einzelnen Gelenkpositionen wird eine gewichtete Pseudo-Inverse genutzt, um die Redundanz aufzulösen. Für die Gewichtungsmatrix verwenden Beiner und Mattila dabei die Trägheitsmatrix des Systems, wodurch die Kranbewegung lokal hinsichtlich der minimalen kinetischen Energie optimiert wird. Dieser Ansatz erweist sich jedoch in der simulationsbasierten Evaluierung mittels eines analytischen Modells im Vergleich zu der ebenfalls untersuchten Optimierung hinsichtlich minimaler Gelenkgeschwindigkeiten als schwingungsbehafteter.

Pedersen [92] bildet einen hydraulischen Ladekran in einem Simulationsmodell ab. Dieses besteht aus einem Modell des Hydrauliksystems und einem mechanischen Mehrkörpermodell des Kranes. Zusätzlich integriert er ein Steuerungsmodul und eine 3D-Animation, womit das Modell in Echtzeit auf Eingaben reagieren kann. Mit dem Steuermodul wird eine Kranspitzensteuerung basierend auf der gewichteten Pseudo-Inverse integriert, wobei die Gelenkgrenzvermeidung nach [17] als Einträge für die Gewichtungsmatrix verwendet wird. Es zeigt sich, dass ein Bediener in Echtzeit im Simulationsmodell eine vorgegebene Trajektorie der Kranspitze mit geringen Abweichungen abfahren kann.

Die Umsetzung hin zur Kranspitzensteuerung eines Forstkranes in einer Laborumgebung beschreibt Hansson et al. [43]. Die Autoren integrieren dabei die Gelenkgrenzvermeidung in die gewichtete Pseudo-Inverse und definieren die Joystickbelegung für die Bewegungsrichtungen im kartesi-

schen Koordinatensystem, vgl. Abbildung 2.4. Kjelland [61] nutzt selbiges Prinzip zum Aufbau der Inversen Kinematik und erweitert seine Regelung, um die Auswirkungen einer oszillierenden Untergrundbewegung auf einen hydraulisch-mechanischen Demonstrator auszugleichen.

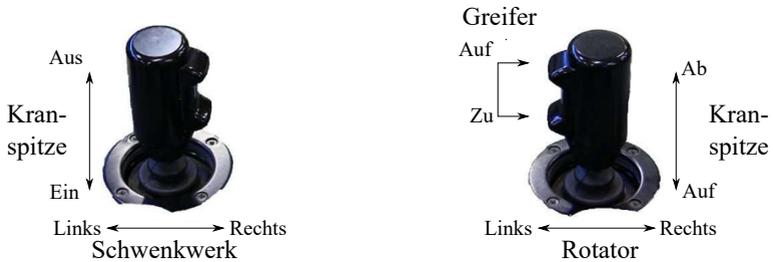


Abbildung 2.4: Joystickbelegung für die Kranspitzensteuerung nach [43]

Die Forschungsarbeiten wurden von John Deere Forestry Oy aufgegriffen und erstmals 2013 mit dem Produkt 'Intelligente Kransteuerung' kommerzialisiert [56, 55]. In den darauffolgenden Jahren entwickeln auch die weiteren Forstmaschinenhersteller wie Ponsse Oy oder Komatsu Forest AB eine für den Endkunden verfügbare Kranspitzensteuerung [94, 63]. [108] integriert in diese eine Ausgleichsbewegung der Kranspitze, damit sich die Greiferspitzen während des Schließens des Greifers auf einer horizontalen Gerade bewegen. Die Kransteuerungen sind sowohl bei den Forstmaschinenherstellern als auch in der Forschung für ein Hydrauliksystem entwickelt, in welchem jede Ventilsektion genau einen Aktuator ansteuert.

**Automatisierung** Die Automatisierung von Forstmaschinen zur Effizienz- und Produktivitätssteigerung ist ein langfristiges Ziel von Forschung und Industrie. Die Grundlage für eine autonome Maschine sind Teilautomatisierungen von einzelnen Arbeits- und Prozessschritten.

Unter anderem wird das autonome Fahren in der Einschlagsfläche untersucht. Ringdahl [99] entwickelt ein GPS-basiertes System, mit welchem ein

vorher aufgezeichneter Pfad von einem Forwarder abgefahren wird. Auf einer Kahlschlagsfläche erreicht er eine mittlere Abweichung zum vorgegebenen Pfad von 7 cm.

Ein Hauptfokus der Forschungstätigkeiten liegt in der Automatisierung und Autonomisierung der Be- und Entladevorgänge. So stellt Hansson [43] eine Steuerung vor, in welcher die Bewegung der Kranspitze zum Stamm hin und wieder zurück automatisch erfolgt. Dabei wird ein vorab geplanter Pfad, in welchem die Umfahrung eines bekannten Hindernisses integriert ist, zu einem vorher definierten Zielpunkt abgefahren. Ein flüssiger Übergang zwischen der manuellen Steuerung des Krans und der automatischen Bewegung wird erreicht, allerdings wurde das System ausschließlich in einer Indoor-Laborumgebung getestet.

Morales [81] entwickelt zeit-optimale Trajektorien für die wiederkehrenden Ladephasen I, Bewegung hin zum Stamm, und Ladephasen III, Bewegung zum Rungenkorb, welche automatisch ausgeführt werden. Diese Trajektorien werden aus Effizienzgründen im Vorfeld für feste Zielpunkte geplant und optimiert, damit sie in der Steuerung hinterlegt werden können. Die Auswahl möglicher Zielpunkte basiert auf Messdaten von realen Ladezyklen und spiegelt damit übliche Stammpositionen wider. Der Bediener kann im Anschluss die am besten passende Endposition des Krans auswählen, woraufhin von der Steuerung die für diesen Zielpunkt und abhängig von der aktuellen Kranspitzenposition beste Trajektorie aus der Datenbank ausgewählt. Eine echtzeitfähige Trajektorienoptimierung scheint aufgrund der Rechenkapazitäten nicht möglich zu sein. Westerberg [114] untersucht die Mensch-Maschine-Interaktion mit derartig vorgeplanten Trajektorien.

Ein bekannter Zielpunkt wird auch in [28] vorausgesetzt. Fodor untersucht die Teilautomatisierung des Ladeprozesses im Hinblick auf eine automatische Ausführung wiederkehrender Schwenkbewegungen, wie sie beispielsweise beim Poltern und beim Laden (Ladephasen I und III) zu finden sind. Dabei wird das Schwenken derart ausgeführt, dass ein Pendeln des Greifers am Zielpunkt vermieden wird. Da im Ladeprozess kein Zielpunkt vorgege-

ben werden kann, wird solange zu einem fiktiven Zielpunkt geschwenkt, bis vom Fahrer ein Signal zum Stoppen des Schwenkvorgangs gegeben wird. Von diesem Zeitpunkt an wird daraufhin in einer parabelförmigen Kurve die Bewegung gestoppt.

Eine komplett automatisierte Ein- und Ausfahrbewegung der Kranspitze wird mittels eines echtzeitfähigen Maschinensimulators eines Forwarders entwickelt und erprobt. Als Zielpunkt für die Ausfahrbewegung wird dabei ein fester Punkt im Abstand von etwa 4 m zur Kransäule und knapp 90° zur Fahrzeugachse definiert. Bei der Einfahrbewegung dient ein Punkt im Rungenkorb als Ziel. [25]

In [81, 74] steht bei der Optimierung der Trajektorien die zeiteffiziente Bewegungen im Fokus, während [4] die kinetische Energie für die Bewegung minimiert. Diese Ansätze reduzieren jedoch nicht die benötigte hydraulische Energie. Nurmi [86, 87] testet einen vielversprechenden Ansatz zur globalen Energieminimierung auf hydraulischer Ebene mittels Dynamischer Programmierung. Hierbei wird jedoch nach [81] ein bekannter Zielpunkt vorausgesetzt, und für eine echtzeitfähige Anwendung ein Abrufen von vorab optimierten und abgespeicherten Trajektorien vorgeschlagen [87].

Allen Publikationen ist gemein, dass die Hydraulikzylinder als Aktuatoren der untersuchten Systeme unabhängig angesteuert werden können und keine hydraulischen Abhängigkeiten zwischen diesen bestehen. Zudem wird ein bekannter Zielpunkt vorausgesetzt.

**Produktionsmonitoring und Informationssysteme** Vor allem OEMs bieten Informationssysteme zum Flottenmanagement und zur Analyse des Arbeitsfortschritts an. So können diese Systeme genutzt werden, um den Ablageort der Stämme einschließlich deren Sortiment in einer Karte der Einschlagsfläche darzustellen. Zeitgleich kann ermittelt werden, wie viele der Stämme bereits gerückt und gepoltet wurden, und das Ende der Rückarbeiten prädiziert werden. Weiterhin ist eine bediener- und fahrzeugspezifische Analyse der Produktivität, des Kraftstoffverbrauchs und der Fahr-

zeugeinstellungen möglich. Bei einer Anbringung von Kranwaagen werden Wiegevorgänge für Energie- und Industrieholz automatisch erfasst. [96, 95, 62, 57, 58, 55]

### **2.3 Auswirkungen der Teilautomatisierung von Kranbewegungen**

Manner [77] untersucht die Auswirkungen einer Kranspitzensteuerung hinsichtlich Produktivität und Lernkurve für ungeübte Bediener. Hierzu werden Versuche mit einer realen Maschine unter Laborbedingungen durchgeführt, wobei in einem wiederholenden Ablauf Stämme von zwei spezifischen Positionen in den Rungenkorb geladen werden. Hierbei stellt sich heraus, dass die Produktivität durch verkürzter Ladezeiten gesteigert werden kann. Dies wird auf den Effekt der vereinfachten Steuerung des Krans zurückgeführt. Bei der Lernkurve zeigt sich jedoch, dass sich der Lernprozess der Bediener durch die Verwendung der Kranspitzensteuerung nicht signifikant beschleunigt.

Durch die von Hansson [43] vorgestellte Kombination aus Kranspitzensteuerung und Automatisierung der Kranbewegung kann die Zykluszeit unerfahrener Bediener um mehr als 50 % reduziert werden. Bei erfahrenen Bedienern führt die Automatisierung zu einer erhöhten Zykluszeit. Beide Bedienergruppen berichteten, dass die Automatisierung zu einer subjektiv geringeren mentalen Beanspruchung führt.

Die signifikant geringere mentale Beanspruchung durch die teilautomatisierten Ladetätigkeiten wird durch Englund [26] in einer Maschinensimulator - Studie mittels Nahinfrarotspektroskopie (NIRS) nachgewiesen. Im Vorfeld evaluiert er den Nutzen eines teilautomatisierten Ladeprozesses durch Zeitstudien [25]. In diesen Studien laden die Probanden Stämme in einem Kahlschlagsszenario auf den Forwarder auf, wobei die Aus- und Einfahrbewegung des Kranes automatisiert ist. Dabei stellt sich heraus, dass sich bei unerfahrenen Bedienern die Zeit der Kranbewegung im Vergleich zu einer

manuellen Steuerung des Krans reduziert. Nutzen jedoch erfahrene Bediener das automatisierte System, so erhöht sich deren Zykluszeit im Vergleich zu einem manuellen Laden der Stämme.

## 2.4 Nutzlastbestimmung

Der Einsatz von Kranwaagen ermöglicht eine Massenermittlung während des Be- und Entladens und kann somit zur Erfassung der Produktivität und zur weiteren Logistikplanung verwendet werden. Stand der Technik sind kommerziell erhältliche Kranwaagen, welche optional zwischen Teleskopauge und Greifer montiert werden können, vgl. Abbildung 2.5 links, und entweder als mechanische oder hydraulische Kraftaufnehmer realisiert sind [96, 63].



Abbildung 2.5: Einfluss einer zwischen Teleskopauge und Rotator montierten Kranwaage: Links mit Kranwaage, Rechts ohne Kranwaage

Dabei verändert sich jedoch die Krankinematik negativ, da der vergrößerte Schwerpunktsabstand der Greifermitte zum Teleskopauge zu höheren Pendelbewegungen des Greifers führen kann, vgl. Abbildung 2.5. Mit einer

Kranwaage kann im dynamischen Ladevorgang, welcher gleichmäßig und flüssig ausgeführt wird, die Greiferladung vermessen werden, wobei sich hier die Genauigkeit im Vergleich zu einer statischen Messung signifikant verringert [64, 117]. In Zusammenhang mit unterbrochenen Ladeprozessen für statische, exakte Vermessungen führt dies zu einer signifikant verringerten Produktivität bei Be- und Entladeprozessen.

Mehrere Forschungsprojekte untersuchen eine Nutzlastbestimmung in Radladern oder Frontladern, wobei die Fahrzeuge als mechanische Mehrkörpermodelle abgebildet sind. Basierend auf diesen, und unter Modellierung von Reibkräften, wird die Masse in der Schaufel bestimmt. [112, 5, 123, 113] Die Güte der Gewichtsbestimmung korreliert jedoch sehr stark mit dem Detaillierungsgrad der Modelle. Aufgrund von auf empirischen Erkenntnissen basierenden Annahmen für Modellparameter wie Bauteilverformungen, Reibung oder Leckagen und die dadurch entstehende Herausforderung, das nicht - lineare Systemverhalten der Hydraulik abzubilden, kann ein die Realität im hinreichend genauen Maße widerspiegelndes Model nur mit äußerst hohem Aufwand bestimmt werden.[28, 29]

Savia [104] entwickelt Neuronale Netze für einen Radlader zur Bestimmung des Schaufelinhaltes. Dabei werden die Eingangsdaten für das neuronale Netzwerk, bspw. Druck und Position des Hubzylinders, zuerst mittels eines Kalman-Filters vorverarbeitet. Das verwendete neuronale Netzwerk besitzt eine verdeckte Schicht mit 9 Neuronen. Hiermit wurde in seinen Versuchen ein relativer Fehler von  $\pm 5 \%$  erreicht. Aufgrund einer geringeren Anzahl an Freiheitsgraden, einhergehend mit einer reduzierten Komplexität im Hydrauliksystem, und des variablen Massenschwerpunktes sind die Netzarchitekturen jedoch nicht auf Forstkräne übertragbar.

Die angeführten Forschungsansätze vereinen die Betrachtung einer Kinematik mit einer geringen Anzahl an Freiheitsgraden. Durch die hohe Komplexität eines Forstkranes mit der dreifachen Anzahl an Freiheitsgraden, welche alle reibungsbehaftet sind, ist die Erstellung von mechanischen Ersatzsystemen mit dem Ziel der Gewichtsbestimmung herausfordernd.

## 2.5 Umfelderkennung

**Objekterkennung basierend auf künstlicher Intelligenz** Mittels Neuronaler Netzwerke (NN) ist eine Bildverarbeitung basierend auf künstlicher Intelligenz möglich. Es werden verschiedene Aufgaben bei der Bildverarbeitung unterschieden. Bei der semantischen Segmentierung des Bildes wird jeder Pixel entweder einer spezifischen Klasse oder dem Hintergrund zugeordnet, vgl. Abbildung 2.6 links. Darauf aufbauend kann eine Klassifizierung vorgenommen werden, durch welche über Begrenzungsboxen (Bounding Boxes) die Lokalisierung von Objekten vorgenommen wird. Durch die Objekterkennung werden verschiedene Objekte unterschieden, auch wenn diese zur selben Klasse gehören. Die Aufgabe mit der höchsten Komplexität in der Bildverarbeitung stellt die Instanzsegmentierung dar. Bei dieser müssen zusätzlich zur Objekterkennung die Pixel mehrerer Instanzen gleicher Klasse separiert werden, vgl. das Beispiel der zwei nebeneinander sitzenden Hunde in Abbildung 2.6 rechts.

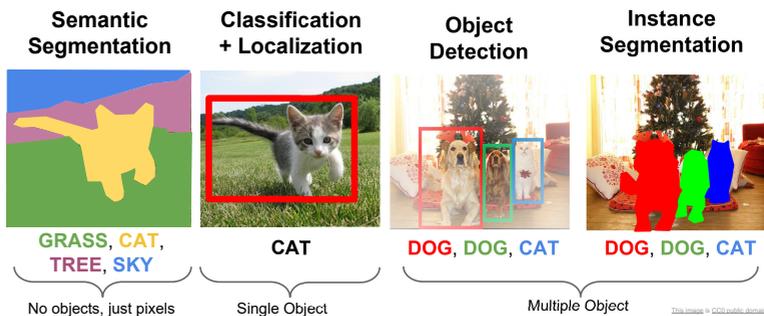


Abbildung 2.6: Maschinelles Sehen: Semantische Segmentierung, Klassifizierung, Objekterkennung, Instanz Segmentierung (links nach rechts) [69]

Die Güte der Objekterkennung wird über die *Average Precision (AP)* bestimmt, welche den Verlauf der *Precision-Recall* - Kurve widerspiegelt. *Precision* gibt dabei das Verhältnis von richtigen Detektionen zu der gesamten Anzahl an Detektionen wieder, *Recall* das Verhältnis der richtigen

Detektionen zur Anzahl an Soll - Detektionen. Dabei wird die AP für verschiedene Werte der *Intersection over Union (IoU)* angegeben, welche das Verhältnis von Überlappung zu Vereinigung der vom Netzwerk vorhergesagten Fläche der Bounding Box mit der Fläche der tatsächlichen Bounding Box wiedergibt. Die *mean Average Precision (mAP)* gibt die über alle Klassen und alle IoUs gemittelte AP wieder. [90]

*Convolutional Neural Networks (CNN)* erweisen sich als sehr geeignet für die Objekterkennung in Bildern [67]. Die Architektur von CNN besteht aus konsekutiv angeordnete Schichten, beginnend mit einer Matrix als Eingangsschicht (bspw. ein RGB-Bild) und am Ende einer Ausgabeschicht (bspw. erkanntes Objekt im Bild). Gebräuchlicher Weise wird dabei für die Architektur die sich wiederholende Abfolge von einer Faltungsschicht (Convolution) samt derer nicht-linearen Aktivierungsfunktion (ReLU) und einer Bündelschicht (Pooling - Layer) gewählt. [37]

In der Faltungsschicht findet eine mathematische Faltung der Eingangsmatrix mit dem Filterkernel statt, welcher mit einer frei wählbaren Schrittweite über diese bewegt wird. Im Anschluss an die Faltung wird die ReLU-Aktivierungsfunktion ausgeführt, bei welcher nur Werte einschließlich Null direkt weiter gegeben werden, negative Werte werden direkt zu Null gesetzt. Durch die Pooling - Layer werden die Werte einer spezifischen Matrixregion gebündelt, indem beispielsweise bei MaxPooling - Layern nur der Maximalwert dieser Matrixregion weitergegeben wird, bei AveragePooling der Mittelwert ebendieser. [37]

Eine sehr schnelle, genaue und robuste Architektur zur Erkennung von Objekten ist YOLO, wobei diese auf die Ausgabe von Bounding Boxes beschränkt ist [98]. Mit der populären Architektur von ResNet [46] ist eine Verbesserung der Genauigkeit um etwa 15 % gegenüber YOLO möglich. Solche Architekturen sind speziell für die Instanzsegmentierung verfeinert, indem neben der Erkennung von Bounding Boxes ein paralleler Zweig für die Vorhersage einer Objektmaske hinzugefügt ist, wie am Beispiel des

Mask R-CNN [47] zu sehen ist. Dadurch wird ein Objekt nicht nur innerhalb einer Bounding Box klassifiziert, es ist zudem eine Zuweisung der zum Objekt gehörigen Bildpixel möglich. Eine Neuentwicklung ist YOLACT++, eine Architektur für eine echtzeitfähige, einstufige Instanzsegmentierung [10, 11]. Basierend auf diesem einstufigen Ansatz, mit einem ResNet-101 als Backbone, ist YOLACT++ deutlich schneller als zweistufige Instanzsegmentierungsverfahren. Darüber hinaus sind die erzeugten Masken von hoher Güte, wodurch sich eine Performance beim Testen auf dem MS COCO-Datensatz [72] für das Netz von einer gemittelten Durchschnittsgenauigkeit von 34,1 mAP bei 33,5 fps Bildern pro Sekunde ergibt [11].

**Objekterkennung im Baugewerbe** Für das Baugewerbe, speziell für den Tief- und Hochbau, sind Datensätze publiziert, in welchen gelabelte Bilder von einer Vielzahl an unterschiedlichen Baustellen vorgestellt werden [121, 109, 60, 122, 120]. Darin werden, zum Teil automatisch [60], sowohl unterschiedliche Baumaschinen als auch Arbeiter bis hin auf Pixelebene klassifiziert. Bei der Evaluation der Datensätze durch Training und Test von bekannten Netzarchitekturen wie YOLOv3 oder Faster R-CNN können Genauigkeiten von ca. 96 mAP erreicht werden [121]. Eine Erklärung für diese sehr gute Performance kann in dem deutlichen Unterschied zwischen Hintergrund und zu klassifizierenden Objekt, wie beispielsweise ein Bagger in einer Baugrube, liegen.

### **Objekterkennung für land- und forstwirtschaftliche Anwendungen**

Für eine nachhaltige Landwirtschaft ist für den selektiven Einsatz von Pflanzenschutzmitteln eine Kulturpflanzen- und Unkrauterkenung notwendig. Daher wird eine auf RGB-Bildern basierende Nutzpflanze - Unkraut - Klassifikation entwickelt, die sowohl auf manuellen, wissensbasierten Merkmalen [75] als auch auf Deep Learning, insbesondere mit CNNs, beruht [75, 80, 83, 102]. Die Autoren in [76] verwenden ein *Fully Convolutional Network*, welches eine semantische Segmentierung des Bildes in Getreide und

Unkraut liefert. Eine kommerziell verfügbare Implementierung solcher Systeme wird beispielhaft von AMAZON für Spritzen angeboten [1]. In einer anderen landwirtschaftlichen Anwendung eines CNN werden anzukoppelnde Anbaugeräte als Grundlage für ein Assistenzsystem erkannt [7].

Ein früherer Ansatz, welcher künstliche Intelligenz für eine auf RGB-Bildern basierende Stammdetektion verwendet, wird von [42] durchgeführt. Dieser verwendet ein vorwärts gerichtetes Netzwerk (*Feed Forward NN*), das aus insgesamt 14 Neuronen inklusive einer verdeckten Schicht besteht. Aufgrund einer sehr kleinen Stichprobenmenge und der Beschränkung auf maximal 5 zu erkennende Stämme pro Bild ist die Interpretation der Ergebnisse jedoch schwierig. Ein neuerer Ansatz zur Erkennung von Baumstämmen verwendet *Deep Convolutional Networks* [111]. Nach dem Training einer YOLOv3 - Architektur auf der Basis von Bildern gestapelter Baumstämmen zeigen die Ergebnisse eine gute Genauigkeit. Bei der Interpretation gilt es aber zu berücksichtigen, dass die Ausgabe auf die Bounding Boxes, deren Kanten immer parallel zu denen der Bilder verlaufen, beschränkt ist. Dies entspricht nur selten der Ausrichtung der Stämme im Bild.

In der Forstwirtschaft findet eine enorme Entwicklung in Richtung Automatisierung von Maschinen und Informationssystemen statt, z.B. bei der Waldinventur. Grundlage hierfür ist, insbesondere beim Fällen als ersten Prozessschritt der Holzernte, die Kenntnis um die Position der stehenden Bäume in Bezug auf den Harvester sowie deren Dimensionen. Die dafür notwendige Erkennung von Bäumen auf Basis von 2D - Lasersensoren erfolgt im Wesentlichen in zwei Schritten: Zunächst werden die durch ein Lidar gewonnenen Punktwolkendaten geclustert, um die Position des Baumes zu erkennen. Anschließend wird der Stammdurchmesser über Triangulation oder Methoden zur Kreisannäherung geschätzt. [48, 59, 124, 100]

Ein anderer Ansatz verwendet 3D-Lasersensoren, die den Vorteil von dreidimensionalen Punktwolkendaten haben [41, 2, 110, 6, 73, 84, 70, 119, 89, 68]. Hierbei ist die Detektion von stehenden Bäumen mittels einer Hough - Transformation [2], Eigenvektoren [70, 89] oder Clustering - Algorithmen

[6] möglich. Die Autoren in [89] verwenden eine robuste Hauptkomponentenanalyse (PCA) mit vielversprechenden Ergebnissen zur Baumerkennung. Außerdem wird durch die Kombination der Hyper - Kreisfitting - Methode mit einer Kleinste - Quadrate - Schätzung eine robuste Schätzung des Baumdurchmessers durchgeführt.

Obwohl die Erkennung und Modellierung von stehenden Bäumen umfangreich erforscht wird, findet eine Erkennung von liegenden Baumstämmen nur vereinzelt statt. Die Autoren in [91] schlagen eine Baumstammerkennung inklusive einer Posen - Schätzung auf Basis einer Kamera mit strukturierten Licht (Streifenlichtscanning) vor. In den so erzeugten 3D-Daten werden Stämme durch die Suche nach rotationssymmetrischen Punktmustern erkannt. Zur Rekonstruktion von Baumstämmen wird die Rotationsachse mit Hilfe von Eigenvektoren berechnet, gefolgt von einem Kreisfitting - Algorithmus. Ein Vergleich eines derart rekonstruierten Baumstammes mit bereits vordefinierten geometrischen Modellen von Stämmen identifiziert diesen als ebensolchen, insofern sie übereinstimmen. Die Indoor - Studien beschränken sich dabei auf einen Stammabstand von bis zu 5 m, während nur bis zu 2 m eine Erfolgsquote von über 75 % möglich ist. Aufgrund der hohen Anfälligkeit für variierende Umgebungsbedingungen wie z.B. die Beleuchtung, kombiniert mit den üblichen Stammabständen von 5 bis 10 Metern im Einschlagsgebiet, scheint diese Methode für reale Arbeitsbedingungen nicht geeignet zu sein.



## **3 Forschungsbedarf und methodisches Vorgehen**

Aufbauend auf dem Stand der Technik werden in diesem Kapitel zuerst der Forschungsbedarf abgeleitet und anschließend die Forschungshypothese sowie die zu deren Beantwortung notwendigen Forschungsfragen formuliert. Anschließend wird das Entwicklungsvorgehen erläutert, mit welchem das Ziel der Arbeit erreicht werden soll.

### **3.1 Forschungsbedarf**

Die Steuerung des Endeffektors im kartesischen Koordinatensystem wurde umfangreich erforscht und erfolgreich umgesetzt. Dabei lag jedoch immer ein Hydrauliksystem zugrunde, in welchem durch die Ansteuerung einer Ventilsektion genau ein Hydraulikzylinder aktuiert wird. Ein Hydrauliksystem, bei welchem mehrere Verbraucher eines Forstkranes in direkter Geschwindigkeitsabhängigkeit zueinander stehen, wie beispielsweise bei [50] der Hub- und Wippzylinder, wurde dabei nicht berücksichtigt. Dies trifft neben der Steuerung auch auf die Ansätze zur energetischen Optimierung zu.

Die Zusammenfassung des Forschungsstandes hat aufgezeigt, dass eine Teilautomatisierung die Produktivität vor allem bei ungeübten Bedienern erhöht. Hierbei wurden mit unterschiedlichen Ansätzen Teile der Ladephase I, Ausfahrbewegung hin zum Stamm, und Ladephase III, Bewegung zum Rungenkorb, automatisiert. Bei der Ausfahrbewegung wird dabei immer ein vorab festgelegter Endpunkt angesteuert, welcher jedoch unabhängig

von der real vorliegenden Stammposition ist. Ein umfeld- und situationsangepasster Zielpunkt kann nicht definiert werden, weil kein Wissen über die Position des aktuell zu ladenden Stammes vorliegt. Dies ist einer der Gründe, warum die komplexe Aufgabe der Ladephase II, das Greifen des Stammes, noch nicht automatisiert werden konnte. Aufgrund des fehlenden, umfeldbasierten Zielpunkts ist zum aktuellen Zeitpunkt keine sinnvolle Automatisierung des Ladezyklus gegeben.

Die Grundlagen für die Objekterkennung von liegenden Stämmen in 2D-Bildern sind prinzipiell durch die Entwicklungen von *Convolutional Neural Networks* gegeben, jedoch liegt kein passender Datensatz einer forstlichen Einschlagsfläche zum Training solcher Architekturen vor. Dadurch fehlt eine pixelorientierte Segmentierung und Klassifizierung von Stämmen. Insbesondere bei Durchforstungsprozessen, welche in Europa dominieren, bietet keiner der aufgeführten Ansätze die Möglichkeit, Stämme am Boden zu erkennen und ihre Merkmale wie Stammdurchmesser, Länge oder Position zu schätzen. Die Ansätze aus der Forschung, wie Clustering-Methoden zur Positionsbestimmung von stehenden Bäumen im 3D-Raum unter Zuhilfenahme von Lasersensoren, sind aufgrund der unebenen und rauen Oberflächen des Waldbodens nicht zur Erkennung von liegenden Stämmen geeignet. Es kann somit zum aktuellen Forschungszeitpunkt keine Stamm- und somit Greifposition als Zielpunkt für eine echtzeitfähige Automatisierung des Ladeprozesses unter realen Einsatzbedingungen ermittelt werden.

Die vorliegende Arbeit soll genau diese Defizite aufgreifen und sowohl die Stammposition als den benötigten Zielpunkt für das automatische Greifen eines Stammes in der Einschlagsfläche bereitstellen, als auch die Architektur und die Algorithmen für ein echtzeitfähiges Assistenzsystem für ungeübte Bediener zur automatischen Ausführung des Ladezyklus. Hierbei werden Teile der Ladephase I, Ausfahrbewegung zum Stamm, sowie die komplette Ladephase II, Greifen des Stammes, vollautomatisch ausgeführt.

Dabei ist die aktuelle, reale Position des zu ladenden Stammes berücksichtigt, wodurch das Assistenzsystem die Informationen aus dem Umfeld verarbeitet. Zudem werden für eine nachhaltige Forstwirtschaft die energetischen Auswirkungen auf hydraulischer Ebene innerhalb eines Ladezyklus betrachtet, welche sich durch die soft- und hardwareseitige Integration eines innovativen Hydrauliksystems ergeben. Bei diesen ist eine Energieregeneration zwischen Hub- und Wipparmzylinder möglich.

Darauf basierend kann die Forschungshypothese formuliert werden, welche in dieser Arbeit verifiziert oder falsifiziert werden soll:

*Assistenzsysteme ermöglichen eine effiziente Teilautomatisierung des Ladeprozesses bei Forwardern für ungeübte Bediener.*

Zur Untersuchung der Hypothese dienen 4 Forschungsfragen, welche im Zuge dieser Arbeit beantwortet werden.

1. Gibt es ein Steuerungskonzept, welches eine Automatisierung des Greifvorgangs im Ladeprozess für einen Einzelstamm zulässt?
2. In welcher Höhe ändert sich die Produktivität eines ungeübten Bedieners durch eine Teilautomatisierung des Referenzzyklus mittels eines automatischen Greifens von Einzelstämmen?
3. In welcher Höhe ändert sich der Energiebedarf eines ungeübten Bedieners durch eine Teilautomatisierung des Referenzzyklus mittels eines automatischen Greifens von Einzelstämmen?
4. Mit welcher Genauigkeit kann die Zuladung bei Rückzügen erfasst werden?

### 3.2 Entwicklung eines Assistenzsystem zur Teilautomatisierung des Ladeprozesses

**Architektur** Die Architektur des Assistenzsystems *AutoLoad* zur Bedienerunterstützung beim Ladeprozess ist in Abbildung 3.1 gezeigt. Das Assistenzsystem wird durch die zwei Faktoren Umfeld und Forstmaschine beeinflusst und wirkt durch ausgegebene Steuersignale direkt auf letztere ein.

Das Assistenzsystem selbst besteht zu einem aus dem Informationsmodul zur Objekterkennung. Darin werden mittels Methoden des Maschinellen Sehens 2D-RGB-Bilder des Umfelds semantisch segmentiert und dieses Ergebnis im Anschluss auf die 3D-Daten übertragen. Dadurch entsteht eine semantisch segmentierte Punktwolke, aus welcher zur weiteren Verarbeitung nur die Punkte betrachtet werden, welche zu einem Stamm gehören. Als Ergebnis werden die vier Stammattribute Stammlänge, -durchmesser, -position und -ausrichtung an den zweiten Bestandteil des Assistenzsystems, die Steuermodule, übergeben. Zusammen mit dem Input der aktuellen Sensordaten des Forwarders wird der benötigte Geschwindigkeitsvektor des Greifers zum Stamm hin fortlaufend berechnet. Mit Hilfe der Kranspitzensteuerung werden die Steuersignale für die einzelnen hydraulischen Verbraucher berechnet, damit sich der Geschwindigkeitsvektor einstellt. Am Greifpunkt angekommen, wird das automatische Schließen des Greifers gestartet, bis der Stamm vollständig umschlossen ist. Die notwendigen Steuersignale werden dabei an den Ventilblock der Forstmaschinen weitergegeben, wodurch der Kran aktuiert wird.

Durch die Trennung in Informations- und Steuermodule ist ein modularer Aufbau der Architektur gegeben, wodurch die benötigte Rechenkapazität auf mehrere Steuergeräte aufgeteilt werden kann. Dadurch wäre auch bei einem Ausfall der Informationsmodule die sicherheitsrelevante Steuerung des Kranes weiterhin möglich.

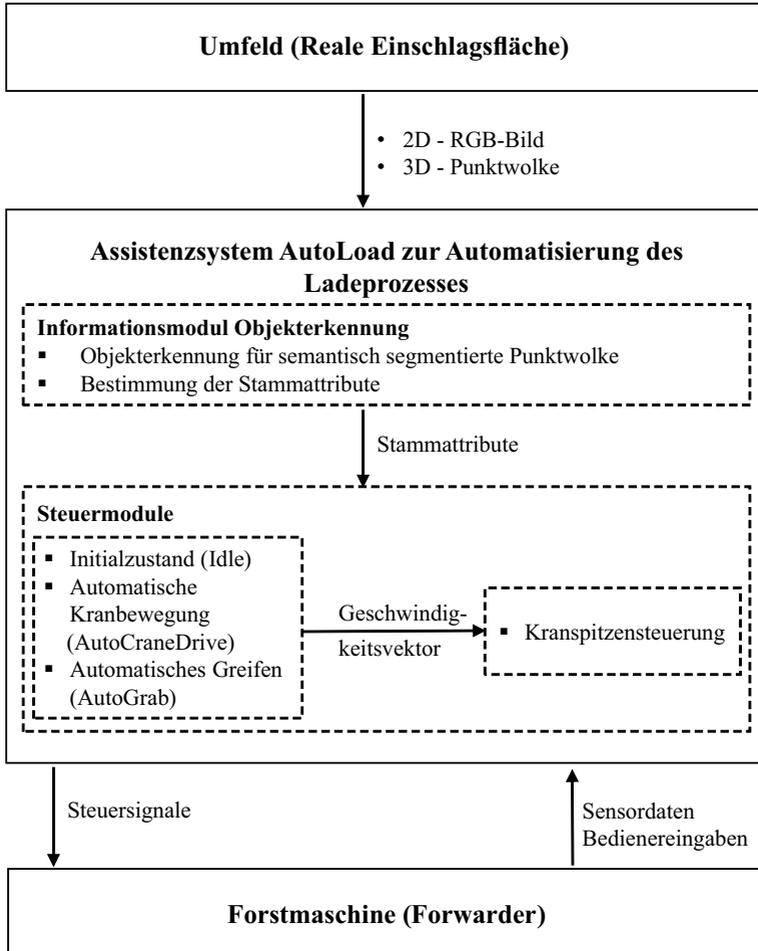


Abbildung 3.1: Architektur des Assistenzsystems AutoLoad

**Entwicklungsvorgehen** Das methodische Vorgehen bei der Entwicklung und Evaluation des Assistenzsystems unterteilt sich in 4 Phasen und strukturiert dadurch auch inhaltlich die vorliegende Arbeit.

- Phase 1: Architekturentwurf

In Kapitel 3 wurde aufbauend auf dem Forschungsbedarf die Architektur für ein Assistenzsystem zur Teilautomatisierung des Ladeprozesses erstellt. Der modulare Aufbau dieser Steuerungsarchitektur wird hardwareseitig in Phase 2 und softwareseitig in Phase 3 berücksichtigt.

- Phase 2: Aufbau des Versuchsträgers als Entwicklungsumgebung

In der zweiten Phase wird innerhalb des Kapitels 4 die Entwicklungsumgebung hardwareseitig beschrieben. Anschließend wird die Funktionalität des Versuchsträgers erprobt und verifiziert. Dies setzt den Fokus im Speziellen auf die Hydraulik des Forstkrans einschließlich des Potentials zur Energieregeneration sowie der verbauten Sensorik. Zur reproduzierbaren Evaluation der Effizienz wird ein Referenzzyklus für die Laborumgebung definiert, welcher sich aus Messdaten von realen Ladezyklen ableitet.

- Phase 3: Entwicklung des Assistenzsystems

Die Informationsmodule für das Assistenzsystem werden in Kapitel 5 als erster Entwicklungsschritt beschrieben. Ein Fokus liegt hier auf der Objekterkennung, damit der Zielpunkt für die automatisierte Bewegung bestimmt werden kann. Die Implementation einer datenbasierten Kranwaage liefert die Basis für eine Produktivitätsbewertung im realen Forsteinsatz. Aufbauend auf der Stammerkennung wird in Kapitel 6 das Assistenzsystem für einen automatisierten Lade-

und Greifprozess entwickelt. Durch die Verwendung eines Zustandsautomaten werden die notwendigen Aufgaben zur Automatisierung strukturiert. Durch die entwickelte Kranspitzensteuerung, welche die Grundlage zur Automatisierung bildet, wird die Bewegung des Greifers ausgeführt.

- Phase 4: Evaluation

Das Assistenzsystem wird in Kapitel 7 mittels des definierten Referenzzyklus hinsichtlich der Änderung des Energiebedarfs und der Produktivität bei ungeübten Bedienern evaluiert. Zusätzlich wird das Potential zur Energiereduktion durch das Hydrauliksystem mit gekoppelten Hub- und Wippzylinder unter Nutzung der dafür entwickelten Kranspitzensteuerung untersucht. Mit einer Analyse der Genauigkeit der datenbasierten Kranwaage wird eine Produktivitätsbewertung von Bedienern im realen Einsatz vorgeschlagen.



## **4 Versuchsträger und Entwicklungsumgebung**

Die Entwicklung mitsamt der Erprobung des Assistenzsystems erfolgt in einer realen Entwicklungsumgebung mit der Forstmaschine Forwarder. Diese wird dafür sensorisch und messtechnisch ausgerüstet. Für den Versuchsträger wird eine innovative Arbeitshydraulik samt Hydro-Transformator zur Energieregeneration entwickelt und in diesen integriert. Zum Testen des zu entwickelnden Assistenzsystems einschließlich der neuen Arbeitshydraulik wird ein Referenzzyklus für die Arbeitsaufgabe Laden definiert.

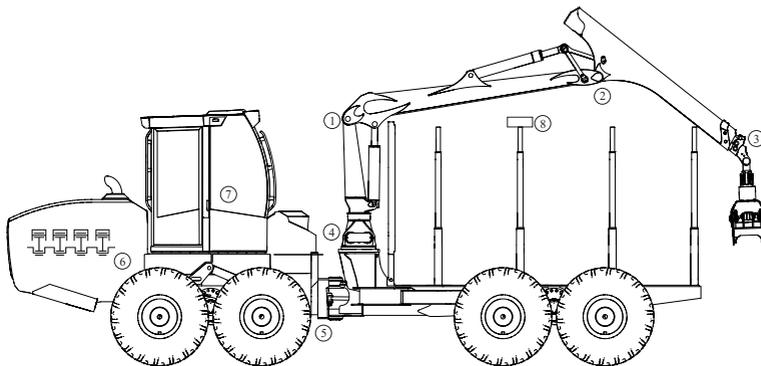
### **4.1 Arbeitsantrieb einschließlich seiner Messtechnik**

#### **4.1.1 Forstkran als Arbeitskinematik**

Der auf dem Demonstrator verbaute Forstkran ist ein Prototyp, bei welchem die Kranreichweite maximal 11 m beträgt. Für die Positionsbestimmung der Kran Spitze, im Speziellen des Teleskopauges, sind die rotatorischen Gelenke von Schwenkwerk, Haupt- und Wipparm mit Drehgebern ausgestattet, vgl. Abbildung 4.1. Diese weisen eine Auflösung von  $0,088^\circ$  auf. Die Position des Teleskops wird mittels eines Seilzugsensor mit einer Auflösung von 1 mm ermittelt. Generell sind Sensoren für die Gelenke serienmäßig installiert und werden von der Hauptsteuerung eingelesen, da sie als Grundlage für eine serienmäßig angebotene Kranspitzensteuerung benötigt werden.

Die maschinenspezifischen Signale wie Drehzahl der VKM, die Joystick-signale als Bedieneingabe sowie die in der Hydraulik verbaute Sensorik,

vgl. Abbildung 4.2, werden ebenfalls von der Hauptsteuerung eingelesen. Die Messdatenaufnahme erfolgt zeitkongruent mit einer Frequenz von 50 Hz. Zusätzlich ist auf einer Runge eine Stereokamera Typ RealSense D415 angebracht. Mit dieser kann der Ladebereich des Forwarders visuell erfasst werden, wodurch zum einen ein 2D-RGB-Bild dieser vorhanden ist, zum anderen eine 3D-Punktwolke. Dieser Kameratyp ist auch unter den Begriffen Tiefenkamera oder RGB-D-Kamera bekannt.



Nr.	Signal	Nr.	Signal
1	Winkel Hauptarm $\Theta_1$	5	Lenkwinkel
2	Winkel Wipparm $\Theta_2$	6	Drehzahl VKM
3	Teleskoplänge $\Theta_3$	7	Bedienervorgaben
4	Winkel Schwenkwerk $\Theta_4$	8	Stereo-Kamera

Abbildung 4.1: Allgemeine Messtechnik auf dem Versuchsträger Forwarder

### 4.1.2 Hydrauliksysteme für den Forstkran

Serienmäßig ist auf der Maschine ein LS-Hydrauliksystem mit vorgeschalteten Druckwagen verbaut, bei welchem jeder Verbraucher separat mittels einer ihm zugehörigen Ventilsektion angesteuert wird. Innerhalb dieser Arbeit wird neben dem bereits verbauten Seriensystem ein innovatives Hydrauliksystem entwickelt und getestet sowie beide energetisch miteinander verglichen.

**Hydrauliksystem mit Hydro-Transformator** Abbildung 4.2 zeigt den vereinfachten hydraulischen Schaltplan des Hydro-Transformator (HT) - Systems, welches basierend auf [50] entwickelt wurde. Der HT ist durch zwei miteinander verflanschte Konstanttriebwerke ausgeführt, wodurch sich eine feste Übersetzung ergibt. Er verbindet die Bodenseite des Hubzylinders (IBC) mit der Stangenseite des Wippzylinders (OBC), wodurch die beiden Zylinder hydraulisch gekoppelt sind. Dies ermöglicht eine Leistungsübertragung zwischen den Zylindern, sodass eine Energieregeneration im Hydrauliksystem möglich ist.

Es wird prinzipiell keine separate Ansteuerung für den HT benötigt, diese erfolgt automatisch durch die Funktion des Wipparms: Durch Betätigen der Ventilsektion (VS) 1 wird der OBC angesteuert, wodurch sich aufgrund des HT und seiner Drehzahl automatisch der IBC mitbewegt. Für ein ausreichendes Nachsaugverhalten des HTs auf der IBC-Seite ist die Tankleitung vorgespannt. Die vom Bediener geforderte Bewegung des Hauptarms wird durch Betätigen der VS 2 eingestellt. Dadurch kann weiterhin eine unabhängige Bewegung von Haupt- und Wipparm erreicht werden, obwohl die dazugehörigen Zylinder miteinander gekoppelt sind. [35]

Das Funktionsprinzip der Energiereduktion durch Energieregeneration wird beispielhaft an der zyklisch wiederkehrenden Ausfahrbewegung des Greifers zum Stamm hin erläutert. Die sich daraus ergebenden Bewegungsrichtungen der einzelnen Komponenten sind mit roten Pfeilen in Abbildung 4.3 dargestellt. In der ersten Phase des Ladeprozesses wird der Greifer linear zum Stamm hinab bewegt. Dies resultiert in einem Absenken des Hauptarms, einhergehend mit einem Einfahren des IBC. Um die Streckbewegung des Kranes zu erreichen wird simultan der Wipparm angehoben, welches in einem Einfahren des OBC resultiert. Bei Bedarf kann das Teleskop zusätzlich mit ausgefahren werden.

Die Grundidee nach [50] ist, die durch das Absenken des Hauptarms nutzbare Energie zu verwenden, um das Anheben des Wipparms zu unterstützen.

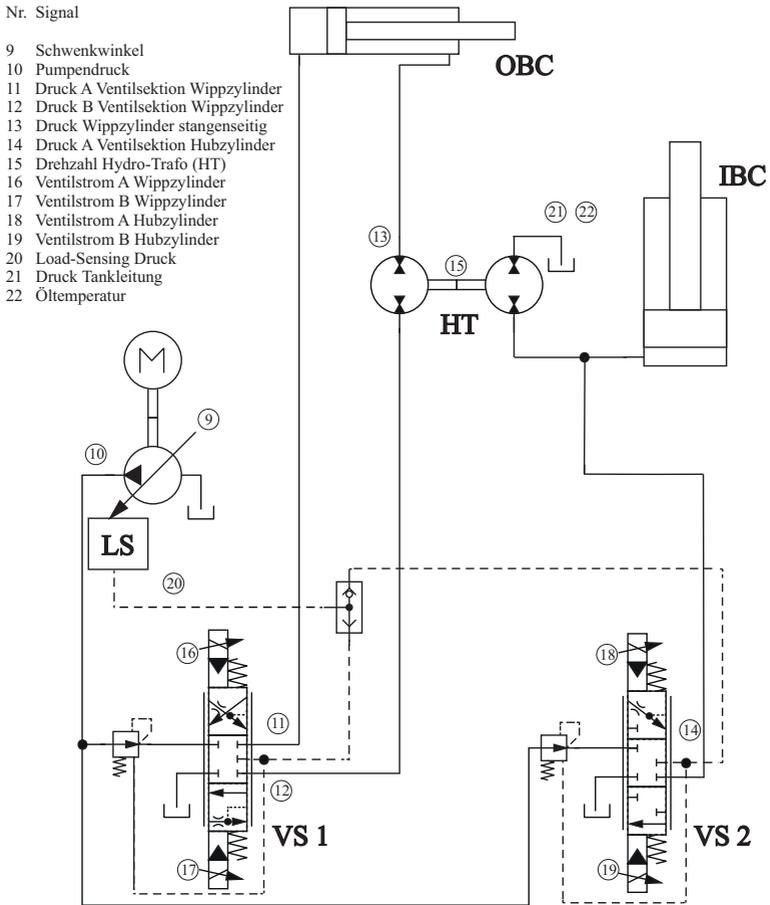


Abbildung 4.2: Schaltplan des HT-Systems einschließlich Sensorsignale nach [50]

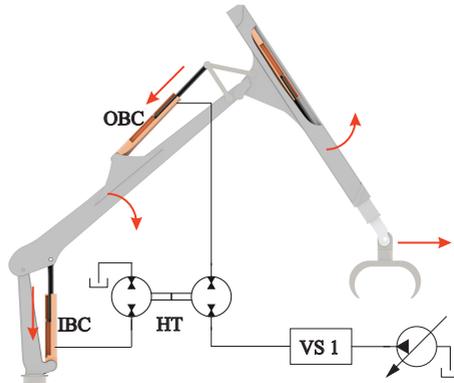


Abbildung 4.3: Bewegungsablauf bei der Energieregeneration

Dies ist durch die Kopplung von Hub- und Wippzylinder möglich, wodurch eine Energieregeneration zwischen den beiden Zylindern stattfindet. Da sowohl unterschiedliche Kräfte auf die Zylinder wirken, als auch divergierende Zylinderbaumaße verwendet werden, wird zur Leistungsübertragung eine Volumenstrom- und Druckanpassung zwischen IBC und OBC benötigt. Hierfür wird durch den HT die hydraulische Leistung als Produkt aus Volumenstrom und Druckdifferenz vom einfahrenden IBC hin zum OBC transferiert.

Selbiges Prinzip der Energieregeneration findet auch bei der Ladephase III, der Einfahrbewegung der Kranspitze zum Rungenkorb hin, Anwendung. Hierbei muss der Hauptarm angehoben (Ausfahren von IBC) und Wipparm abgesenkt (Ausfahren von OBC) werden. Da bei dieser Bewegung auf den Wippzylinder eine aktive Last wirkt, kann die Energie des ausfahrenden Wippzylinders genutzt werden, um mittels des Hydro-Transformators den Hauptarm anzuheben.

Eine detaillierte Erläuterung des Hydrauliksystems ist [35] zu entnehmen.

## 4.2 Versuchsumgebungen

Für die Entwicklung des Assistenzsystems werden verschiedene Versuchsumgebungen verwendet, um spezifische Entwicklungsziele zu erreichen.

**Reproduzierbare Laborumgebung** Als reproduzierbare Laborumgebungen werden ebene Flächen mit einheitlichem Untergrund definiert. Dies können sowohl gemähte Wiesenflächen oder aufgeschotterte Plätze ohne Hangneigung und Fremdobjekte wie Menschen oder Maschinen sein. Durch diese Vereinheitlichung ist sichergestellt, dass darauf durchgeführte Versuche reproduzierbar sind und nicht von äußeren Störgrößen beeinflusst werden. Zudem werden Versuche in der Laborumgebung ausschließlich durchgeführt, wenn der Forwarder samt VKM und Hydrauliksystem seine Betriebstemperatur erreicht hat.

Mit der einheitlichen Fläche kann bei den Assistenzsystem betreffenden Versuchen die Objekterkennung unabhängig von Störgrößen erfolgen. Zeitgleich kann damit der Fokus auf die Untersuchung der Steuerungsalgorithmen (siehe Forschungsfrage 1) für die automatische Kranbewegung und das automatische Greifen des Stammes gelegt werden.

**Forstliche Einschlagsfläche** Bei der Aufnahme von Trainingsdaten zur Objekterkennung wurden Fichtenbestände priorisiert, da der Fokus der Entwicklung des Assistenzsystems auf der Anwendung in der Durchforstung liegt. Alle Aufnahmen wurden unter realen Bedingungen von einem geübten Fahrer durchgeführt, indem mit dem Versuchsträger auf aktiven Einschlagsflächen die im Vorfeld durch Forstdienstleister mit Harvestern geschnittenen Stämme gerückt wurden. Es handelte sich dabei um Zweitudurchforstungen oder Endnutzungen. Zusätzlich wurden Versuche mit langjährigen, professionellen Bedienern durchgeführt, um Messdaten für die Definition eines Referenzzyklus aufzunehmen. Tabelle 4.1 fasst die wichtigsten Messungen zusammen, welche im Rahmen dieser Arbeit durchgeführt wurden.

Tabelle 4.1: Übersicht der Datenaufnahme

Nr.	Beschreibung	Umgebung
1	Daten für Referenzzyklus	Forst: Eibenstock
2	Trainingsdaten zur Bilderkennung	Forst: Wolfegg
3	Trainingsdaten zur Bilderkennung	Forst: Bremelau
4	Trainingsdaten zur Bilderkennung	Forst: Adelsried
5	Trainingsdaten zur Bilderkennung	Labor: Karlsruhe
6	Trainingsdaten für datenbasierte Stammwaage	Labor: Karlsruhe
7	Bestimmung Sensortotweg	Labor: Wolfegg
8	Funktionstest Kranspitzensteuerung	Labor: Wolfegg
9	Konventionelle Kransteuerung: Bediener 1 & 2	Labor: Wolfegg
10	Assistenzsystem AutoLoad: Bediener 1 & 2	Labor: Wolfegg
11	Einfluss HT-System auf Energiebedarf	Labor: Wolfegg
12	Assistenzsystem AutoLoad: Realeinsatz	Forst: Wolfegg

### 4.3 Definition eines Referenzzyklus für die Arbeitsaufgabe Laden

Für eine standardisierte Versuchsumgebung und Arbeitsaufgabe wird ein reproduzierbarer Referenzzyklus definiert, welcher einen die Realität widerspiegelnden Ladeprozess eines Forwarders darstellt. Der Referenzzyklus entspricht damit einem Arbeitsspiel nach DIN ISO 9245 [23] und ist kein Lastzyklus. Standardisierte Lastzyklen für die Arbeitsaufgabe Laden wurden in Anlehnung an [20] vom Autor der vorliegenden Arbeit in [30] vorgestellt und sind konsistent mit [82].

Durch die Auswertung von Messdaten (vgl. Tabelle 4.1) unter realen Arbeitsbedingungen in einer Durchforstung kann der von den Bedienern bevorzugte Greifpunkt des Stammes, relativ zur Krandrehachse, ermittelt werden. Abbildung 4.4 stellt die Häufigkeit des Greifens innerhalb eines Raster-

segments, mit der Kransäule als Ursprung, dar. Die Verteilung zeigt klar die von den Bedienern präferierte Position des Forwarders beim Ladeprozess, welche rechtwinklig zu den Stämmen auf Höhe der Kransäule ist. Diese Position ermöglicht ihnen durch den Überblick über die Maschine, die zu ladenden Stämme und die Umgebung einen optimalen Ladeprozess. Die Ergebnisse der Messungen decken sich mit den Veröffentlichungen von [81, 82], welche den Zielpunkt von Greifprozessen untersuchen.

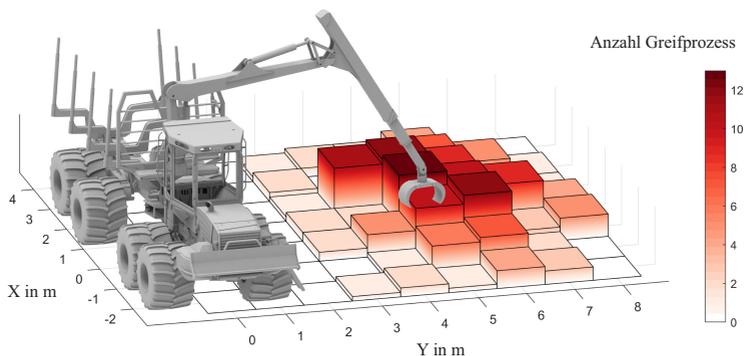


Abbildung 4.4: Histogramm zur Verteilung und Anzahl der Greifposition

Ausgehend von der in Abbildung 4.4 beschriebenen Verteilung wird der nachfolgende Prozess der Arbeitsaufgabe Laden als Referenzzyklus definiert, mit welchem die Effizienz von verschiedenen Systemkonfigurationen eines Forwarders evaluiert werden kann:

Ein Stamm (Länge 4 m - 5 m, Masse 300 kg) wird rechtwinklig zum Fahrzeug auf Höhe der Kransäule positioniert, vgl. Abbildung 4.5. Der Abstand zwischen der Krandrehachse und der Stammmitte beträgt hierbei in Übereinstimmung mit [82] 5 m. Der Greifer befindet sich zu Beginn des Referenzzyklus in der Mitte des Rungenkorbes, welcher leer ist. Nun lädt der Bediener den positionierten Baumstamm in den Rungenkorb und legt diesen dort mittig ab. Dadurch werden alle 4 Ladephasen durchgeführt.

Durch den Referenzzyklus ist ein standardisierter Zyklus für die Ausführung der Arbeitsaufgabe Laden definiert, welcher in ähnlicher Form auch von [77] zur Messung von reproduzierbaren Ladezyklen verwendet wird.

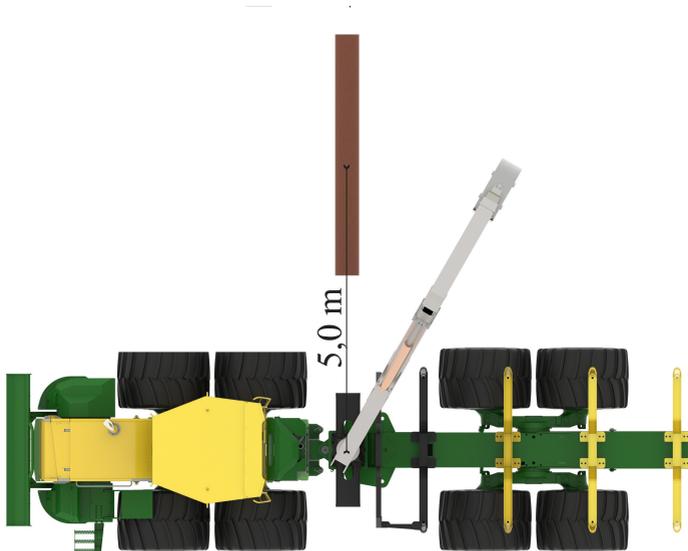


Abbildung 4.5: Positionierung des Stammes für den Referenzzyklus



## 5 Informationsmodule

Das zur Produktivitätsanalyse benötigte Informationsmodul der datenbasierten Kranwaage wird im ersten Teil des Kapitels dargestellt. Im zweiten Teil erfolgt die Beschreibung der Objekterkennung, durch welche Stämme in der forstlichen Einschlagsfläche erkannt werden und damit Zielpunkte für die Automatisierung des Ladeprozesses gegeben sind.

### 5.1 Datenbasierte Kranwaage im Ladeprozess

Mit der datenbasierten Methode wird ein dynamischer Wiegeprozess einschließlich anschließender Datenverarbeitung realisiert, mit welchem ohne Produktivitätsreduktion die Information über das aktuelle Gewicht im Greifer erhalten werden kann. Ein Vorteil liegt darin, dass die Krankinematik hierbei nicht durch zusätzliche Komponenten verändert und damit das Handling verschlechtert wird.

Aufgrund der vollkommen autonomen Messung und Datennachbereitung ist weder eine Interaktion des Bedieners mit dem Messsystem notwendig, noch muss das Ladeverhalten angepasst werden. Dadurch ist eine produktivitätsoptimale Beladung des Forwarders durch kontinuierliche Ladevorgänge weiterhin gewährleistet.

Mittels des datenbasierten Ansatzes ist eine aufwändige Modellierung der Krankinematik [29, 28], welche die Zylinder- und Gelenkreibungen berücksichtigt, nicht notwendig. Durch die Abstraktion des Kranes mittels eines neuronalen Netzes entfällt die explizite Modellierung unbekannter Parameter des Hydrauliksystems. Als Datenbasis für das CNN dienen Signale von bereits serienmäßig installierten Sensoren.

### 5.1.1 Physikalische Motivation zur datenbasierten Waage

In einer statischen Situation kann die Masse des Greiferinhalts, unter Vernachlässigung der Haftreibung der translatorischen und rotatorischen Gelenke, aus einem Momentengleichgewicht um die Drehachse des Hubarms basierend auf dem Druck des Hauptarmzylinders (IBC) und dem Greiferabstand berechnet werden, vgl. Abbildung 5.1. Damit steht die durch die Masse im Greifer hervorgerufene Gewichtskraft  $F_G$  mit der Kraft, welche vom Hubzylinder (IBC) aufzubringen ist, unter Vernachlässigung des konstanten Eigengewichts idealisiert betrachtet in folgendem Zusammenhang:

$$F_G \cdot l_G = F_{IBC} \cdot l_{IBC} \quad (5.1)$$

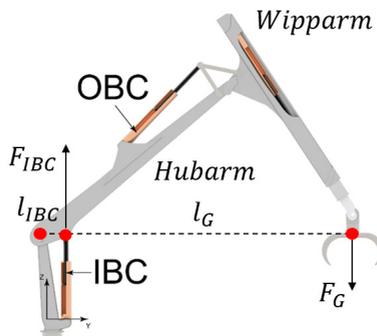


Abbildung 5.1: Physikalisches Grundprinzip zur Nutzlastbestimmung

Hierbei lässt sich die Masse  $m$  des Greiferinhalts basierend auf dem Druck  $p_{IBC}$  im Hubzylinder analytisch bestimmen, da dieser nur bodenseitig angeschlossen ist:

$$m = \frac{p_{IBC} \cdot A_{IBC}}{g} \cdot \frac{l_{IBC}}{l_G} \quad (5.2)$$

mit:

- $g$  = Erdbeschleunigung
- $A_{IBC}$  = Bodenfläche Hubzylinder
- $l_{IBC}$  = Hebelarm für Hubzylinder
- $l_G$  = Hebelarm für Gewichtskraft

Die oben aufgeführten Gleichungen beschreiben eine idealisierte analytische Möglichkeit der Gewichtsbestimmung im statischen Zustand, an dessen Idee sich die entwickelte Methode anlehnt. Das Eigengewicht des Krans wird dabei vernachlässigt, da es als konstanter Faktor unerheblich für ein neuronales Netzwerk ist. Jedoch ist das sich mit den Hebelarmen verändernde Moment der Kranelemente über deren Position als Eingang des NN berücksichtigt. In Realität ergeben sich jedoch eine Vielzahl an Einflüssen, wie zum Beispiel Reibung, die eine einfache analytische Modellierung erschweren, wodurch bei unzureichender Applikation eine hohe Varianz der Ergebnisse erwartet wird. Um diese Erwartung, vor allem im dynamischen Wiegeprozess, zu überprüfen, wurde ein analytisches Modell des Mehrkörpersystems "Forstkran" mittels dem Lagrange-Formalismus 2. Art hergeleitet, mit welchem die Masse im Greifer berechnet werden kann. Als Input für das analytische Modell werden Signale aus einem MKS-Simulationsmodells, aufgebaut in MATLAB-Simulink, verwendet, wobei die Zylinderreibungen vernachlässigt wurden. Hiermit konnte in Simulationen eine hohe Varianz bei der Massenbestimmung verifiziert werden, wobei vor allem die fehlende Information der Winkelgeschwindigkeit und -beschleunigung des pendelnden Greifers den höchsten Einfluss zeigt. Zudem müssen Annahmen für die Trägheitsmomente des Greiferinhalts, also der gegriffenen Stämme, getroffen werden, wodurch sich die Varianz weiter erhöht.

Aus diesem Grund werden die Ansätze aus dem Bereich der Gewichtsbestimmung bei Front- und Radladern mittels eines neuronalen Netzwerk und deren vorverarbeiteten Eingangsdaten [104], vgl. Kapitel 2.4, aufgegriffen,

und zur Nutzlastbestimmung ein datenbasierter Ansatz mittels künstlichen neuronalen Netzen verfolgt.

### **5.1.2 Eingangsdaten und deren Vorverarbeitung**

Für einen möglichst unbeeinflussten Wiegeprozess eignet sich die Lade-  
phase III, Bewegung zum Rungenkorb, am besten. In dieser Phase befindet  
sich der Stamm durchgehend in der Luft, während er bei der Ladephase II  
Kontakt zum Boden und in der Ladephase IV Kontakt zum Rungenkorb hat,  
was eine Störung des Wiegeprozesses darstellt. Als Eingangsdaten für das  
neuronale Netzwerk dienen die in Tabelle 5.1 aufgeführten und nachfolgend  
beschriebenen Signale aus dem Zeitbereich der Ladephase III, beginnend  
mit dem Start der Phase. Die notwendige Separierung der unterschiedlichen  
Ladephasen wird in Kapitel 5.1.6 beschrieben.

Das hydraulische Signal des Drucks des IBC wird sowohl als direkte als  
auch als vorverarbeitete Eingabe in das Netzwerk verwendet. Das Druck-  
signal wird mit Hilfe eines Savitzky-Golay-Filters [79] gefiltert. Darüber  
hinaus dient das durch eine schnelle Fourier-Transformation berechnete Fre-  
quenzspektrum des Drucks als zusätzlicher Eingang. Zusätzlich ist die Öl-  
temperatur im Tank, welche zu Überwachungs- und Sicherheitszwecken bei  
Forstmaschinen jederzeit verfügbar ist, ein Eingangssignal, wodurch die  
Einflüsse durch variable Umgebungsbedingungen mit berücksichtigt wer-  
den. Die Greiferposition als Eingang ergibt sich aus der Verarbeitung des kin-  
ematischen Sensors jedes Krangelenks, die Greifergeschwindigkeit durch  
Differenzierung der Position. [32]

Zusätzlich werden die Signale der Winkelsensoren von Haupt- und Wip-  
parm sowie des Wegaufnehmers am Teleskop verwendet, da aufgrund der  
redundanten Kinematik des Krans durch die Greiferposition allein kein  
Rückschluss auf die aktuelle Stellung der Arbeitskinematik möglich ist.  
Neben dem radialen Greiferabstand dient auch der Quotient dessen mit

Tabelle 5.1: Eingangsdaten in das Neuronale Netzwerk

Nr.	Eingangssignal
1	Zylinderdruck IBC
2	Zylinderdruck IBC, gefiltert
3	Frequenzspektrum Zylinderdruck IBC
4	Normierter Zylinderdruck IBC
5	Radialer Greiferabstand
6	Quotient Zylinderdruck zu Radialer Abstand
7	Position Greifer: X-Achse
8	Position Greifer: Y-Achse
9	Position Greifer: Z-Achse
10	Geschwindigkeit Greifer: X-Achse
11	Geschwindigkeit Greifer: Y-Achse
12	Geschwindigkeit Greifer: Z-Achse
13	Winkel Hauptarm
14	Winkel Wipparm
15	Ausfahrhub Teleskop
16	Öltemperatur
17	Geschwindigkeit Hubzylinder
18	Geschwindigkeit Wippzylinder

dem Zylinderdruck als Eingang. Dies geschieht, da aus der Theorie heraus folgt, dass je weiter die Eingangsdaten zu den Netzen vorbereitet sind, desto bessere Ergebnisse zu erwarten sind [66]. Dieser Quotient beinhaltet die direkte Verknüpfung des Greifergewichts mit dem Zylinderdruck über das Momentengleichgewicht um die Verbindungsachse von Hauptarm und Kransäule, vgl. Abbildung 5.1.

Die Eingabe besteht aus Zeitreihendaten. In einem ersten Schritt werden die Eingangssignale standardisiert. Anschließend werden die standardisierten Signale normiert und als Graustufenbild gespeichert, da ein bildverarbeitendes Neuronales Netzwerk in Anlehnung an [40] für die Auswertung von Zeitreihendaten verwendet wird. Das resultierende Bild hat eine Größe von 18x250 Pixel und gibt damit die 18 Eingangssignale in einer Länge von 250 Zeitschritten wieder. Eine detaillierte Erläuterung der Vorverarbeitung der Eingangsdaten des neuronalen Netzes ist [32] zu entnehmen.

### 5.1.3 Architektur des künstlichen Neuronales Netzes

Das zur Nutzlastbestimmung verwendete künstliche Neuronale Netz wird als *Convolutional Neural Network* (CNN) ausgeführt, was einer Faltungsarchitektur entspricht. Dabei vermeidet diese Architektur Nachteile von *Rekursiven Neuronales Netzen* mit Long short-term memory (LSTM)-Zellen, wie sie in [34] untersucht wurden. Diese Nachteile drücken sich in höhere Trainings- und Prüfzeiten, Parallelisierungsproblemen sowie eine höhere Empfindlichkeit gegenüber Überanpassung oder Reihenfolge der ersten Trainingsdaten aus [24]. Basierend auf der Idee von [24, 40] und in ersten Ansätzen durch [39] umgesetzt wurde ein CNN entwickelt, das die Aufgabe erfüllt, die Masse des Greiferinhalts abzuschätzen.

Die CNN-Architektur besteht aus drei parallelen Zweigen, welche sich vor allem in der Größe und Schrittweite der Filter unterscheiden. Dadurch bearbeitet jeder Zweig des CNN die Eingangssignale mit einer unterschiedlichen

zeitlichen Auflösung. Somit werden die Eingangsdaten nicht nur zum aktuellen Zeitpunkt (1. Zweig) betrachtet, sondern zusätzlich in Zeitbereichen mit einer Länge von 100 ms (2. Zweig) und 1000 ms (3. Zweig). Dadurch werden Informationen zu kurzzeitig auftretenden Ereignissen, wie beispielsweise Druckspitzen, genauso berücksichtigt wie die charakteristischen Signalverläufe, zum Beispiel der Druckverlauf des Hubzylinders.

Die drei parallelen Zweige der CNN-Architektur beinhalten jeweils Faltungsschichten, Schichten für rektifizierte Lineareinheiten (ReLU) und Pooling - Schichten [24, 39]. Abbildung 5.2 veranschaulicht beispielhaft den ersten Zweig. Als Input für das CNN dienen die konvertierten Zeitreihendaten als Graustufenbild (links dargestellt) mit  $18 \times 250$  Pixel. Die erste Faltungsschicht im ersten Zweig besteht aus 128 Filtern mit einer Filtergröße von  $18 \times 1$  und einer Schrittweite von 1. Damit deckt dieser Filter alle Eingangssignale zu jedem Zeitschritt ab. Direkt mit der Faltungsschicht verbunden ist die ReLU-Aktivierungsfunktion  $f(x) = (x, x \geq 0; 0, x < 0)$ , welche nur für Eingangswerte größer und gleich Null durchlässig ist [85]. Anschließend reduziert die Max-Pooling Schicht mit einer Größe von  $5 \times 1$  und Schrittweite 5 den Eingang von  $250 \times 1$  auf  $50 \times 1$ . Dies entspricht einer Verwendung ausschließlich der Maximalwerte der gefilterten 18 Eingangssignale in einem Zeitbereich von fünf Zeitschritten. Die zweite Faltungsschicht besteht aus 32 Filtern mit einer Filtergröße von  $1 \times 1$  und Schrittweite 1. Als Eingang dienen die 128 Kanäle, die sich aus den vorhergehenden Schichten ergeben. Dadurch wird das zuvor geteilte Eingangssignal wieder zusammengeführt. Die zweite Max-Pooling Schicht verdichtet den Eingang auf  $25 \times 1$ , damit die Verkettungsschicht (Concatenation Layer) nur 800 Eingänge für diesen Zweig erhält.

Die erste Faltungsschicht des zweiten Zweiges besteht aus 128 Filtern mit einer Filtergröße von  $18 \times 5$  und Schrittweite fünf. Daher werden bereits bei der ersten Schicht im CNN fünf Zeitschritte berücksichtigt. Im Gegensatz zum ersten Zweig findet zwischen der ersten und zweiten Faltungsschicht kein Bündeln der Zwischenwerte durch eine Max-Pooling Schicht statt. Das

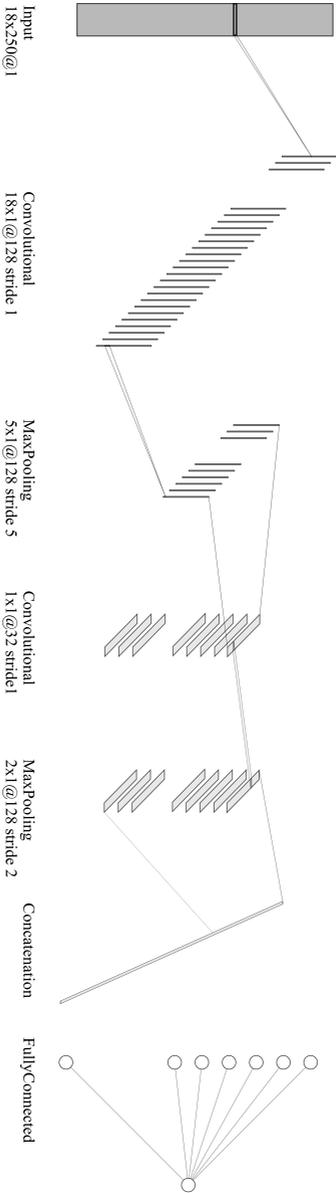


Abbildung 5.2: Architektur des ersten Zweigs des CNN

gleiche Prinzip wird auch für den dritten Zweig angewandt, wobei hier die Filtergröße  $18 \times 51$  mit Schrittweite 4 beträgt und somit ein Zeitbereich von 1000 ms abgedeckt wird. Sowohl für den zweiten als auch für den dritten Zweig ist die zweite Faltungsschicht und die zweite Max-Pooling-Schicht die gleiche wie im ersten Zweig, was zu 800 Ausgabewerten für jeden Zweig führt. Die Verkettungsschicht (Concatenation Layer) vereint die Ergebnisse der drei parallelen Zweige, indem die 800 Ausgaben der jeweilige Zweige aneinander gereiht werden. Die dadurch entstehenden 2.400 Werte werden an die vollständig verbundene Schicht (Fully Connected Layer) übertragen. Daher müssen beim Training für diese Schicht nur 2.400 Gewichte bestimmt werden. Die letzte Schicht ist eine Regressionsausgabeschicht, was bedeutet, dass die Ausgabe des  $18 \times 250$ -Bildes ein einziger ganzzahliger Wert ist, der die Masse des Greiferinhalts darstellt.

Eine Beschreibung des entwickelten CNN ist in [32] zu finden, wo eine Anwendung der datenbasierte Kranwaage zur Qualitätskontrolle von Stämmen erläutert wird.

### 5.1.4 Training und Validierung

Zur Entwicklung des CNNs wird eine Datengrundlage benötigt, mit welcher das Netz trainiert und getestet werden kann. Hierfür wurden insgesamt 550 Ladezyklen unter reproduzierbaren Laborbedingungen zwischen August 2018 und März 2019 aufgezeichnet, wobei sowohl der Forwarder als auch die Stämme auf einer ebenen Fläche platziert wurden. Drei verschiedene Maschinenbediener mit unterschiedlichem Qualifikationslevel (ungeübter Bediener, geübter Bediener, professioneller Bediener) führten die Ladezyklen durch.

Die tatsächliche Stammmasse wird mit einer Waage mit einer Genauigkeit von 0,5 kg bestimmt. Die Stammlängen betragen etwa 5,2 m, die Stammmassen liegen in einem Bereich von 98 bis 600 kg, mit einem variierenden Durchmesser von bis zu 50 cm. Durch das Greifen mehrerer Stämme

wurden Ladezyklen mit einer maximalen Gesamtmasse von 1020 kg aufgezeichnet, was der Obergrenze der Lademöglichkeit durch den Forstkran entspricht. 31 Ladezyklen sind als Hold-Out-Set für das Testen der Kranwaage reserviert. Die restlichen 519 Zyklen werden während des Training zu 90 % für das Training und zu 10 % für die Validierung aufgeteilt. Aufgrund der geringen Menge an Trainingsdaten mit den daraus resultierenden Herausforderungen [37] wird eine sechsfache Kreuzvalidierung verwendet, d.h. alle 519 Trainingszyklen werden zufällig sechs Mal in einen Trainingsdatensatz und einem Validierungsdatensatz aufgeteilt. Für das Training wird die Lernrate auf 0,01 und die Größe der Mini-Batches auf 20 gesetzt und maximal 30 Epochen verwendet. Jedes Training besteht aus 20 Durchgängen, was aufgrund der 6-fachen Kreuzvalidierung insgesamt 120 Netzwerke ergibt. Nach dem ersten Training werden nacheinander zwei weitere Trainingsdurchgänge mit einer Lernrate von 0,001 durchgeführt, wobei das Netz mit den Gewichten der vorher trainierten Netzwerks initialisiert wird.

Die Güte des CNN wird mit den Trainings- und Validierungsdaten anhand des Vorhersagefehlers (VF) bewertet, der sich aus der Differenz zwischen der vorhergesagten Masse und der tatsächlichen Masse geteilt durch die tatsächliche Masse ergibt. Abbildung 5.3 zeigt, kombiniert für die 120 trainierten Netze, die Gauß-Verteilung des Vorhersagefehlers für den Validierungsdatensatz (rechts) und den Trainingsdatensatz (links) in einem Bereich von -20 % bis 20 %. Der Trainingsdatensatz zeigt, basierend auf 56.160 Werten, einen mittleren VF von 0,23 % und einen Median VF von -0,0263 % mit einer Standardabweichung von 4,67 %. Der Validierungsdatensatz zeigt, basierend auf 6.120 Werten, einen mittleren VF von 0,46 % und einen Median VF von -0,0095 % mit einer Standardabweichung von 7,33 %.

Tabelle 5.2 listet den Vorhersagefehler sowohl für Trainings- als auch für Validierungsdaten mit seinen Quantilen 5 %, 25 %, 75 % und 95 % auf. Unter Berücksichtigung der 5 %- und 95 %-Quantilen sowie des mittleren VF zeigt das CNN mit seiner Vorhersage eine leichte Tendenz zur Überschätzung der Masse. 50 % der vorhergesagten Massen weisen ein absoluten

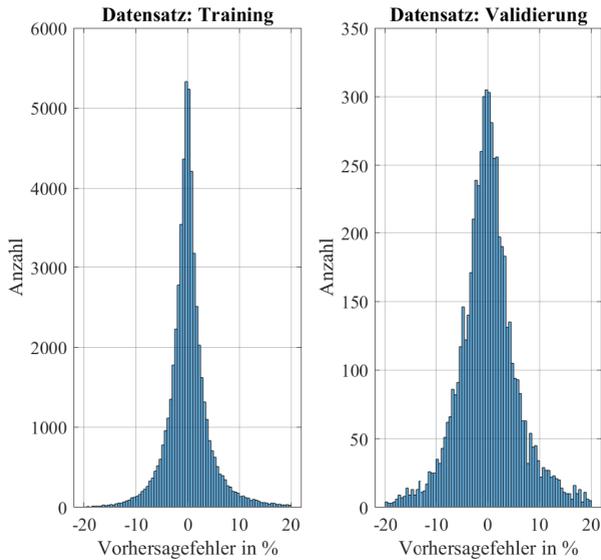


Abbildung 5.3: Ergebnis des Trainings des Neuronalen Netzwerks

Tabelle 5.2: Statistische Analyse des CNN

Quantile in %	Vorhersagefehler in % für Trainingsdatensatz	Vorhersagefehler in % für Validierungsdatensatz
Median	-0,0263	-0,0095
5	-6,25	-9,46
25	-1,69	-2,95
75	1,71	3,13
95	7,44	12,18

VF von weniger als 1,71 % (Trainingsdatensatz) bzw. weniger als 3,13 % (Validierungsdatensatz) auf. Daher wird keine signifikante Überanpassung des CNN beobachtet, woraus auf ein robustes Netzwerk zur Erkennung zu schließen ist.

### 5.1.5 Automatisierter Wiegeprozess im Sortimentungsverfahren

Mit dem Ziel einer hohen Akzeptanz und einfachen Anwendbarkeit der dargestellten Methode zum Wiegen des Greiferinhaltes muss ebendieses möglichst benutzerfreundlich erfolgen. Aufgrund der großen Datenmengen, die während eines Arbeitstages entstehen, ist daher eine Automatisierung der einzelnen Gewichtsabschätzung zwingend notwendig. Abbildung 5.4 veranschaulicht den Ablauf des automatisierten Wiegeprozesses, bei welchem in einem Post-processing–Verfahren die geladenen Massen eines kompletten Arbeitstages ermittelt werden.

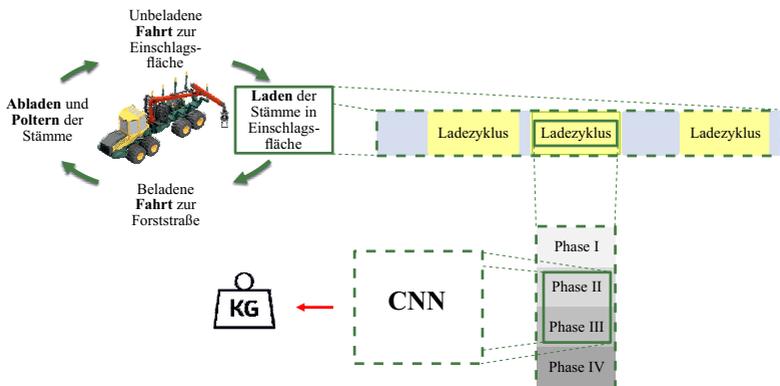


Abbildung 5.4: Ablaufdiagramm des automatisierten Wiegeprozesses

Der Forwarder befindet sich im Verlauf eines Arbeitstages mehrmals in der Rückegasse, weswegen im ersten Schritt diese Zeiträume extrahiert werden

müssen. Anschließend werden die einzelnen Ladezyklen in der Rückegasse erkannt. Darauf folgend werden für jeden erkannten Ladezyklus die 4 Phasen im Ladeprozess ermittelt. Alle aufgenommenen Signale werden für die Phase 2 und Phase 3 abgespeichert, da diese Zeitreihen anschließend die Eingänge für das Neuronale Netzwerk bilden. Im trainierten Netz wird die Masse zum jeweiligen Ladezyklus geschätzt und anschließend ausgegeben.

### **5.1.6 Phasenbestimmung des Ladezyklus**

Während das Laden gut von den Arbeitsprozessen des beladenen und unbeladenen Fahrens unterschieden werden kann, ist eine Differenzierung zum Abladen und Poltern jedoch anspruchsvoll. Daher wird im Vorfeld zur Bestimmung der Ladephasen ein Algorithmus verwendet, welcher die Ladezyklen des Forwarders detektiert. Generell werden Kranzyklen über den Schwenkwinkel des Krans erkannt, mit welchem ein wiederkehrendes Verlassen und Wiedereintreten des Greifers in den Rungenkorb detektiert wird, jedoch keine Unterscheidung zwischen Laden und Poltern ermöglicht. Deshalb wird zum einem der Zylinderdruck des Greifers beim Schwenken des Greifers in Richtung Rungenkorb betrachtet. Dieser ist bei einem Ladezyklus signifikant höher als beim Entladen, da hier der Greifer leer zum Rungenkorb zurückgeschwenkt wird. Zusätzlich wird der Druckverlauf des Hubzylinders untersucht. Ist dieser beim Eintreten in den Rungenkorb (Ende der Ladephase III) signifikant höher als zu Beginn der Kranbewegung (Ladephase I), so liegt ein Ladezyklus vor, da der höhere Druck des IBC durch die Stämme im Greifer verursacht wird. Nach erfolgter Detektion der Ladezyklen werden für die Phasenbestimmung zusätzliche Eingangssignale herangezogen.

Der Zeitabschnitt der Greifphase (Ladephase II) im Ladezyklus wird durch eine Analyse der Joysticksignale, des IBC-Druckes und der Greiferposition im ersten Schritt der Phasenbestimmung ermittelt. 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 Druckspitzen im Zyklus detektiert sind, werden alle Positionen, in denen sich der Greifer in einem lokalen Minimum der z-Position befindet, auf drei Bedingungen hin überprüft:

- Befindet sich eine Druckspitze des Hubzylinders in einem Zeitbereich von 1 s?
- Schließt der Greifer in einem Zeitbereich von 1 s?
- 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. Dies schließt den Praxisfall des Sammelns mehrerer Stämme mit geringem Durchmessers ein, die dann gemeinsam geladen werden.

Der Startpunkt der Ladephase II legt den Endpunkt der Ladephase I fest, welche mit dem Bewegen des Greifers aus dem Rungenkorb beginnt. Das Ende der Greifphase (Ladephase II) markiert den Beginn der Ladephase III, welche mit Eintritt des Greifers in den Rungenkorb endet. Die darauffolgende Ladephase IV endet mit dem abgeschlossenen Öffnen des Greifers, da damit die Stämme im Rungenkorb abgelegt sind. Die Dauer des Ladezyklus ergibt sich damit automatisch aus der Summe der Zeitdauer der einzelnen Phasen.

Eine detaillierte Erläuterung der datenbasierten Kranwaage ist [34, 32] zu entnehmen.

## 5.2 Objekterkennung im Forst mittels maschinellen Sehens

Ziel des Informationsmoduls zur Objekterkennung ist es, die Lücke einer fehlenden Stammerkennung während des Holzeinschlags zu schließen, wobei der Fokus auf einer Durchforstung liegt. Dadurch können Zielpunkte für eine automatisierte Kranbewegung ermittelt werden, welche von dem Assistenzsystem *AutoLoad*, vgl. Kapitel 6.2, angefahren werden können.

Eine Stereokamera erzeugt sowohl ein 2D-RGB-Farbbild als auch eine 3D-Punktwolke, wobei jedem Punkt der 3D-Punktwolke ein entsprechender Pixel im 2D-RGB-Bild zugeordnet ist. Das vorgeschlagene Verfahren nutzt diese technische Grundlage und kombiniert eine bildbasierte Objekterkennung mit den Punktwolkendaten der Stereokamera, wodurch eine semantisch segmentierte 3D-Punktwolke der Umgebung entsteht. Die Erkennung von Stämmen erfolgt mittels den 2D-RGB-Bildern, während der Bestimmung von Stammattributen 3D-Punktwolkendaten zugrunde liegen, vgl. Abbildung 5.5. Es werden dabei nur genau jene Punkte, welche zu einem Stamm gehören, extrahiert und weiterverarbeitet. Diese aus den 3D-Daten extrahierten Punkte ermöglichen eine Bestimmung der Stammattribute wie Durchmesser, Länge und Position in Bezug auf den Forwarder. Der Prozess der Erkennung gliedert sich dabei in drei aufeinanderfolgende Schritte:

1. Für die Objekterkennung wird ein Convolutional Neural Networks mit der YOLACT++ [11] Architektur mittels *Transfer Learning* auf dem benutzerdefinierten Datensatz *MobimaLogs* (vgl. Kapitel 5.2.1), bestehend aus Bildern von Hiebsflächen während der Durchforstung, trainiert. Die Ausgaben dieses CNN sind Masken, welche die zu einem bestimmten Objekt gehörenden Pixel im Bild bestimmen. Diese Masken sind in Abbildung 5.5, links Mitte, beispielhaft durch farbige Regionen für Bäume, Stämme und Stümpfe visualisiert.

2. Im zweiten Schritt werden die zum Stamm gehörenden Punkte aus der 3D-Punktwolke extrahiert. Eine derartige Extraktion der Punkte hat den Vorteil, dass die Separation schnell erfolgt und für die weitere Bestimmung der Stammattribute nur die zu Stämmen gehörenden Punkte berücksichtigt werden müssen, was den gesamten Prozess beschleunigt.
  
3. Auf Basis der extrahierten Punkte werden die Stammattribute wie Durchmesser und Länge über einen klassischen Algorithmus zur Kreisschätzung berechnet [106], vgl. Abbildung 5.5, rechts unten. Mit diesen Ergebnissen wird abschließend die Stammpose, also die Position und Orientierung des Stammes, in Bezug auf den Forwarder bestimmt.

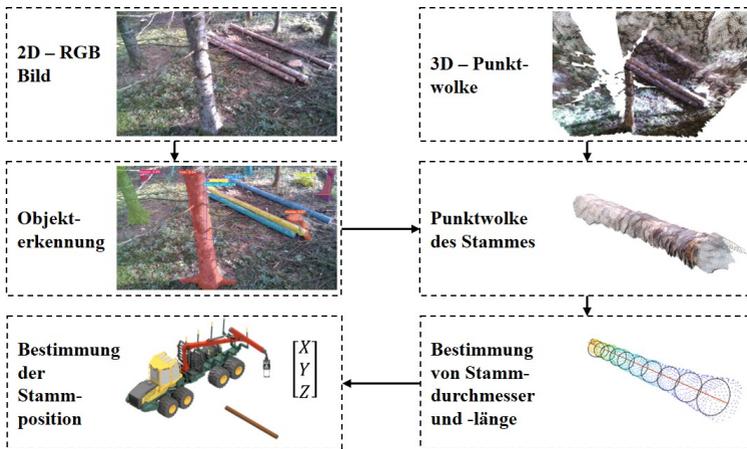


Abbildung 5.5: Ablaufdiagramm der Objekterkennung

Im Folgenden werden die einzelnen Schritte detailliert erläutert.

### 5.2.1 Objekterkennung und semantische Instanzsegmentierung von Stämmen

Die Aufgabe der Detektion und Segmentierung von Baumstämmen wird ausschließlich mit den 2D-RGB-Bilddaten durchgeführt. Der Grund für den Verzicht auf die Verwendung der 3D-Punktwolke-Daten ist zum einen das starke Sensorrauschen, das eine 3D-Detektion nicht möglich macht. Zum anderen existiert bereits eine große Anzahl von Algorithmen für 2D-RGB-Bilddaten, während zeitgleich der Stand der Technik durch eine Vielzahl an Forschungstätigkeiten kontinuierlich vorangetrieben wird. Der Großteil der modernen Methoden zur Objekterkennung basieren auf Convolutional Neural Networks. Oft werden gebräuchliche CNN-Modelle wie ResNet [54] als Rückgrat (engl.: Backbone) in einer komplexeren Architektur verwendet. Der Prozess der Objekterkennung, welcher die Erkennung und Bildsegmentierung kombiniert, wird Instanzsegmentierung genannt. Dieser eignet sich gut für die Aufgabe, die Stämme zu segmentieren und mehrere Instanzen auf Pixel-Basis zu unterscheiden. In Kombination mit einer Stereokamera kann das Ergebnis der Bildsegmentierung direkt auf das Tiefenbild angewendet werden, womit eine semantisch segmentierte 3D-Punktwolke zur Verfügung steht. Das neuronale Netzwerk YOLACT++ wird mit ResNet-101 als Backbone für eine Instanzsegmentierung trainiert und evaluiert, da diese Architektur ein sehr ausgeglichenes Verhältnis zwischen Genauigkeit, Geschwindigkeit und Hardwareanforderungen bietet [11]. In dieser Arbeit wird das neuronale Netz mittels *Transfer Learning* auf dem forstspezifischen Datensatz MobimaLogs trainiert.

**Datensatz *MobimaLogs* für Training und Validierung** Der Datensatz MobimaLogs besteht aus 2.123 Bildern, die in einem Zeitraum von 2019 - 2021 aufgenommen wurden. Während Laborumgebungen wie Wiese oder Schotter enthalten sind, machen Waldumgebungen etwa 85 % der Daten aus, einschließlich verschiedener Umwelteinflüsse von trocken und

sonnig hin zu schneebedeckt und bewölkt. Innerhalb des Datensatzes wurden neun Objektklassen eingeführt und markiert: *Bäume* sind die Klasse für noch stehende Bäume, Baumstämme werden in *Stamm* und *Stamm verdeckt* unterteilt, wenn das Stammende von einem Baum verdeckt wird oder aus dem Bild ragt. Hintergrund hierfür ist, dass nur für die Klasse *Stamm* eine gültige Längenabschätzung möglich ist. Weiterhin ist mit der Klasse *gegriffener Stamm* eine Beurteilung möglich, ob ein erfolgreicher Greifvorgang stattgefunden hat. Die Erkennung von Objekten der Klasse *Stumpf*, *Person*, *Greifer*, *Hindernis* und *Forwarder* dient als Grundlage für zukünftige Arbeiten zum automatisierten Fahren auf einer Rückegasse oder einer automatischen Notbremsung.

**Training von YOLACT++ mittels Transfer Learning** Das Netzwerk wird mittels *Transfer Learning* trainiert, was die Trainingszeit reduziert, indem von einer bereits trainierten Konfiguration des Netzwerks ausgegangen wird. Beim Training auf dem benutzerdefinierten Datensatz MobimaLogs ändert sich die Dimension der Gewichte nur für die letzten Schichten, während das Backbone nicht verändert wird. Als Startkonfiguration werden die von [9] zur Verfügung gestellten Gewichte verwendet, die auf dem öffentlichen Benchmark-Datensatz MS COCO trainiert wurden [72]. Das Trainingsverfahren orientiert sich an [11], zur Abstimmung auf die vorliegende Aufgabe werden die Hyperparameter modifiziert. So wird die Anzahl der Trainingsiterationen reduziert, um diese auf die geringere Größe des MobimaLogs-Datensatzes anzupassen. Der kleinere verfügbare GPU-Speicher im Vergleich zu [10, 11] führt zu einer reduzierten Anzahl von Bildern, die auf einmal verarbeitet werden können. Um dies zu berücksichtigen, wird eine im Vergleich zu [11] verringerte Lernrate nach [38] verwendet. Der Datensatz MobimaLogs wurde randomisiert in einen Trainingsdatensatz (85 % der Bilder) und einen Validierungsdatensatz (15 % der Bilder) aufgeteilt.

**Validierung und Online-Erkennung** Die Performance des trainierten Netzwerks wird anhand des Validierungsdatensatzes bewertet. Dabei wird für die Bewertung der Genauigkeit die COCO-style Average Precision ab dem Intersection-over-Union -Schwellenwert von 0,5 [72] verwendet. Deckungsgleichheit von manuell markierten und prädierten Objekten gilt für  $IoU = 1$ .

Dabei fasst die AP den Recall-Precision-Kurvenverlauf zur mittleren Präzision auf 101 gleichmäßig verteilte Recall-Stufen [72, 27] zusammen. Die Auswertung mit dieser Methode ermöglicht eine Interpretation der Ergebnisse insbesondere für Regionen mit hoher IoU, was für die anschließende maskenbasierte Punktextraktion aus Tiefendaten entscheidend ist. Die Rechenzeit zur Prädiktion betrug auf dem zur Verfügung stehenden System (Nvidia Quadro P3200, 6 GB Video-RAM) durchschnittlich 90 ms, was etwa dreimal langsamer ist als bei [10, 11] ([10]: Titan Xp, 12 GB Video-RAM).

Tabelle 5.3 zeigt die durchschnittliche Präzision für IoU-Schwellenwerte von 0,5 % bis 0,95 %. Das trainierte YOLACT++ Netzwerk zeigt eine mittlere AP, gemittelt über alle 10 Objektklassen des Datensatzes und alle IoU's, von 60,93 mAP für Boxen und 56,65 mAP für Masken. Obwohl die AP zu hohen IoU-Verhältnissen hin abnimmt, liefert das trainierte Netz robuste und qualitativ hochwertige Ergebnisse für die Objekterkennung. Die deutlich höhere mAP im Vergleich zur Validierung in [10, 11] mit 34,6 mAP ist durch die geringere Anzahl an gelabelten Klassen bedingt.

Tabelle 5.3: Durchschnittliche Genauigkeit auf dem Validierungsdatensatz nach dem Training

IoU	mAP	0,50	0,55	0,60	0,65	0,70	0,75	0,80	0,85	0,90	0,95
AP Box	60,93	83,03	81,79	80,45	78,79	76,23	69,97	62,29	44,40	27,05	5,32
AP Maske	56,65	78,75	77,76	76,45	74,21	69,58	64,21	56,96	40,43	22,89	5,24

Abbildung 5.6 zeigt beispielhafte Bilder aus dem Validierungsdatensatz mit den resultierenden Masken. Das erste Szenario zeigt eine Durchforstung im mittleren Bestand bei Sonnenschein. Hier ist erkennbar, dass der Schattenschwurf keine Auswirkungen auf die Detektion aufweist, sondern die Objekte richtig erkannt werden. Auch bei stark unterschiedlichen Belichtungsverhältnissen der Stämme werden diese korrekt identifiziert. Szenario zwei wurde bei Dunkelheit aufgenommen, wobei als Lichtquelle ausschließlich die Arbeitsscheinwerfer des Forwarders dienen, wodurch die Anwendbarkeit der Objekterkennung unabhängig von Tageslicht verifiziert ist. In Szenario drei wird korrekt erkannt, dass die Stämme im Greifer gegriffen sind. Der Fall, dass die Stammenden verdeckt sind, ist in Szenario vier zu sehen. Durch das eingeschränkte Sichtfeld aufgrund des Reishaufens werden die Stämme als *Stamm verdeckt* klassifiziert.

Befindet sich der Forwarder wie Szenario fünf im Bild, so wird auch dieser erkannt. Während bei der Darstellung in Abbildung 5.6 alle Masken oberhalb eines Schwellenwerts (Score) für die Erkennungsgüte von 0.3 gezeigt werden, wird bei der Real-Time-Objekterkennung im forstlichen Hieb die Methode der *Non-Maxima Supression* [8, 11] verwendet, um doppelte Masken desselben Objektes zu unterdrücken. Sofern doppelte, sich überlappende Masken vorhanden sind, wird nur die Maske mit dem höchsten Score verwendet.



Abbildung 5.6: Ergebnisse von YOLACT++ auf dem Validierungsdatensatz von *MobimaLogs*

## 5.2.2 Bestimmung der Stammattribute

Basierend auf den segmentierten Punktwolken für jeden Stamm können die geometrischen Eigenschaften der Stämme bestimmt werden. Zunächst wird die Punktwolke mithilfe eines Voxel-Grid-Filter [125] heruntergesampelt, was zu einer gleichmäßigeren Dichte der resultierenden Punktwolke führt. Um den Fall zu behandeln, dass grobe Ausreißer vorhanden sind, wird eine statistische Ausreißerkorrektur verwendet. Die Vorverarbeitungsschritte werden mit der Open3D-Bibliothek durchgeführt [125].

Im Gesamten werden drei konsekutive Verarbeitungsschritte durchgeführt, um die Stammattribute zu bestimmen:

1. Zunächst wird die Hauptachse des Stamms mittels einer Hauptkomponentenanalyse (PCA) geschätzt, was in einer ersten Bestimmung der Stammpose resultiert. Damit wird die Punktwolke in ein Koordinatensystem transformiert, welches an der Stammachse ausgerichtet ist.
2. Dies ermöglicht es, die Punktwolkendaten entlang der Stammachse zu unterteilen und den mittleren Durchmesser für jeden Abschnitt in 2D zu berechnen.
3. Im dritten Schritt werden die geschätzten Zentren der Abschnitte verwendet, um die anfängliche Posenbestimmung zu verbessern. Abschließend wird die Längenkorrektur durchgeführt, welchen den Effekt des Verschmierens der Punktwolke am Ende des Stammes reduziert.

**Bestimmung der Stammpose** Die Posenbestimmung besteht darin, die Position und Orientierung der Stämme zu finden. Dies wird mit einem PCA-basierten Ansatz gelöst, ähnlich wie [89] unter Verwendung der Punktwolkendaten. Im Falle von 3D-Koordinaten liefert eine PCA die orthogonalen Vektoren  $\vec{v}_1, \vec{v}_2, \vec{v}_3$ , in denen die Daten am meisten variieren. Diese werden

nach der Varianz entlang dieser Dimensionen sortiert, was es erlaubt, die Achse mit der größten Varianz ( $\vec{v}_1$ ) als erste Schätzung der Hauptachse des Stammes zu identifizieren. Für die weitere Verarbeitung ist es nützlich, die Punktwolke in das Koordinatensystem zu transformieren, welches mittels der Hauptkomponenten der PCA gebildet werden kann:

$$\begin{pmatrix} x'_{1,i} \\ x'_{2,i} \\ x'_{3,i} \end{pmatrix} = \begin{pmatrix} \vec{v}_1 \\ \vec{v}_2 \\ \vec{v}_3 \end{pmatrix} \cdot \begin{pmatrix} x_{1,i} - x_{1,mean} \\ x_{2,i} - x_{2,mean} \\ x_{3,i} - x_{3,mean} \end{pmatrix} \quad (5.3)$$

Durch Subtraktion des Mittelwerts von den Punktwolkendaten  $x_{mean}$  liegt der Ursprung des stammausgerichteten Koordinatensystems  $x'$  in der Mitte des Stammes. Die Länge des Stammes kann mit Hilfe der Differenz der minimalen und maximalen Werte entlang der Achse  $x'_1$  geschätzt werden. Mit  $x'_2$  und  $x'_3$  als Basen kann ein 2D-Koordinatensystem gebildet werden, das eine Querschnittsansicht der Punktwolkendaten darstellt. Im globalen Koordinatensystem wird der Mittelwertsvektor  $\vec{x}_{mean}$  und die erste Hauptkomponente der Punktwolke verwendet, um die Hauptachse des Stammes, und damit die Stammpose, durch eine Geradengleichung mit der allgemeinen Variable  $k$  zu beschreiben:

$$\vec{x}_{Stamm} = \vec{x}_{mean} + \vec{v}_1 \cdot k \quad (5.4)$$

**Ermittlung des Stammdurchmessers via Kreisregression** Eine 3D-Rekonstruktion des Stammes wird durch ein Fitten mehrerer Kreise entlang der Hauptachse des Stammes durchgeführt. Für diesen Verarbeitungsschritt werden die transformierten Punkte aus der PCA zunächst in gleichmäßig verteilte Segmente unterteilt. Anschließend werden die Punkte in jedem Segment auf dessen jeweilige 2D-Mittelebene projiziert. Da das Koordinatensystem bereits entlang der Stammachse orientiert ist, kann die Projektion

effizient erfolgen, indem dafür nur die  $x'_2$  und  $x'_3$  Komponenten der einzelnen Punkte verwendet werden. Ein ähnlicher Ansatz wurde bereits bei [89] verwendet, wobei hier mit Lidar-Daten von technischen Objekten gearbeitet wurde.

Bei Anwendungen zur Umgebungserkundung werden die zylindrischen Objekte meist nur aus einem Winkel betrachtet. Die daraus resultierende unvollständige Erfassung des Querschnitts erhöht den Aufwand für das Fitten von Kreisen. Die Regressionsmethode *Hyper-Fit* [106] liefert für das Lösen dieser Herausforderung gute Ergebnisse in [89], insbesondere wenn sie in einem *Least-Trimmed-Squares*-Verfahren (LTS) für robuste Regression angewendet wurde. Zudem ist diese Methode in Bezug auf die Rechenzeit effizient, da sie keine iterativen Solver benötigt, wodurch eine Anwendung in Echtzeit möglich ist. Das LTS-Verfahren erlaubt eine Korrektur von Ausreißern basierend auf dem Ausreißerverhältnis  $R$ , welches das Verhältnis von Ausreißern zu validen Datenpunkten vorgibt. Auch wenn es die oben erwähnten Unterschiede in den Daten gibt, baut die in dieser Arbeit vorgeschlagene Methode auf [89] auf. Die Hyper-Fit-Methode wurde mit einer linearen Algebra-Bibliothek basierend auf [18] implementiert. Für die LTS-Methode wurde ein iteratives Verfahren wie in [101] beschrieben implementiert. Um den besten Parametersatz für die Anpassung der Kreise zu ermitteln, wurde eine Parametervariation durchgeführt. Dabei wird die Anzahl der 2D-Projektionsebenen, welche der Anzahl an gefitteten Kreise  $C$  entspricht, und das Ausreißerverhältnis  $R$  jeweils 3-mal variiert, was zu 9 Parametersätzen führt. Hierzu wurden mit der Tiefenkamera Messdaten von 6 Stämmen unter Laborbedingungen aufgezeichnet, wobei deren Durchmesser vorab manuell an 11 Positionen entlang der Stammachse gemessen wurde. Da die Messungen jeweils über mehrere Sekunden liefen, liegen für jeden Parametersatz etwa 2.300 Datenpunkte vor, womit eine statistische Auswertung möglich ist. Tabelle 5.4 zeigt den über die Anzahl der Kreise gemittelten Fehler des Durchmessers für jede Variation unter Berücksichtigung des Median und der Quantile. Der Fehler im Median steigt

Tabelle 5.4: Einfluss des Ausreißerverhältnis  $R$  und der Anzahl gefitteter Kreise  $C$  auf die Bestimmung des Stammdurchmessers

Parameter	C=3			C=6			C=11		
	R = 0,05	R = 0,2	R = 0,4	R = 0,05	R = 0,2	R = 0,4	R = 0,05	R = 0,2	R = 0,4
Median in cm	2,29	0,55	0,04	3,11	2,40	12,21	2,93	3,18	15,94
5 % Quantil in cm	- 18,80	-17,52	-16,64	-17,12	-0,15	-14,54	-15,48	-2,39	0,24
25 % Quantil in cm	-2,19	-1,57	-1,22	1,56	0,96	2,17	-2,79	1,51	4,63
75 % Quantil in cm	3,93	1,87	2,19	4,77	5,35	28,41	5,32	9,17	58,26
95 % Quantil in cm	31,76	41,35	76,21	28,56	51,57	172,2	40,77	87,09	316,36

mit höherer Kreisanzahl an, ebenso der Fehler bei den 75 % - und 95 %-Quantilen. Daher wurde die Anzahl der zu fittenden Kreise auf 3 gesetzt. Das Ausreißerverhältnis weist einen großen Einfluss auf den Fehler auf. Bei einem Ausreißerverhältnis von 0,2 gleichen sich die Fehler zwischen den 25 % - 75 % Quantilen nahezu aus. Der etwas höhere Median im Vergleich zu einem Ausreißerverhältnis von 0,4 ist im Vergleich zu dem deutlich geringeren Fehler am 95 %-Quantil vernachlässigbar, da dadurch die Robustheit gegenüber starken Ausreißern erhöht ist. Daher wurde der Parametersatz mit 3 zu fittenden Kreisen und einem Ausreißerverhältnis von 0,2 für weitere Auswertungen verwendet.

**Stammposen- und Stammlängenkorrektur** Die anfängliche Schätzung der Lage des Stammes kann mit einer Ungenauigkeit behaftet sein, da der Mittelwert aller 3D-Datenpunkte zur Bestimmung der Ausrichtung der Stammachse verwendet wird. Da die Erfassung der Stämme aufgrund des Blickwinkels der Kamera unvollständig sein kann, ist ein Versatz von der tatsächlichen Mittellinie möglich. Um dies zu korrigieren, wird ein zweiter Regressionsdurchgang mit den Mittelpunkten der einzelnen Kreise durchgeführt. Dabei werden Ausreißer verworfen, indem ein RANSAC-Algorithmus [103] auf den Kreisdurchmessern ausgeführt wird. Anschließend werden die Mittelpunkte der validen Kreise in eine weitere PCA eingespeist, die eine verfeinerte Schätzung für die Mittelachse liefert. Ab-

bildung 5.7 zeigt die Punktwolke mit den angepassten Kreisen in schwarz und der Stamm-Mittellinie in rot. Das Farbschema der Punkte gibt den Abstand zur Kamera wieder, von nah (lila) zu fern (gelb).

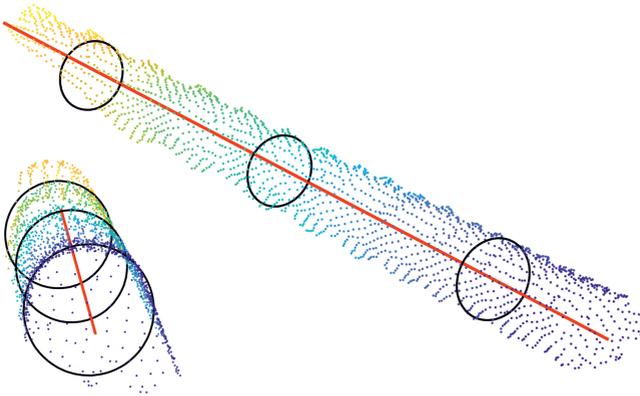


Abbildung 5.7: Visualisierung des Kreisfittings auf der zum Stamm gehörigen Punktwolke

Die anfängliche Bestimmung der Stammlänge ist vereinfacht durch die Differenz des Minimums und Maximums der Datenpunkte entlang der Achse  $x'_1$  abgeschätzt. Unter der Annahme, dass es keine Ausreißer in den Punkten gibt, führt dies bereits zu einer ausreichenden Längenschätzung. Bei der verwendeten Stereokamera wurden jedoch teilweise fehlerhafte Punkte am Stammende beobachtet, was durch den Effekt einer Punktwolkenverschmierung aufgrund des starken Sensorrauschens erklärt werden kann. Dies äußert sich in einem Schweif von Punkten, welcher sich von der Hinterkante des Stammes bis zum Boden entlang der Kamerablickrichtung erstreckt. Dieser Effekt führt zu einem Überschätzen der Stammlänge. Um diese Herausforderung zu lösen, wird ein bildbasierter Ansatz herangezogen, welcher Informationen aus der Objekterkennung zur Korrektur der Länge verwendet. Im ersten Schritt wird die Stammachse auf das 2D-RGB-Bild projiziert. Die Segmentierungsmaske wird dann verwendet, um den Endpunkt der Mittel-

linie des Stammes zu bestimmen, indem der Schnittpunkt des Stammendes mit der transformierten Linie bestimmt wird. Anschließend wird dieser neue Endpunkt mit der Annahme, dass der Punkt aufgrund seiner Unterbestimmtheit auf der Mittellinie liegen muss, wieder in einen 3D-Punkt transformiert. Der detaillierte Ablauf ist in [31] beschrieben.

### 5.2.3 Genauigkeitsanalyse der Merkmalsbestimmung

Mit einem einfachen Testfall unter reproduzierbaren Laborbedingungen wird die Genauigkeit der Längen- und Durchmesser-schätzung untersucht. Es werden nur einzelne Stämme auf einem einfachen Hintergrund verwendet, wie gleichmäßiger Waldboden, Schotter oder Rasen, um die Objekterkennung so einfach wie möglich zu gestalten. Es werden dieselben Stämme wie bei der Parametervariation verwendet. Der repräsentative Durchmesser der Stämme ist der Mittelwert aus den Einzelmessungen, analog zu den Messprinzipien aus der Holzindustrie [3]. Die für die Auswertekampagne verwendeten Stämme wurden alle aus einer Höhe von ca. 3 m mit einer Kameraposition analog zu Kapitel 4 aufgenommen. Die Durchmesser variieren in einem Bereich von 0,33 m bis 0,44 m, während die Stammlängen 5,14 m bis 5,32 m betragen. Der Abstand der Stämme zur Drehachse des Krans reichte von 1 m bis 10 m, wodurch realistische Bedingungen mit einer maximalen Kranreichweite von 10 m abgebildet sind. Datengrundlage für die statistische Auswertung sind 44 verschiedene Messungen von 6 verschiedenen Stämmen.

Abbildung 5.8 zeigt die zeitlich gemittelten Fehler von Durchmesser und Länge für die Messungen mittels einen Boxplot. Dabei stellt die blaue Box die 25% -75% - Quantile (Quartile) dar, die rote horizontale Linie den Median, die maximalen Whisker sind das 1,5-fache des Interquartilsbereichs und Ausreißer sind als rote Kreuze markiert. Der Median des Durchmesserfehlers beträgt 1,46 cm, mit einem 75 %-Quantil von 3,77 cm. Werden die Ausreißer vernachlässigt, so reichen die Fehler von -5 cm bis 8 cm,

was eine gute Schätzung des Durchmessers ergibt. Der Median des Stamm-  
 längenfehlers liegt bei 7,0 cm, mit 23,2 cm im 75 %-Quantil, was eine  
 Unterscheidung zwischen den im forstlichen Hieb üblicherweise vorkom-  
 menden Standardsortimenten ermöglicht.

Eine detaillierte Erläuterung der Objekterkennung ist [31] zu entnehmen.

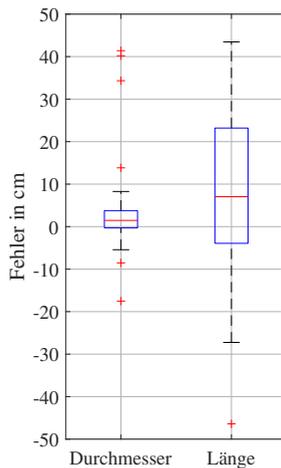


Abbildung 5.8: Genauigkeit der Bestimmung der Stammattribute

## 6 Assistenzsysteme für die Kransteuerung

Mittels der im folgenden Kapitel entwickelten Kranspitzensteuerung einschließlich ihrer gewichteten Pseudo-Inverse der Krankinematik kann direkt die Bewegung des Greifers vorgegeben werden. Das Assistenzsystem *AutoLoad* nutzt die Kranspitzensteuerung und realisiert, basierend auf dem Informationsmodul Umfelderkennung, mit einem Zustandsautomaten einen automatisierten Lade- und Greifprozess.

### 6.1 Kranspitzensteuerung als Steuermodul

In einer konventionellen Steuerung wird durch die Betätigung der Joysticks die Geschwindigkeit der einzelnen hydraulischen Verbraucher festgelegt. Um die Kranspitze in die gewünschte Richtung zu bewegen, muss der Bediener die Einzelverbraucher Hub-, Wipp- und Teleskopzylinder einzeln ansteuern und deren Bewegung manuell überlagern. Dies benötigt viel Erfahrung und ist mental sehr fordernd. Die Kranspitzensteuerung verfolgt das Ziel der Entlastung des Bedieners, indem ebendiese Geschwindigkeitsüberlagerung automatisiert wird. Der Bediener kann durch Nutzung der Kranspitzensteuerung direkt den Geschwindigkeitsvektor der Kranspitze vorgeben, ohne dass er die Bewegung der Einzelverbraucher berücksichtigen muss.

Für die Entwicklung der Kranspitzensteuerung werden zuerst die kinematischen Zusammenhänge des Forstkranes beschrieben, aus welchen sich dessen Jacoby-Matrix ableitet. Anschließend wird die Inverse Kinematik mit Hilfe der gewichteten Pseudo-Inverse berechnet. Mit der Inversen Kinematik werden die notwendigen Geschwindigkeiten der Einzelverbraucher be-

rechnet, durch deren Überlagerung die vom Bediener vorgegebene Kran-  
spitzengeschwindigkeit erreicht wird.

### 6.1.1 Kinematik des Forstkran

Die Grundlagen für eine Kranspitzensteuerung wurden in Kapitel 2 erör-  
tert. Nachfolgend wird deren Anwendung auf den vorliegenden Forstkran  
mit den zwei möglichen Hydrauliksystemen beschrieben. Im ersten Schritt  
wird in Anlehnung an [61, 4, 81] ein kinematisches Modell des Krans auf-  
gestellt. Dieses bildet, beginnend beim Schwenkwerk, eine offene kinemati-  
sche Kette mit 3 rotatorischen Gelenken und einem translatorischen Gelenk.  
Die Kette endet am Teleskopauge, an welchem der in der Betrachtung ver-  
nachlässigte Rotator und Greifer montiert ist. Abbildung 6.1 stellt den Kran  
mit seinen Gelenken dar.

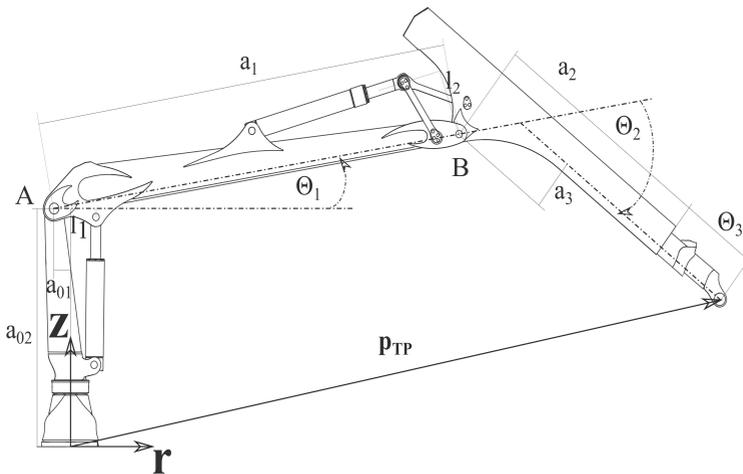


Abbildung 6.1: Forstkran mit seinen Variablen

mit

- $\theta_0$  rotatorisches Gelenk im Schwenkwerk zwischen Kranplatte und -säule
- $\theta_1$  rotatorisches Gelenk im A-Bolzen zwischen Kransäule und Hauptarm
- $\theta_2$  rotatorisches Gelenk im B-Bolzen zwischen Hauptarm und Wipparm
- $\theta_3$  translatorisches Gelenk des Teleskops

Für den weiteren Verlauf des Kapitels wird das Schwenkwerk vernachlässigt und für die Gelenke 1 - 3 die generalisierten Koordinaten  $\theta = [\theta_1, \theta_2, \theta_3]^T$  eingeführt und verwendet. Hierdurch wird die Steuerung des Teleskopauges auf ein 2D-System in der r-z-Ebene reduziert, vgl. Abbildung 6.1. Mit der Vorwärtskinematik kann damit die Position des Endeffektors  $\mathbf{p}_{\text{TP}}$ , in diesem Fall des Teleskopauges, aus den einzelnen Gelenkstellungen berechnet werden:

$$\begin{aligned} \mathbf{p}_{\text{TP}} &= \begin{pmatrix} r(\theta) \\ z(\theta) \end{pmatrix} = \\ &= \begin{pmatrix} a_1 \cos(\theta_1) - a_3 \sin(\theta_1 - \theta_2) + (a_2 + \theta_3) \cos(\theta_1 - \theta_2) - a_{01} \\ a_1 \sin(\theta_1) + a_3 \cos(\theta_1 - \theta_2) + (a_2 + \theta_3) \sin(\theta_1 - \theta_2) + a_{02} \end{pmatrix} \end{aligned} \quad (6.1)$$

Gleichung 6.1 beschreibt das kinematisch redundante System Forstkran: Der Gelenkraum bestehend aus  $\theta_1, \theta_2, \theta_3$  besitzt die Dimension 3, während der Endeffektorraum mit  $r, z$  die Dimension 2 aufweist. Die Kinematik des Forstkrans kann somit generalisiert nach [61, 4] beschrieben werden:

$$\begin{aligned} \mathbf{p}_{\text{TP}} &= f(\theta) \\ \dot{\mathbf{p}}_{\text{TP}} &= \mathbb{J}(\theta) \cdot \dot{\theta} \end{aligned} \quad (6.2)$$

$\dot{\mathbf{p}}_{\text{TP}}$  spiegelt dabei den Geschwindigkeitsvektor des Teleskopauges wider,  $\mathbb{J}$  die Jacoby-Matrix des Systems.

### 6.1.2 Jacoby-Matrizen für das Serien- und HT-System

Während beim Seriensystem die Gelenkgeschwindigkeiten nicht voneinander abhängig sind, sind beim HT-System der Hub- und Wippzylinder unidirektional miteinander gekoppelt. D.h., bei einer Ansteuerung des Wippzylinders wird automatisch der Hubzylinder mitbewegt, eine Ansteuerung des Hubzylinders führt jedoch nicht zur Bewegung des Wippzylinders. Aus diesem Grund müssen die Jacoby-Matrizen für jedes System separat ermittelt werden. Aufbauend auf den kinematischen Zusammenhängen zur Bestimmung des Geschwindigkeitsvektors kann zunächst die Jacoby-Matrix für das Seriensystem bestimmt werden:

$$\mathbb{J}_{\text{Serie}} = \begin{bmatrix} J_{11} & J_{12} & J_{13} \\ J_{21} & J_{22} & J_{23} \end{bmatrix} = \begin{bmatrix} \frac{\partial f_1(\theta)}{\partial \theta_1} & \frac{\partial f_1(\theta)}{\partial \theta_2} & \frac{\partial f_1(\theta)}{\partial \theta_3} \\ \frac{\partial f_2(\theta)}{\partial \theta_1} & \frac{\partial f_2(\theta)}{\partial \theta_2} & \frac{\partial f_2(\theta)}{\partial \theta_3} \end{bmatrix} \quad (6.3)$$

mit

$$J_{11} = -a_1 \sin(\theta_1) - (a_2 + \theta_3) \sin(\theta_1 - \theta_2) - a_3 \cos(\theta_1 - \theta_2)$$

$$J_{12} = (a_2 + \theta_3) \sin(\theta_1 - \theta_2) + a_3 \cos(\theta_1 - \theta_2)$$

$$J_{13} = \cos(\theta_1 - \theta_2)$$

$$J_{21} = a_1 \cos(\theta_1) + (a_2 + \theta_3) \cos(\theta_1 - \theta_2) - a_3 \sin(\theta_1 - \theta_2)$$

$$J_{22} = -(a_2 + \theta_3) \cos(\theta_1 - \theta_2) + a_3 \sin(\theta_1 - \theta_2)$$

$$J_{23} = \sin(\theta_1 - \theta_2)$$

Mit Gleichung 6.3 ergibt sich die Vorwärtskinematik für das Seriensystem:

$$\dot{\mathbf{p}}_{\text{TP}} = \mathbb{J}_{\text{Serie}} \cdot \dot{\boldsymbol{\theta}} \quad (6.4)$$

Für das HT-System muss die Kopplung zwischen Hub- und Wippzylinder berücksichtigt werden. Eine Bewegung des Wipparms ( $\dot{\theta}_2 \neq 0$ ) führt damit automatisch zu einer Bewegung des Hauptarms ( $\dot{\theta}_{1,HT} = k \cdot \dot{\theta}_2$ ). Somit ergibt sich für die Vorwärtskinematik des Endeffektors für das HT-System:

$$\dot{\mathbf{P}}_{\text{TP}} = \mathbb{J}_{\text{Serie}} \cdot \begin{bmatrix} \dot{\theta}_1 + k \cdot \dot{\theta}_2 \\ \dot{\theta}_2 \\ \dot{\theta}_3 \end{bmatrix} = \begin{bmatrix} J_{11} & J_{12} + k \cdot J_{11} & J_{13} \\ J_{21} & J_{22} + k \cdot J_{21} & J_{23} \end{bmatrix} \cdot \begin{bmatrix} \dot{\theta}_1 \\ \dot{\theta}_2 \\ \dot{\theta}_3 \end{bmatrix} = \mathbb{J}_{\text{HT}} \cdot \dot{\theta} \quad (6.5)$$

Die Triebwerke des HT haben das gleiche Schluckvolumen. Der Faktor  $k$  gibt das sich aus dem Volumenstromverhältnis ergebende Verhältnis der Gelenkgeschwindigkeiten  $\dot{\theta}_1$  und  $\dot{\theta}_2$  mittels der jeweiligen Hebelarme an, vgl. Abbildung 6.1:

$$k = \frac{l_1 \cdot A_{\text{IBC},\text{Boden}}}{l_2 \cdot A_{\text{OBC},\text{Stange}}}$$

mit

$l_1$  : Hebelarm Hubzylinder

$l_2$  : Hebelarm Wippzylinder

$A_{\text{IBC},\text{Boden}}$  : Kolbenfläche des Hubzylinders bodenseitig

$A_{\text{OBC},\text{Stange}}$  : Ringfläche des Wippzylinders stangenseitig

### 6.1.3 Die Pseudo-Inverse Lösung und ihre Gewichtungsmatrix

Eine notwendige Grundlage für die Steuerung des Endeffektors ist das Aufstellen dessen Inverser Kinematik. Aufgrund des redundanten Systems Forstkrans mit dem Freiheitsgrad des Teleskops ist eine direkte Invertierung der Kinematik nicht möglich. Die Jacoby-Matrizen, vgl. Gleichung 6.4 und 6.5, sind nicht quadratisch und somit nicht invertierbar.

Aus diesem Grund wird die gewichtete Pseudo-Inverse nach [17, 4] verwendet, um die Inverse Kinematik des Forstkrans zu bilden:

$$\dot{\theta} = \mathbb{W}^+ \cdot \dot{\mathbf{P}}_{\text{TP}} \quad (6.6)$$

Die gewichtete Pseudo-Inverse der Jacoby-Matrix wird mittels der Gewichtungsmatrix  $\mathbb{W}$  gebildet [17, 4]:

$$\mathbb{J}_W^+ = \mathbb{W}^{-1} \mathbb{J}^T (\mathbb{J} \mathbb{W}^{-1} \mathbb{J}^T)^{-1}$$

$\mathbb{W}$  muss hierbei eine positiv definite, symmetrische Matrix sein [92]. Aufgrund der betrachteten Gelenke ergibt sich  $\mathbb{W}$  zu:

$$\mathbb{W} = \begin{bmatrix} w_1 & 0 & 0 \\ 0 & w_2 & 0 \\ 0 & 0 & w_3 \end{bmatrix}$$

Dabei korreliert ein Eintrag  $w_i$  direkt mit dem Gelenk  $\theta_i$ , womit eine Beeinflussung der Gelenkgeschwindigkeiten über die Gewichtungsmatrix möglich ist. Somit können über die Einträge  $w_i$  Optimierungskriterien für die jeweiligen Gelenke in die inverse Kinematik eingebracht werden. Je höher der absolute, positive Wert eines Eintrages  $w_i$  ist, umso geringer wird die Gelenkgeschwindigkeit  $\theta_i$ . Darauf aufbauend werden die Gewichtungen für die einzelnen Gelenke definiert. Die Gewichtungen für die jeweiligen Gelenke sind als Summe aus der konstanten Gelenkgewichtung  $c_i$  und der Gelenkgrenzvermeidung  $JLA_i$  ausgeführt, um verschiedene Einflussfaktoren zu berücksichtigen:

$$w_i = c_i + JLA_i \tag{6.7}$$

**Gelenkgewichtung  $c_i$**  In einem ersten Schritt wird jedem Gelenk eine konstante Gewichtung  $c_i$  zugeordnet. Die Werte der Gewichtungen werden vom Hauptarm absteigend gesetzt, womit der Gewichtungsfaktor für das Teleskop am geringsten ist. Hierdurch wird das Expertenwissen mit verwendet, damit sich dadurch eine Kransteuerung ergibt, welche ähnlich zu einem professionellen Maschinenbediener ist. So ist es beispielsweise bei einem Ausfahren der Kranspitze aufgrund der kinematischen Bedingungen sinnvoll, eine im Vergleich zu den anderen Gelenken hohe Geschwindigkeit des Teleskops zu erreichen. Zudem führt ein starkes Absenken des Hauptarmes während einer Durchforstung zu einem erhöhten Risiko einer Kollision des Kranes mit umstehenden Bäumen. Für den Haupt- und Wipparm sind  $c_1$  respektive  $c_2$  als konstante Werte ausgeführt.

Der Gewichtungsfaktor  $c_3$  für das Teleskop kann entweder konstant oder abhängig vom Radius gesetzt werden, um Anforderungen aus dem realen Einsatz zu berücksichtigen. Hierfür wird der Verlauf des Gewichtungsfaktors  $c_3$  in drei Bereiche gegliedert, vergleiche Abbildung 6.2:

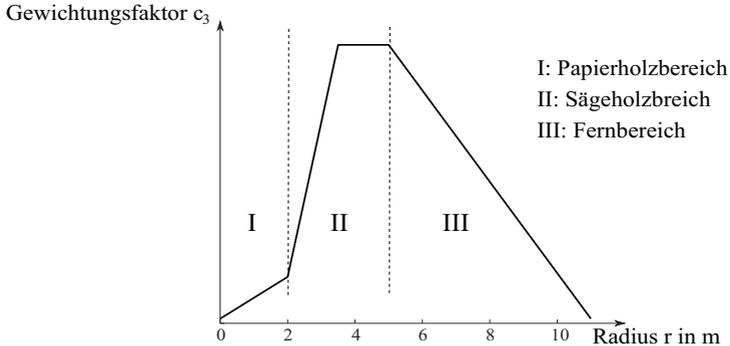


Abbildung 6.2: Bereichsweiser, radiusabhängiger Verlauf des Gewichtungsfaktors  $c_3$

Im ersten Bereich bis zu einem Abstand zum Kranmittelpunkt von 2 m wird der Gewichtungsfaktor sehr gering gesetzt, wobei dieser sich mit steigendem Abstand stetig erhöht. Hierdurch wird beim Laden von Papierholz mit einer Länge von 2 m, welches im forstlichen Hieb direkt an der Rückegasse liegt, vor allem das Teleskop für die vorwiegend vertikale Bewegung der Kranspitze verwendet. Dadurch wird sowohl die Bewegung von Haupt- und Wipparm reduziert, als auch ein Greifen der Stämme ohne Kollision mit umstehenden Bäumen ermöglicht, da durch die nahezu vertikale Position des Wipparms der Kran kaum in den Waldbestand ragt. Zu Beginn des Bereichs II steigt der Gewichtungsfaktor stark an, bis er im Bereich von 3,5 m - 5 m ein Tableau bildet. In diesem Bereich liegen die im realen Betrieb häufig vorkommenden Greifpositionen bei den Stammsortimenten von 3,6 m - 5 m. Im dritten Bereich wird der Faktor  $c_3$  wieder reduziert, wodurch für die weit entfernten Greifpunkte der Freiheitsgrad des Teleskops priorisiert wird.

Mittels der durch Expertenwissen generierten Gewichtung für das Teleskop ( $\theta_3$ ) wird eine Kranspitzensteuerung realisiert, die sich an einen erwarteten Zyklusverlauf einschließlich der einzelnen Gelenkbewegungen orientiert. Zeitgleich unterstützt die

Kranspitzensteuerung das Ausnutzen des Potentials zur Energiereduktion durch das HT-System, da im Radiusbereich II durch  $c_3$  eine erhöhte, simultane Bewegung des Haupt- und Wipparms forciert wird.

**Gelenkgrenzvermeidung  $JLA_i$**  Für eine funktionierende Steuerung des Endeffektors muss eine Strategie für den Fall festgelegt werden, dass ein oder mehrere Gelenke sich auf deren Endanschlag zubewegen oder sich bereits in diesem befinden und somit rein mechanisch keine Bewegung mehr möglich ist. Eine einfache Möglichkeit zur Vermeidung dieser Zustände ist, die Geschwindigkeit des Gelenkes, welches sich im mechanischem (oder auch elektronisch vorgegebenen) Anschlag befindet, zu 0 vorzugeben. Damit löst sich die Redundanz des Systems auf, die Jacoby-Matrix ist als  $2 \times 2$  Matrix invertierbar und die notwendigen Gelenkgeschwindigkeiten direkt aus der Sollvorgabe der Endeffektorgeschwindigkeiten berechenbar [74]. Nachteil hierbei ist jedoch das daraus resultierende unstetige Verhalten der Gelenkgeschwindigkeiten. Aus diesem Grund wird in der vorliegenden Arbeit in Anlehnung an [92] der Endanschlag über das Einfügen einer Kostenfunktion vermieden (engl.: Joint Limit Avoidance JLA). Hierbei wird der Gewichtungsfaktor  $JLA_i$  gesetzt zu:

$$JLA_i = \begin{cases} \left| 50 \cdot \frac{2 \cdot \theta_{i,norm} - 1}{4 \cdot (1 - \theta_{i,norm}) \cdot \theta_{i,norm}} \right| & \text{wenn } \Delta |JLA_i| > 0 \\ 0 & \text{wenn } \Delta |JLA_i| \leq 0 \end{cases}$$

Um die Funktion, deren Verlauf in Abbildung 6.3 dargestellt ist, für alle Gelenke verwenden zu können, werden die zwischen 0 und 1 normierten Gelenkwinkel  $\theta_{i,norm}$  verwendet. Vorteil dieses Vorgehens im Vergleich zur festen 0-Vorgabe der Gelenkgeschwindigkeit ist die stetige Reduzierung der jeweiligen Gelenkgeschwindigkeit. Hierdurch wird ein abruptes Stoppen eines Gelenks, einhergehend mit dem daraus resultierenden Schwingungseintrag in das Hydrauliksystem und die Kinematik, vermieden. Zudem kann dadurch softwareseitig konsistent die gewichtete Pseudo-Inverse zur Berechnung der inversen Kinematik verwendet werden, wodurch kein Wechsel auf ein kinematisches System mit 2 Freiheitsgraden einschließlich dessen direkt invertierbarer Jacoby-Matrix notwendig ist.

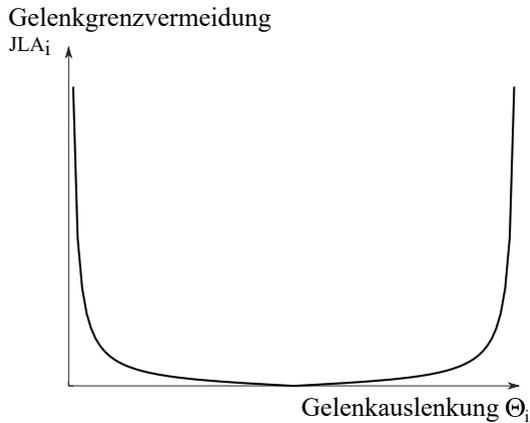


Abbildung 6.3: Verlauf des Gewichtungsfaktors  $JLA_i$  zur Vermeidung der Gelenkgrenzen: Um das Anfahren eines Gelenkes in einen seiner Endanschläge zu vermeiden, steigt der Gewichtungsfaktor zum Minima und Maxima der Gelenkauslenkungen an

### 6.1.4 Ventilansteuerung

Aus den Gelenkgeschwindigkeiten  $\dot{\theta}_1$  und  $\dot{\theta}_2$  wird über den aktuellen Hebelarm  $l_1(\theta_1)$  respektive  $l_2(\theta_2)$  die translatorische Zylindergeschwindigkeit  $\dot{x}_{Zyl,i} = \dot{\theta}_i \cdot l_i$  für den IBC und OBC berechnet. Aufgrund des Doppelteleskops beträgt die Geschwindigkeit des Teleskopzylinder  $\dot{x}_{Zyl,3} = 0,5 \cdot \dot{\theta}_3$  die Hälfte der translatorischen Geschwindigkeit von Gelenk 3.

Unter Berücksichtigung der aktuell wirkenden Kolben- oder Ringfläche  $A_{i,j}$  kann der benötigte Volumenstrom  $Q_i$  für die jeweilige Geschwindigkeit berechnet werden:

$$Q_i = \dot{x}_{Zyl,i} \cdot A_{i,j}$$

Die Einzelsektionen des Ventilblocks wurden separat für jede Funktion vermessen und somit der Zusammenhang zwischen dem elektrischen Ansteuerstrom der Ventilsektion und dem sich daraus ergebenden Volumenstrom ermittelt, vgl. Abbildung 6.4. Aufbauend auf diesen Kennfeldern wird der zu  $Q_i$  korrelierende Ventilstrom  $I_i$  vom Steuergerät ausgegeben. Aufgrund der positiven Überdeckung der Ventilschieber, welche zur Reduzierung der inneren Leckage und damit einer Vermeidung bspw.

des Absinken des Hubarmes verwendet werden, ergibt sich erst ein Volumenstrom ab dem minimalen Ventilstrom des Ventils

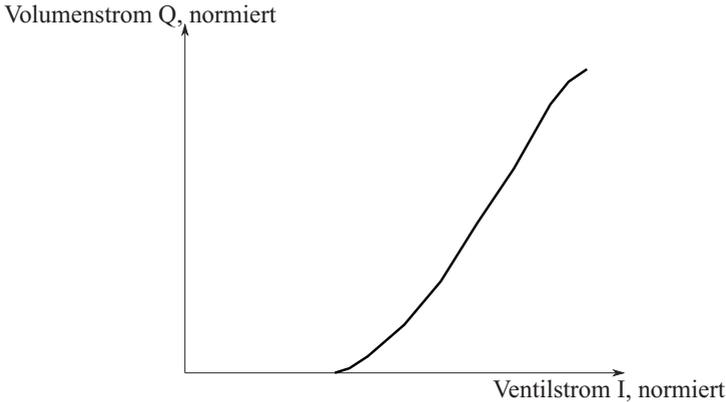


Abbildung 6.4: Zusammenhang zwischen normierten Volumenstrom  $Q$  und normierten Ventilstrom  $I$ : Volumenstrom steigt aufgrund der positiven Überdeckung des Ventilschiebers ab dem Minimalstrom des Ventils stetig an

Die Kranspitzensteuerung ist als reine Steuerung ausgeführt. Der Bediener schließt den Regelkreis durch seine Funktion als Regelglied.

### 6.1.5 Genauigkeit der Kranspitzensteuerung

Für die Evaluation der Genauigkeit der Kranspitzensteuerung wird eine horizontale Aus- und Einfahrbewegung der Kranspitze vorgegeben, indem ausschließlich eine konstante Geschwindigkeitskomponente in r-Richtung aufgeprägt wird. Dies führt zu dem in Abbildung 6.5 gezeigten Positionsverlauf der Kranspitze in r- und z-Richtung. Hierbei zeigt sich, dass der radiale Verlauf erwartungsgemäß monoton steigend respektive fallend für die Aus- respektive Einfahrbewegung ist. Dem entgegen zeigt sich für die vertikale Position der Kranspitze ein Toleranzband von 0,23 m, in welchem es sich während des Versuch bewegt.

Zur Analyse dieser, vor allem für den Realbetrieb, geringfügigen Abweichung werden die Ist- und Sollgeschwindigkeiten der Gelenke untersucht, vgl. Abbildung 6.6. Hierbei ist erkennbar, dass die Ist-Geschwindigkeit der Sollvorgabe im Allgemeinen

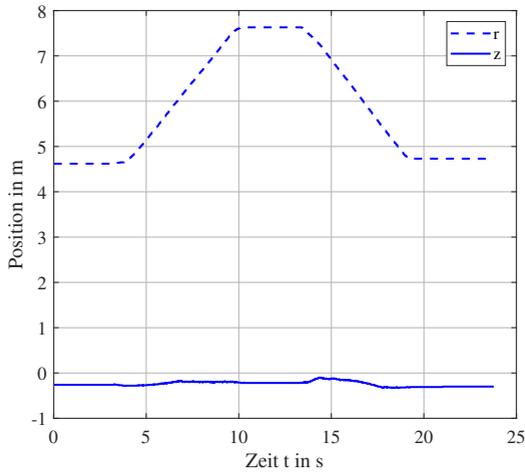


Abbildung 6.5: Evaluation der Positionsgenauigkeit der Kranspitze in r- und z-Richtung

sehr gut folgt, jedoch beim Einleiten einer Bewegung bei den Gelenken  $\theta_1$  und  $\theta_2$  eine signifikante Abweichung vorliegt.

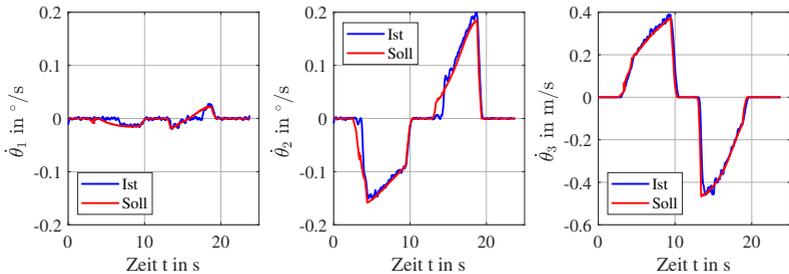


Abbildung 6.6: Evaluation der Genauigkeit der Geschwindigkeiten der Gelenke von Hauptarm  $\theta_1$ , Wipparm  $\theta_2$ , Teleskop  $\theta_3$

Durch Messdatenaufnahme wurde bei singulärer Bewegung der Gelenke nachgewiesen, dass die Drehgeber im A-Bolzen für den Hauptarm und im B-Bolzen für den Wipparm ein Totspiel bei einer Bewegungsumkehr von ca.  $4,0^{\circ}$  aufweisen, vgl. Abbildung 6.7. Aufgrund des Totspiels liegt beim Hauptarm  $\theta_1$  eine Geschwindig-

keitsabweichung beginnend bei  $t = 6,0 \text{ s}$  und  $t = 18,2 \text{ s}$  vor, da hier jeweils eine Bewegungsumkehr erfolgt. Da bei  $t = 15,1 \text{ s}$  keine Bewegungsumkehr bei  $\theta_1$  erfolgt (vgl. die ebenfalls negative Winkelgeschwindigkeit im Bereich  $t = 5,0 \text{ s}$  bis  $t = 10,0 \text{ s}$ ), wird die Ist-Geschwindigkeit von Bewegungsbeginn an korrekt gemessen.

Bei  $t = 18,1 \text{ s}$  befinden sich alle Gelenke seit einer ausreichenden Zeitspanne in Bewegung, womit die Auswirkungen der Bewegungsumkehr keinen Einfluss mehr aufweisen. Die Abweichungen in der  $z$ -Position von  $-0,09 \text{ m}$  vor der Richtungs- umkehr und von  $-0,17 \text{ m}$  am Ende der kompletten Bewegung, vgl. Abbildung 6.5, resultieren aus geringfügigen Abweichungen in der Ist-Geschwindigkeit, welche auf Abweichungen in dem vermessenen I-Q-Kennfeld für die einzelnen Ventilsektionen zurückzuführen sind.

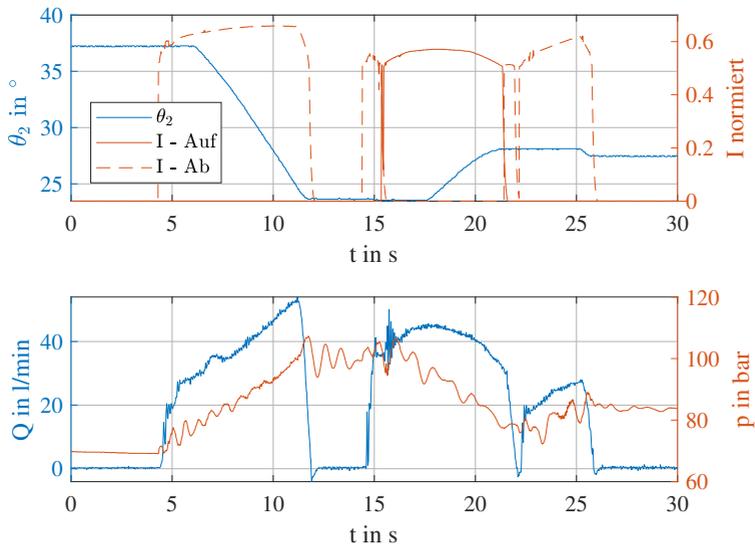


Abbildung 6.7: Evaluation des Sensortotwegs des Drehgebers am A-Bolzen

### 6.1.6 Bediener- und umfeldangepasste Kransteuerung

Mit den in Kapitel 6.1.3 beschriebenen Gelenkgewichtungen  $c_i$  kann die Kranspitzensteuerung für unterschiedliche Bediener individualisiert werden. Während erfahrene Bediener eine hohe Geschwindigkeit des Teleskops bevorzugen ( $c_3$  eine Größenordnung geringer als  $c_1, c_2$ ), ist dies für ungeübte Bediener nicht sinnvoll. Hier weisen die Gelenkgewichtungen eine ähnliche Größenordnung auf.

Weiterhin sind unterschiedliche Parametersätze der Gelenkgewichtungen für den Einsatz bei der Starkholzernte und für eine Durchforstung auf dem Steuergerät abgelegt. Eine Durchforstung zeichnet sich durch einen sehr dichten Bestand aus, in welchem Stämme mit geringem Durchmesser und dadurch geringem Gewicht geladen werden. Unter diesen Bedingungen soll vor allem das Teleskopverfahren werden, damit eine Kollision von Haupt- und Wipparm mit den dicht stehenden Bäumen vermieden wird. Dafür wird die Gelenkgewichtung  $c_3$  über den gesamten Radiusbereich hinweg auf ihren Minimalwert gesetzt, vgl. Bereich I in Abbildung 6.2.

Dazu gegensätzlich soll bei der Starkholzernte das Teleskop so wenig wie möglich ausgefahren werden. Damit wird zum Anheben der Stämme hauptsächlich der Hubzylinder genutzt, welcher aufgrund seines Kolbendurchmessers das maximale Hubmoment aufbringen kann. Hierzu wird die Gelenkgewichtung  $c_3$  im Vergleich zu  $c_1, c_2$  signifikant größer gesetzt, wodurch die Bewegungen von Haupt- und Wipparm priorisiert werden.

Die Auswahl der verschiedenen Modi erfolgt aktiv durch den Bediener über ein separates Bedienelement. Wird keine Individualisierung oder Spezifizierung auf die aktuelle Erntesituation durch den Bediener vorgenommen, wird die Kranspitzensteuerung wie in Kapitel 6.1.3 beschrieben als Standard verwendet, wobei der Verlauf von  $c_3$  nach Abbildung 6.2 integriert ist. Im weiteren Verlauf der Arbeit wird nur diese Spezifikation verwendet und betrachtet.

## 6.2 Assistenzsystem AutoLoad: Automatisierter Lade- und Greifprozess

Die Steuermodule des automatischen Bewegens und Greifens sind in die Architektur des Assistenzsystems integriert, vgl. Abbildung 3.1. Die grundlegende Methode für das Assistenzsystem ist, dass der notwendige Geschwindigkeitsvektor für eine au-

tomatische Kranbewegung innerhalb eines Zustandsautomaten berechnet wird und danach an das Steuermodul Kranspitzensteuerung, vgl. Kapitel 6.1, weitergegeben wird. Dadurch wird eine generalisierte Maschinensteuerung umgesetzt und auf dem Forwarder implementiert. Dabei kann die Vorgabe des Geschwindigkeitsvektors für die Kranspitze entweder manuell durch den Bediener oder automatisch durch die Ausgabe des Assistenzsystems gesetzt werden.

Zur Umsetzung eines automatisierten Lade- und Greifprozesses müssen die dafür nötigen Bewegungsabläufe eingehalten werden. Dies ist mittels eines Zustandsautomaten möglich. Das Assistenzsystem, und damit der Zustandsautomat, wird durch Drücken und Halten des Wippschalters am linken Joystick aktiviert. Sobald der Schalter nicht mehr betätigt ist, werden jegliche Vorgaben durch das Fahrerassistenzsystem beendet und der Kran reagiert auf die manuellen Bedienervorgaben. Durch diese Sicherheitsfunktion ist gewährleistet, dass der Bediener jederzeit die Kontrolle über die Kranbewegung besitzt und dadurch auf unvorhergesehen Änderungen des Umfelds reagieren kann. Das Ablaufdiagramm des Zustandsautomaten ist in Abbildung 6.8 dargestellt. Der Zustandsautomat erhält die Informationen aus der Objekterkennung sowie Sensordaten und Bedienereingaben vom Forwarder. Im Zustandsautomaten werden mit diesen die Sollvorgaben berechnet, welche als Geschwindigkeitsvektor der Kranspitze an die Kranspitzensteuerung und als Steuersignale für den Greifer an den Forwarder ausgegeben werden.

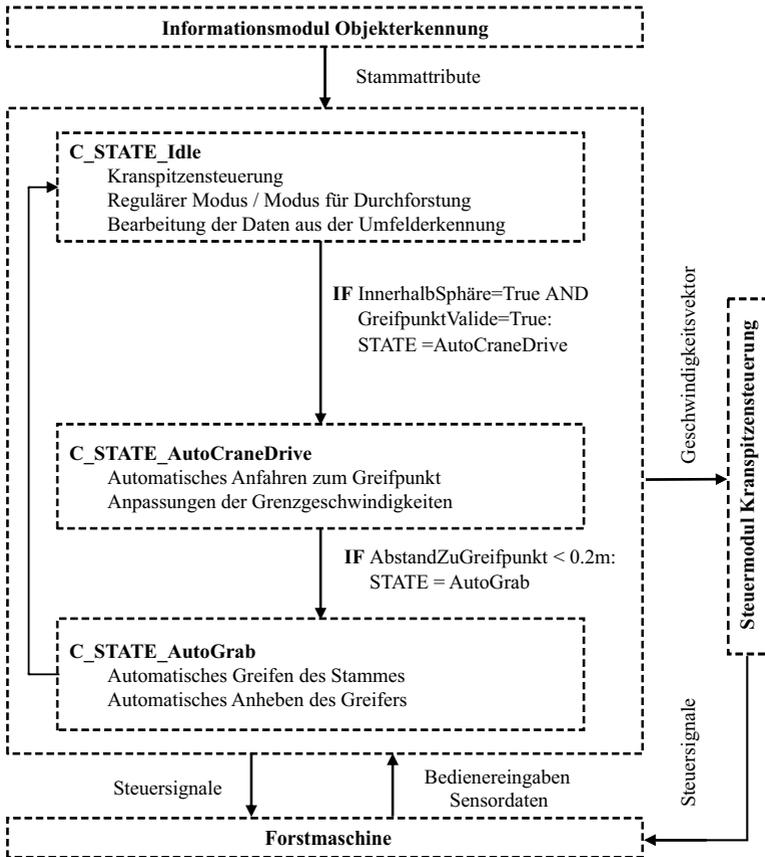


Abbildung 6.8: Ablaufdiagramm der Zustandsautomaten zum Assistenzsystem AutoLoad

### 6.2.1 Initialzustand *Idle*

Im ersten Zustand des Zustandsautomaten, *Idle*, nimmt das Assistenzsystem nur passive Funktionen wahr und gibt keine Steuersignale aus. Der Kran wird mit Hilfe der Kranspitzensteuerung vom Bediener manuell aktuiert, wobei diese im regulären Modus oder im Modus für die Durchforstung betrieben werden kann. Der sich aus den Bedienvorgaben ergebende Geschwindigkeitsvektor wird direkt an das Steuermodul Kranspitzensteuerung übermittelt. Simultan werden die Eingangssignale aus dem Informationsmodul Objekterkennung, im Speziellen die Greifposition eines sich im Bild befindenden Stammes, und den Sensordaten der Forstmaschine verarbeitet. Hierbei wird kontinuierlich der Abstand des Teleskopauges zum Stamm berechnet. Unterschreitet dieser Abstand einen festgelegten Grenzwert, so wird geprüft, ob in den nächsten Zustand des Zustandsautomaten gewechselt werden kann. Bildhaft veranschaulicht lässt sich dies so vorstellen, dass die Kranspitze in eine Sphäre um den Greifpunkt mit dem festgelegten Radius eintritt, vgl. Abbildung 6.9. Außerhalb der Sphäre wird der Kran manuell gesteuert, innerhalb der Sphäre bei aktiviertem Assistenzsystem automatisch.

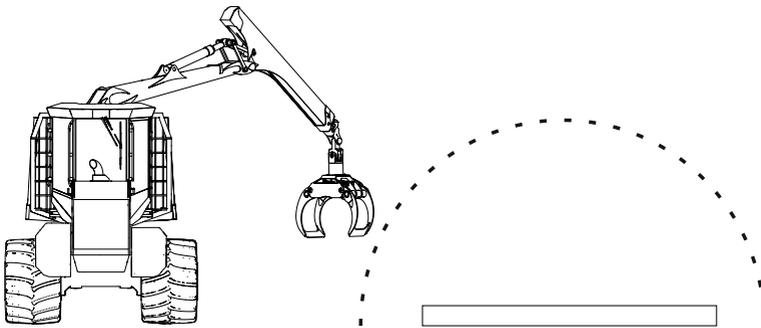


Abbildung 6.9: Veranschaulichung der Sphäre um den zu greifenden Stamm.

In diesem Fall wird überprüft, ob die Position des Greifpunktes innerhalb des zulässigen Arbeitsbereiches liegt. Dies stellt eine einfache Sicherheitsfunktion dar, damit der Kran Kollisionen vermeidet. Der zulässige Arbeitsbereich ist durch die maximale Kranreichweite auf der einen Seite und die Maschinenumrisse von Vorder- und Hinterwagen auf der anderen Seite begrenzt. Werden die beiden Bedingungen

erfüllt, wechselt der Zustand im Zustandsautomaten von *Idle* auf *AutoCraneDrive*. Der zulässige Arbeitsbereich kann zukünftig um eine Prädiktion der Standsicherheit ergänzt werden.

Bei dem Zustandswechsel wird der Greifpunkt als fixer Zielpunkt für die automatische Kranbewegung an den darauffolgenden Zustand übergeben, wobei in seiner z-Komponente der Stammdurchmesser einberechnet wird. Damit ist die z-Position unabhängig vom Durchmesser der Stämme derart definiert, dass sich bei Erreichen des Greifpunkts die Greiferspitzen immer wenige Zentimeter über dem Untergrund befinden. Zudem wird der aktuelle Geschwindigkeitsvektor der Kranspitze bei Eintritt in die Sphäre mit übermittelt.

### 6.2.2 Automatische Kranbewegung *AutoCraneDrive*

Ausgehend von der aktuellen Kranposition werden die benötigten Komponenten des Geschwindigkeitsvektors der Kranspitze zum Greifpunkt hin berechnet. Hierzu wird die Soll-Bewegungsrichtung ermittelt, indem Kranspitze und Greifpunkt über eine Gerade miteinander verbunden werden. Dies entspricht dem geringsten Abstand zwischen den beiden und dient dadurch als zeit-optimale Trajektorie. Anschließend wird die Länge des Vektors skaliert, damit dessen Betrag der gewünschten Geschwindigkeit entspricht.

Dieser Geschwindigkeitsverlauf ist in Abbildung 6.10 dargestellt, wobei er sich in 3 Bereiche aufteilt. Im ersten Bereich wird kontinuierlich die Geschwindigkeit der Kranspitze vom Wert bei Sphäreneintritt auf die vorgegebene Maximalgeschwindigkeit  $v_{max}$  angepasst. Dies hat den Effekt, dass kein Sprung in der Geschwindigkeit vorliegt und somit Schwingungen des Systems vermieden werden. Das Vorgehen ist sowohl möglich, wenn mit einer höheren als auch niedrigeren Geschwindigkeit als  $v_{max}$  in die Sphäre eingefahren wird, vgl. die beiden Strichlinien. Letzteres tritt vor allem bei ungeübten Bedienern auf, wodurch sich im Vergleich zu einem Beibehalten der geringeren Geschwindigkeit ein zeitlicher Vorteil bei der Bewegung ergibt. Zeitgleich wird in diesem Bereich kontinuierlich die Richtung des Geschwindigkeitsvektors angepasst, wieder ausgehend von der Bewegungsrichtung bei Eintritt in die Sphäre, zu der in jedem Zeitschritt berechneten Bewegungsrichtung des geringsten Abstandes. Dadurch wird eine ruckhafte Richtungsänderung der Kranspitze

vermieden, welche ein Pendeln des Greifers und eine deutliche Schwingungsexposition der Maschine und damit des Bedieners zur Folge hätte. Die Abstraktion einer Sphäre und das darauffolgende Vorgehen bieten den Vorteil, dass alle Möglichkeiten abgedeckt sind, wie an den Stamm herangefahren werden kann, und stellt damit die Funktion des Assistenzsystems bei unkonventionellen Bewegungen durch ungeübte Bediener sicher.

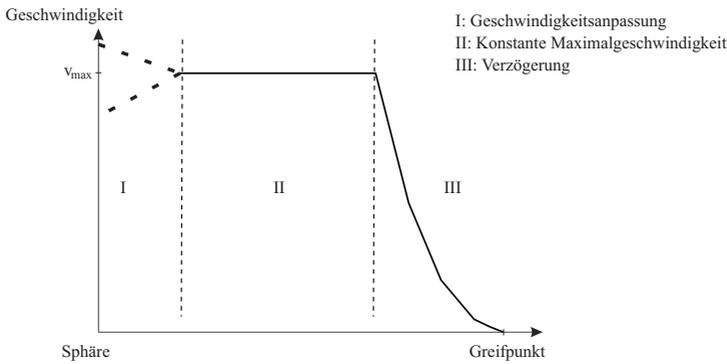


Abbildung 6.10: Bereichsweiser Geschwindigkeitsverlauf der Kranspitze in Abhängigkeit zum Abstand des Greifpunkts, welcher durch das Assistenzsystem gesetzt wird

Im zweiten Bereich wird die Kranspitze mit maximaler Geschwindigkeit bewegt, um eine möglichst hohe zeitliche Effizienz zu erreichen. Darauffolgend wird der dritte Bereich eingeleitet, in welchen die Geschwindigkeit annähernd parabolisch zu Null hin reduziert wird. Aufgrund der dadurch konstanten Verzögerung der Kranspitze wird ein Pendeln des Greifers reduziert.

Sobald die Kranspitze in einem Abstand von wenigen Zentimetern vom Greifpunkt entfernt ist, wird in den nächsten Zustand *AutoGrab* übergegangen. Diese Vereinfachung im Zentimeterbereich liegt im Sensortoleranzbereich der Stereokamera und ist im Forst zulässig. Der Vorteil hierbei ist, dass es nicht zu einem Aufschwingen des Systems um den Greifpunkt herum kommen kann, wenn die Kranbewegung aufgrund der Systemträgheit und den Dämpfungen in der Hydraulik nicht exakt am Greifpunkt gestoppt wird

### 6.2.3 Automatisches Greifen *AutoGrab*

Am Greifpunkt angekommen und somit im Zustand *AutoGrab*, wird das automatische Greifen des Stammes begonnen. Hierzu wird durch den Zustandsautomaten direkt das Steuersignal zum Schließen des Greifers vorgegeben, wobei der Greifer zu Beginn des Zustandes komplett geöffnet ist. Bei einer Bewegung der Greiferschalen verändert sich aufgrund des kinematischen Zusammenhangs der Anlenkpunkte die z-Position der Greiferspitzen, vgl. Abbildung 6.11. Bei vollständig geöffnetem Greifer, siehe linke Skizze des Greifers, ist der Greiferzylinder komplett eingefahren. Wird dieser ausgefahren und der Greifer geschlossen, bewegen sich die Greiferspitzen in die negative z-Richtung, bis kurz vor der rechts im Bild gezeigten Greiferanordnung das Minimum der Greiferspitzenposition erreicht ist. Ist die rechts dargestellte Greiferanordnung erreicht, haben sich die Greifspitzen bereits wieder in positive z-Richtung bewegt. Dieser Effekt ist für die nachfolgend beschriebene Ausgleichsbewegung besonders wichtig, da dünne Stämme in der minimalen z-Position der Greifspitzen nicht umfasst werden.

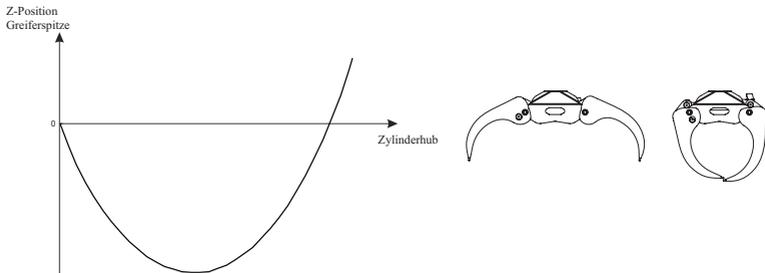


Abbildung 6.11: Positionsverlauf der Greiferspitze in vertikaler Richtung in Abhängigkeit des Zylinderhubs einschließlich graphischer Visualisierung

Durch das Setzen des Greifpunktes und dem automatischen Anfahren im Zustand *AutoCraneDrive* befinden sich die Greiferspitzen zu Beginn des Zustandes *AutoGrab* wenige Zentimeter vom Boden entfernt, ohne dass dieser berührt wird. Würde der Greifer nun ohne weitere Maßnahmen geschlossen werden, würden die Greiferspitzen in den Boden eindringen. Dieser Grabprozess würde demnach zu einer Bodenschädigung führen. Zum anderen wird Humusmaterial mit aufgeladen und führt

zu einer Verunreinigung des Endproduktes Holz, was vor allem für die Zellstoffproduktion negative Folgen hätte. Aus diesem Grund wird parallel zu dem Schließen des Greifers in Anlehnung an [108] die Kranspitze angehoben, um das Eindringen in den Boden zu vermeiden. Zusätzlich wird die Bewegung jedoch derart ausgeführt, dass beim kompletten Greifprozess keine Positionsänderung der Greiferspitzen in  $z$ -Richtung auftritt, womit auch schwaches Holz geladen werden kann, welches bei einem reinen Anheben der Kranspitze nicht umschlossen werden könnte.

Der kinematische Zusammenhang zwischen Greiferspitzenposition und Zylinderhub  $x_{Greifer}$

$$z_{Greiferspitze} = f(x_{Greifer})$$

ist mittels eines Polynoms 5. Grades angenähert. Über die Ableitung des Polynoms wird die Geschwindigkeit der Greifspitzen beim Schließen bestimmt, wodurch diese von der aktuellen Position und der Geschwindigkeit des Greiferzylinders abhängig ist:

$$\dot{z}_{Greiferspitze} = f(x_{Greifer}, \dot{x}_{Greifer})$$

Die Zylindergeschwindigkeit wird über die Zylinderfläche direkt aus dem Kennfeld von Volumenstrom zu Ventilstrom bestimmt, vgl. Abbildung 6.4. Die Position des Zylinders wird über die Integration der Zylindergeschwindigkeit berechnet, wobei der Zylinder beim Übergang von *AutoCraneDrive* zu *AutoGrab* komplett eingefahren ist. Während des Schließvorgang wird von dem Zustandsautomaten die negative Greiferspitzen geschwindigkeit  $\dot{z}_{Soll} = -\dot{z}_{Greiferspitze}$  an die Kranspitzensteuerung weitergegeben, wodurch eine Bewegung der Kranspitze resultiert. Diese führt dazu, dass sich die Greiferspitzen beim Schließen parallel über den Boden bewegen. Damit wird eine Bodenpenetration mit den genannten Nachteilen vermieden. Der Schließvorgang wird ausgeführt, bis die Greiferschalen mögliche Stämme vollkommen umschlossen haben (vgl. Abbildung 6.11, rechts), d.h. bis der Zylinderhub des Greiferzylinders und der Druck im Greiferzylinder einen festgelegten Wert übersteigen. Dadurch wird sichergestellt, dass der Greiferinhalt fest umschlossen ist, und die Stämme nicht herausrutschen können. Wenn die beiden genannten Bedingungen im letzten Zustand *AutoGrab* des Zustandsautomaten erfüllt sind, ist der Vorgang

des automatischen Greifens abgeschlossen, und die Kranspitze wird wieder manuell vom Bediener durch seine Joystickeingaben gesteuert.

Die Funktion des Assistenzsystems *AutoLoad* für einen teilautomatisierten Ladeprozess wurde unter Laborbedingungen und realen Einsatzbedingungen verifiziert. Die Ergebnisse der Tests werden im folgenden Kapitel dargestellt.



## 7 Ergebnisse und Validierung des Assistenzsystems

Die Auswirkungen des Assistenzsystems *AutoLoad* hinsichtlich einer Änderung der Produktivität sowie des Energiebedarfs werden mit Hilfe des Referenzzyklus in einer Laborumgebung für verschiedene, ungeübte Bediener untersucht. Zudem wird der Einfluss der Energieregeneration im HT-System separat analysiert. Abschließend wird die Genauigkeit der datenbasierten Kranwaage betrachtet, welche ein Produktivitätsmaß im Realeinsatz ermöglicht.

### 7.1 Evaluation der Produktivitätsänderung im Referenzzyklus

In einer Messkampagne zur Produktivitäts- und Energiebedarfsanalyse führten 2 ungeübte Bediener den Referenzzyklus in Anlehnung an [81] jeweils 30 mal mit der Seriensteuerung im Serien-System und im HT-System (vgl. Kapitel 4.1.2) mit dem Assistenzsystem *AutoLoad* aus.

Um die Produktivität der verschiedenen Bediener zu evaluieren, wird diese in der reproduzierbaren Laborumgebung als Zykluszeit pro Referenzzyklus definiert. Die für den Realeinsatz mögliche Definition als Quotient aus geladener Masse zu Zykluszeit pro Ladezyklus wird hier nicht verwendet, da das Stammgewicht im Referenzzyklus fest definiert ist und sich während den Versuchen nicht ändert.

In Abbildung 7.1 ist die Zykluszeit für Bediener 1 (B1) und Bediener 2 (B2) für die jeweiligen Steuerungssysteme aufgeführt. B1 weist mit der Seriensteuerung eine minimale Zykluszeit von 28,1 s und eine maximale Zykluszeit von 49,1 s auf, wobei der Median bei 36,5 s liegt. Die minimale respektive maximale Zykluszeit für B2 liegt bei 30,1 s respektive 59,8 s, der Median bei 38,8 s. Weiterhin ist zu beobachten, dass die Ladezyklen von B2 eine höhere Standardabweichung im Vergleich zu B1 aufweisen (9,0 s zu 6,0 s). Auffällig ist die geringe Abweichung der minimalen Zykluszeit beider Bediener im Vergleich zur maximalen (2 s zu 10,7 s). Hieraus kann

geschlossen werden, dass für Bediener dieses Qualifikationslevels eine Untergrenze besteht, wie schnell der Referenzzyklus ausgeführt werden kann.

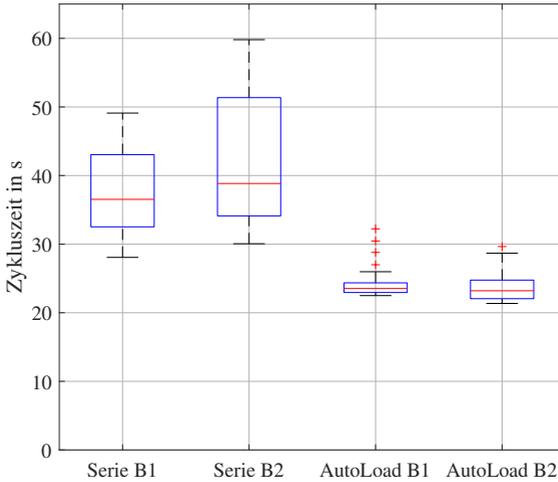


Abbildung 7.1: Vergleich der Zykluszeit von 2 ungeübten Fahrern zur Produktivitätsanalyse

Für das Ausführen des Referenzzyklus mit dem Assistenzsystem *AutoLoad* benötigt B1 minimal 22.5 s und maximal 32.2 s. Der Median liegt bei 23,5 s, die Standardabweichung beträgt 2,4 s. Bei B2 ergibt sich die Unter- und Obergrenze zu 21,4 s respektive 29,6 s mit einem Median von 23.2 s. Mit einer Standardabweichung von 2,2 s liegt die Varianz von B2 geringfügig unter der von B1.

Aus der Betrachtung der Produktivitätsanalyse lassen sich zwei Hauptkenntnisse ableiten: Zum einen ergibt sich, bezogen auf den Median, bei aktivem Assistenzsystem *AutoLoad* eine Reduktion der Zykluszeit um 35,6 % bei B1 und 40,2 % bei B2. Zum anderen verringert sich die Streuung der Zykluszeit bei beiden Bedienern bei aktivem Assistenzsystem signifikant (B1: - 60%, B2: - 75%).

Ursächlich für die Reduktion der Zykluszeit und Standardabweichung in den vorliegenden Messkampagne sind mehrere Effekte, welche sich teilweise überlagern. Die Anfahrbewegung zum Stamm hin wird schneller und gleichmäßiger mit dem Assistenzsystem ausgeführt, vgl. Abbildung 7.2 oben.

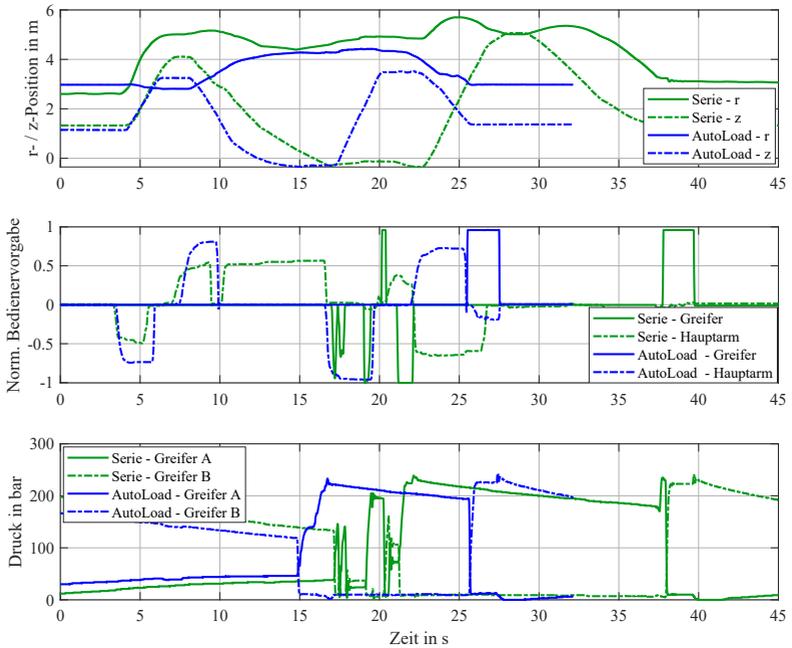


Abbildung 7.2: Kranposition, Bediener-signale und Greiferdrücke für die konventionelle Steuerung und das Assistenzsystem für Bediener 1

Der Greifprozess selbst verkürzt sich deutlich, da mit dem Assistenzsystem dieser sofort erfolgreich ausgeführt wird, ohne ein Nachjustieren oder Korrekturingriffe. Beim manuellen Greifen werden oftmals mehrere Versuche benötigt, den Stamm an der richtigen Stelle vollständig zu umgreifen und nicht nur zwischen den Greiferspitzen einzuklemmen. Dies ist in Abbildung 7.2, Mitte und unten, zu sehen. Die vom Bediener ausgegebenen Signale, dargestellt in der grünen Volllinie, sind unständig, wobei es wiederholte Signale zum Schließen des Greifers ( $t = 16,5 \text{ s} - 19,5 \text{ s}$ ) gibt und der Greifer bei  $t = 20,5 \text{ s}$  wieder ein Stück geöffnet wird. Erst danach wird der Greifer bei  $t = 22 \text{ s}$  vollständig geschlossen. Durch das Assistenzsystem erfolgt die Ladephase II in einem kontinuierlichen Greifvorgang, was zu nur einer Druckspitze bei  $t = 16,2 \text{ s}$  führt, vgl. 7.2 unten. Diese Druckspitze ist zeitgleich mit Positionsänderung in r- und z-Richtung der Nachweis, dass der hier dargestellte Zyklus durch

das Assistenzsystem ausgeführt wurde, da im Zeitbereich von  $t = 10\text{ s}$  bis  $t = 16,2\text{ s}$  keine manuellen Bedienvorgaben vorliegen, vgl. die blauen Linien in Abbildung 7.2, Mitte.

In Abbildung 7.3 ist die Dauer der jeweiligen Zykluszeit in chronologischer Reihenfolge der Datenaufnahme für Bediener 2 mit der Seriensteuerung dargestellt. Die Zykluszeit liegt in den ersten 6 Zyklen über 50 s, fällt im Anschluss ab und variiert zwischen 30 s und 56 s. Das lässt auf einen Lerneffekt des Bediener schließen. Während dieser zu Beginn mit einem Median von 53,5 s durchgehend eine lange Zykluszeit aufweist, reduziert sich diese im Median zu 37,4 s, betrachtet für die Messungen 7 - 30. Somit kann davon ausgegangen werden, dass die in blau abstrahierte Lernkurve ab ca. dem 15. Referenzzyklus einen horizontalen Verlauf annimmt.

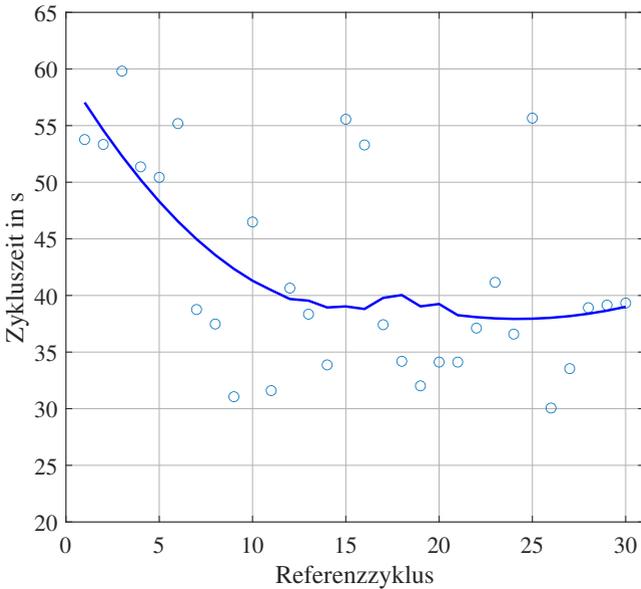


Abbildung 7.3: Verlauf der Zykluszeiten zur Beurteilung der Lernkurve von Bediener 2

Basierend auf dieser Annahme wird prognostiziert, dass temporär in einem Zeitbereich von Stunden voraussichtlich kein weiterer Lerneffekt bei fortlaufender Aus-

übung der Arbeitstätigkeit eintreten wird. Wird davon ausgehend die Zykluszeit mit dem Assistenzsystem *AutoLoad* von 23,2 s im Verhältnis zu der um dem Lerneffekt bereinigten Zykluszeit im Seriensystem von 37,4 s betrachtet, so ergibt sich eine Reduktion um 38,0 %. Im Rahmen dieser Arbeit war eine Betrachtung der Auswirkungen des Assistenzsystems in einer Zeitskala von Wochen oder Monaten hinsichtlich der Zykluszeit und eines sich dann wohl einstellenden Lerneffekts nicht möglich.

Das Resultat, dass die Automatisierung mittels des Assistenzsystems zu einer signifikant verringerten Zykluszeit bei ungeübten Bedienern führt, deckt sich mit den Ergebnissen aus [43, 25]. Ebenso ist gleich, dass ungeübte Bediener auch mit Assistenzsystem nicht die Produktivität von geübten Bedienern erreichen, vgl. Abbildung 7.6 aus Kapitel 7.3. Die Erkenntnis von einer geringeren Streuung der Produktivität bei ungeübten Bedienern kann vor allem für Forstdienstleister die Planungssicherheit erhöhen, wodurch eine Wertschöpfung in der Transportkette entsteht.

## 7.2 Evaluation des Energiebedarfs im Referenzzyklus

Mit der Seriensteuerung und dem Seriensystem benötigt der Bediener 1, respektive der Bediener 2, minimal 118,4 Wh resp. 84,3 Wh und maximal 190,5 Wh respektive 136,6 Wh pro Zyklus, vgl. Abbildung 7.4.

Der Median liegt bei 138,6 Wh respektive 98,7 Wh. Durch die Verwendung des Assistenzsystems ergibt sich für B1, respektive B2, ein minimaler Energiebedarf von 90,4 Wh respektive 81,5 Wh sowie ein Maximalwert von 102,1 Wh respektive 106,3 Wh, der Median liegt bei 97,3 Wh respektive 94,3 Wh. Dadurch ergibt sich eine Energiereduktion, bezogen auf die Mediane, von 29,8 % für B1 und 4,5 % für B2.

Bei der Analyse des Energiebedarfs ist der deutliche Unterschied zwischen den beiden Bedienern im Seriensystem auffällig. Bei ungefähr gleicher Produktivität, vgl. Abbildung 7.1, benötigt B2 nur ca. 72 % der Energie von B1. Die Ursache hierfür liegt in einem verringerten Leistungsbedarf aufgrund der im Vergleich zu B1 reduzierten Ansteuerung und Bewegung des Wipparms  $\theta_2$ , vgl. Abbildung 7.5, wodurch vor allem das Druckniveau des Systems, der LS-Druck und damit der notwendige Pumpendruck sinkt.

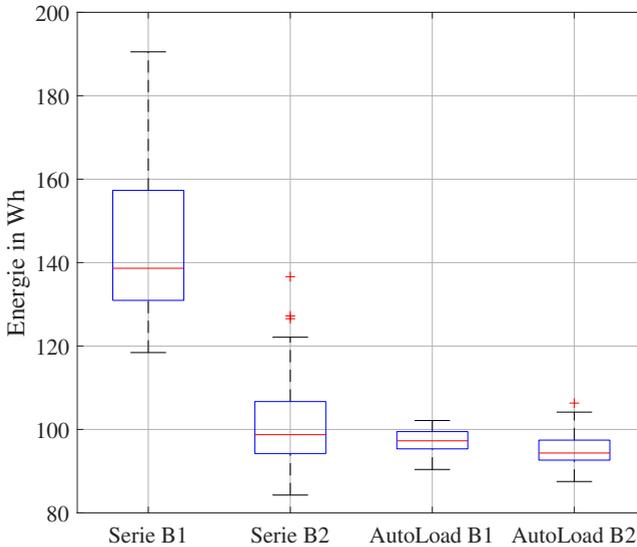


Abbildung 7.4: Vergleich des Energiebedarfs von 2 ungeübten Bedienern zwischen der Serienausführung und der Ausführung mit Assistenzsystem

Hier zeigt sich wieder der Vorteil der verringerten Streuung bei der Nutzung des Assistenzsystems. Durch dieses werden die Bewegungen gleichförmiger und flüssiger im Vergleich zur manuellen Aktuierung ausgeführt. Dieser Effekt führt bei B1 zu dem gezeigten hohen Potential zur Energiereduktion. Obwohl ein deutlicher Unterschied in Median und Standardabweichung zwischen den Bedienern im Seriensystem vorliegt, kann dieser durch das Assistenzsystem ausgeglichen werden. Dadurch kann die Planung hinsichtlich benötigter Kraftstoffmenge und Tankzyklen für den Forstdienstleister erleichtert werden, da starke Ausreißer bei ungeübten Bedienern vermieden werden.

Die Streuung reduziert sich bei B2 ebenfalls, wodurch vor allem Ausreißer hin zu Zyklen mit hohem Energiebedarf vermieden werden. Ein Erklärungsansatz für den ähnlichen Energiebedarf hinsichtlich Seriensteuerung und Assistenzsystem ist im Bewegungsablauf des Bediener zu finden. Die Zylinderbewegungen, siehe Abbildung 7.5, sind repräsentativ für den Referenzzyklus, vergleiche [30], nur langsamer ausgeführt. Damit orientieren sie sich bereits an einem energetisch sinnvollen Ab-

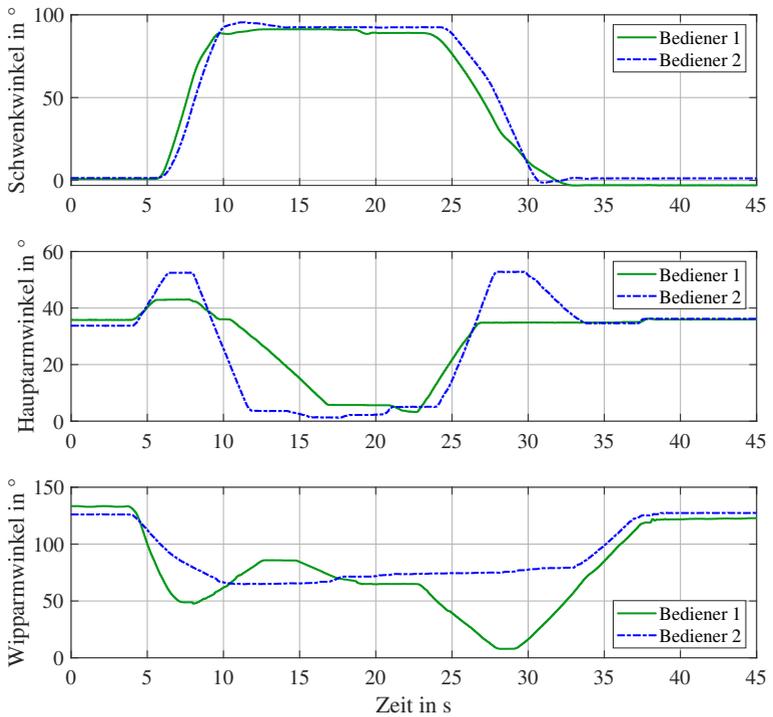


Abbildung 7.5: Vergleich des Bewegungsablauf zwischen Bediener 1 und Bediener 2 im Seriensystem

lauf, resultierend in einer geringen Energiereduktion. Neben der leichten Reduktion der eingesetzten Energie kann die Produktivität durch das Assistenzsystem jedoch um den Faktor 1,6 gesteigert werden.

### 7.3 Einfluss des HT-Systems auf den Energiebedarf

Um den Einfluss der unterschiedlichen Hydrauliksysteme auf den Energiebedarf zu untersuchen, wurden Messungen mit einem geübten Maschinenbediener durchgeführt. Hierzu führte dieser den Referenzzyklus an zwei Messtagen (#1 und #2) im zweiwöchigen Abstand unter Verwendung der Kranspitzensteuerung jeweils 40-mal

für das Serien- als auch das HT-System aus. In Abbildung 7.6 (linke Graphik) ist die statistische Auswertungen der Messungen für die Zykluszeit und den Energiebedarf dargestellt. Der Median der Zykluszeit variiert für die 4 Messungen von 15,3 s bis 16,1 s, wobei die Variation innerhalb eines Messtages maximal 0,3 s beträgt. Die Varianz in der Zykluszeit ist für den ersten Messtag höher als für den zweiten, wobei sich die Bereiche, in welchen die Zykluszeiten liegen, stark überschneiden. Auffällig ist der untere Grenzwert der Zykluszeit, welcher sich um maximal 0,2 s unterscheidet, während bei der maximalen Zykluszeit Unterschiede im Sekundenbereich bestehen. Aufgrund der geringen Abweichung der Mediane sowie der sich überschneidenden Interquartilsabständen kann der Bedienerinfluss vernachlässigt werden. Hierdurch ist ein Vergleich des Energiebedarfs bei den vorliegenden Messungen unabhängig vom Einfluss des Bedieners möglich.

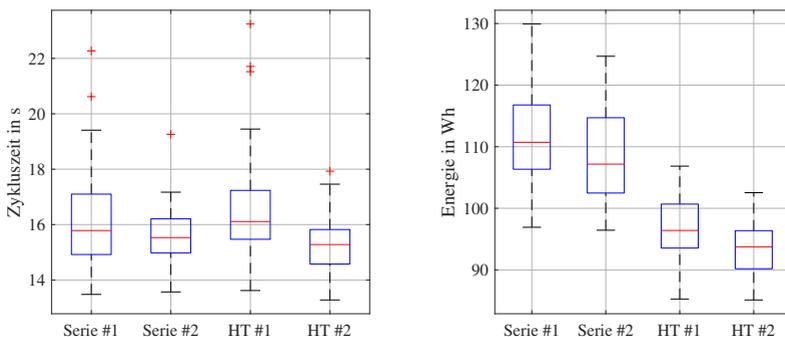


Abbildung 7.6: Vergleich der Zykluszeit und des Energiebedarfs für den Bediener 3 (geübter Bediener) zwischen dem Serien- und HT-System im Referenzsystem für Messtag #1 und Messtag #2

Der Energiebedarf für die Ausführung des Referenzzyklus beträgt für das Serien-Hydrauliksystem mit der in Kapitel 6 beschriebenen Kranspitzensteuerung im Median 110,7 Wh (Messung #1) respektive 107,2 Wh (Messung #2), vgl. Abbildung 7.6 (rechte Graphik). Wird während des Ladevorgangs das HT-System verwendet, wodurch der Hub- und Wippzylinder gekoppelt sind, verringert sich der Energiebedarf im Median auf 96,4 Wh respektive 93,7 Wh (Messung #2). Dies entspricht einer Energiereduktion im Referenzzyklus um 12,9 % respektive 12,6 %. Dabei weisen die Zyklen mit dem niedrigsten Energiebedarf je Messung und System eine maximale

Abweichung von 0,5 Wh auf. In Kombination mit der Zykluszeit zeigt sich, dass das maximal mögliche Potential hinsichtlich der Zyklusdauer und des minimalen Energiebedarfs seitens des Bedieners limitiert auf 13,3 s und 96,4 Wh (Serien-System) respektive 85,1 Wh (HT-System) ist. Werden diese Datenpunkte für die Evaluation des Energiebedarfs herangezogen, so zeigt sich eine Reduktion um 11,7 %.

Zur detaillierten Untersuchung der Ursache der Energiereduktion werden zwei Messschriebe für das Serien- und HT-System gegenübergestellt, vergleiche Abbildung 7.7. Diese unterscheiden sich in der Zykluszeit um 0,2 s, der Energiebedarf liegt im Serien-System bei 115,2 Wh und im HT-System bei 91,8 Wh. Zudem weisen die Zyklen einen sehr ähnlichen Verlauf der Gelenkwinkel  $\theta_1$ ,  $\theta_2$  und  $\theta_3$  auf, siehe Abbildung 7.9, womit die Zyklen in ihrem Bewegungsablauf vergleichbar sind.

Der Energiebedarf wird mit dem Integral der hydraulischen Leistung über die Zeit berechnet. Um die Ursache des geringeren Energiebedarfs im HT-System zu untersuchen, kann der Leistungsverlauf zur Analyse herangezogen werden, vgl. Abbildung 7.7 (Oben). In dieser Abbildung visualisiert die grüne Volllinie das Serien-System, die blau strichlierte Linie das HT-System. Hierbei sind zwei Zeitbereiche mit einem geringeren Leistungsbedarf von  $t = 3,9 \text{ s}$  bis  $t = 7,0 \text{ s}$  sowie von  $t = 8,3 \text{ s}$  bis  $t = 11,1$  erkennbar, während von  $t = 12,8 \text{ s}$  bis  $t = 13,8 \text{ s}$  der Leistungsbedarf höher ist. Durch die Betrachtung des Volumenstroms und des LS-Drucks kann analysiert werden, was die Unterschiede im Leistungsverlauf bewirkt, vgl. Abbildung 7.7 (Mitte und Unten). Ursächlich für die geringere Leistung im ersten Bereich ist der signifikant geringe Druck im HT-System im Vergleich zum Serien-System, während der Volumenstrom gleichbleibend ist. Im zweiten Bereich ab  $t = 8,3 \text{ s}$  liegt eine Kombination aus geringerem Druck bei zeitgleich geringerem Volumenstrom vor. Der erhöhte Leistungsbedarf des HT-Systems im dritten Bereich ab  $t = 12,8 \text{ s}$  ist vorrangig auf einen erhöhten Volumenstrom zurückzuführen, da das Druckniveau hier nur geringfügig höher ist als im Serien-System.

Im Folgenden werden die Ursachen für die beschriebenen Unterschiede im Druck- sowie Volumenstromverlauf detailliert analysiert. Für den ersten Bereich werden hierfür die Druckverläufe der Einzelverbraucher untersucht, vgl. Abbildung 7.8 (Oben: Serien-System, Unten: HT-System).

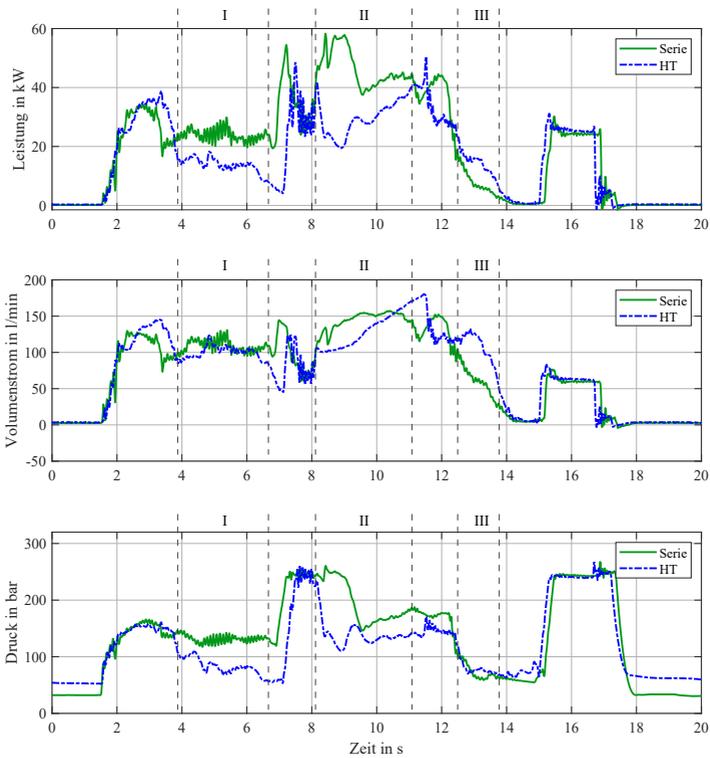


Abbildung 7.7: Vergleich des Leistungsbedarfs im Referenzzyklus für das Serien- und HT-System

Die schwarze Linie in den Graphen gibt den LS-Druck an, welcher an die Pumpe weitergegeben wird. Durch einen Vergleich der Druckverläufe wird der lastgebende Verbraucher bestimmt. Im Bereich von  $t = 3,9 \text{ s}$  bis  $t = 7,0 \text{ s}$  ist der stangenseitige Druck des Wippzylinders (rote Strichlinie Wipp - B) der höchste Druck und wird somit als LS-Druck übermittelt. Der Druck am Ventilblock im Bereich von ca.  $p = 100 \text{ bar}$  bis  $p = 120 \text{ bar}$  ergibt sich, da der Wipparm in diesem Bereich angehoben wird, vgl. auch den Winkelverlauf des Wipparms in Abbildung 7.9 (Mitte Links). Der dafür benötigte Druck muss im Seriensystem direkt von der Pumpe bereitgestellt werden.

Da in diesem Zeitbereich eine simultane Bewegung von Haupt- und Wipparm ausgeführt wird, kann potentielle Energie durch das Absenken des Hauptarmes mittels des HT-Systems genutzt werden. Die hydraulische Leistung wird durch den Hydro-Transformator vom Hubzylinder auf den Wippzylinder übertragen. Hierdurch wird das Druckniveau am Ventilblock auf  $p = 30 \text{ bar}$  bis  $p = 75 \text{ bar}$  abgesenkt, vgl. Abbildung 7.8 (Unten), während der Bewegungsablauf analog erfolgt, vgl. Abbildung 7.9 (Links). Die in Kapitel 4 vorgestellte Idee zur Energiereduktion ist dadurch verifiziert.

Die Kopplung von Haupt- und Wipparm in der Jacoby-Matrix für die Inverse Kinematik des HT-Systems resultiert in einer Priorisierung dieser Gelenke ( $\theta_1$  und  $\theta_2$ ), wodurch das Teleskop  $\theta_3$  im Referenzzyklus mit einer geringeren Geschwindigkeit hin zu einer geringeren Absolutposition ausgefahren wird, vgl. Abbildung 7.9 bei  $t = 8,3 \text{ s}$ . Dem entgegen muss im Serien-System das Teleskop mit einer bis zu zweifach höheren Geschwindigkeit wieder eingefahren werden, wodurch der Volumenstrom ab  $t = 8,3 \text{ s}$  steigt.

Aufgrund der langen Hydraulikschläuche zur Stangenseite des Teleskopzylinders in Kombination mit einem kleinen Schlauchdurchmesser steigen damit die Druckverluste, wodurch das Druckniveau für das Einfahren des Teleskops ebenfalls steigt. Dies wird durch den Druckverlauf der Stangenseite, vgl. die rosa Strichlinie in Abbildung 7.8 (Tele - B), bestätigt, welcher für den zweiten Bereich deckungsgleich mit dem LS-Druck und damit lastgebend ist. Der geringe Leistungsbedarf des HT-Systems im zweiten Bereich resultiert direkt aus einer verringerten Geschwindigkeit des Teleskops und indirekt aus der Kopplung durch den Hydro-Transformator in Verknüpfung mit der Optimierung durch die gewichtete Pseudo-Inverse.

Im dritten Bereich von  $t = 12,8 \text{ s}$  ergibt sich aufgrund des höheren Volumenstrombedarf im HT-System ein gesteigerter Leistungsbedarf, obwohl die Gelenkgeschwindigkeiten  $\dot{\theta}_1, \dot{\theta}_2, \dot{\theta}_3$  nur geringe Abweichungen zwischen den Messschrieben aufweisen. Dieser Effekt ist auf eine im HT-System erhöhte Schwenkgeschwindigkeit zurückzuführen und nicht spezifisch für den Verlauf. Da absolut gesehen das gleiche Volumen je System für das Schwenken benötigt wird, kann diese Leistungserhöhung vernachlässigt werden, da sie sich mit dem geringeren Leistungsbedarf zwischen  $t = 11,7 \text{ s}$  und  $t = 12,2 \text{ s}$  ausgleicht.

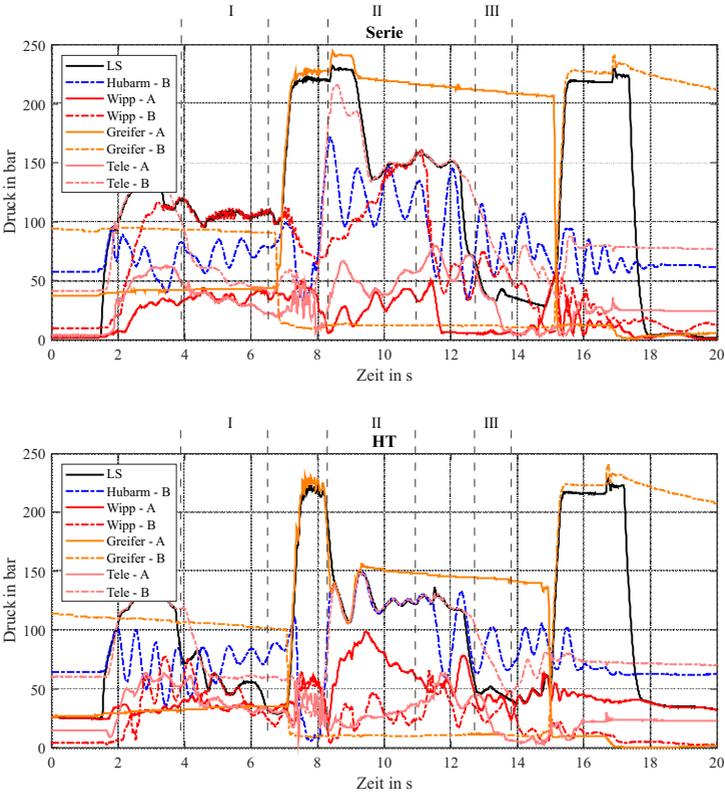


Abbildung 7.8: Vergleich der Druckverläufe der Einzelverbraucher und des LS-Meldedrucks für das Serien- und HT-System

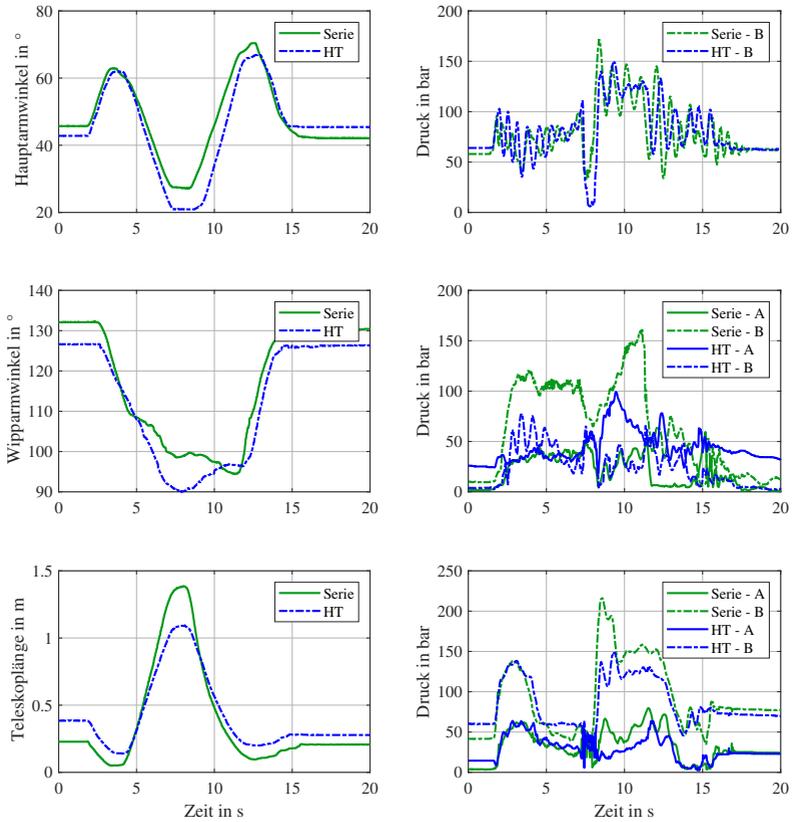


Abbildung 7.9: Darstellung der Positions- und Druckverläufe der Verbraucher  $\theta_1 - \theta_3$  für das Serien- und HT-System

Abschließend erwähnenswert ist die Tatsache, dass vor allem in der Ladephase I ( $t = 2,0\text{ s}$  bis  $t = 7,0\text{ s}$ ), der Bewegung des Greifers zum Stamm hin, eine simultane, gleichgerichtete Bewegung von Hub- und Wippszylinder vorliegt, welche zu einer Energieeinsparung beiträgt. In der Ladephase III ( $t = 8,4\text{ s}$  bis  $t = 12,3\text{ s}$ ) ist zu beobachten, dass keine gleichzeitige Bewegung der beiden Verbraucher vorliegt. Hier besteht somit ein weiteres Potential zur Energiereduktion bei einer Automatisierung dieser Ladephase.

### 7.4 Genauigkeitsanalyse der Ladungserfassung

Unter realen Arbeitsbedingungen ist eine Produktivitätsevaluation wie in Kapitel 7.1 definiert, welche ausschließlich auf der Zykluszeit basiert, nicht zielführend, da sie das Arbeitsergebnis nicht berücksichtigt oder widerspiegelt. So würden bei gleicher Zykluszeit zwei Ladezyklen, in welchen jedoch einmal ein Stamm mit 100 kg und einmal mit 1000 kg geladen werden, die gleiche Produktivität aufweisen, obwohl als Ergebnis die 10-fache Masse in Rungenkorb liegt. Somit ist die Vereinfachung der Produktivität als reine Zykluszeit für den realen Einsatz nicht zulässig.

Aus diesem Grund muss die geladene Masse bei der Produktivitätsanalyse mit betrachtet werden. Die Informationssysteme der führenden OEM integrieren dazu das Signale einer zusätzlich montierten Kranwaage. Damit kann die Produktivität als geladene Masse pro Maschinenstunde ( $kg/h$ ) definiert werden. Über die Dichte der jeweiligen Baumarten wird das gerückte Volumen geschätzt, um das im forstlichen Bereich übliche Produktivitätsmaß  $m^3/h$  zu berechnen.

Mit der datenbasierten Kranwaage ist eine generelle Methode gegeben, um das für die Produktivitätsanalyse notwendige Gewicht der geladenen Stämme zu bestimmen. Dabei ist kein weiteres Bauteil zwischen Teleskopgauge und Greifer mit den einhergehenden Nachteilen nötig. Das Funktionsprinzip der datenbasierten Kranwaage wurde in Kapitel 5.2 erläutert.

Für die universelle Nutzung der Kranwaage unter sich ändernden Einsatzszenarien wird das sogenannte Bagging [45] angewendet, um die Varianz der Massenvorhersage zu reduzieren. Bagging beschreibt dabei das Mitteln der Ergebnisse von mehreren trainierten Netzwerken, wodurch der Fehler aufgrund eines geringeren Einflusses von Ausreißern in den Prädiktionen reduziert wird. Durch das Bagging werden

die Schwächen einzelner CNN auf spezifischen Eingangsdaten ausgeglichen. Für das Bagging wurden die 20 CNNs aus Kapitel 5 ermittelt, welche den geringsten mittleren Vorhersagefehler auf dem Validierungsdatensatz aufweisen. Für jeden Ladezyklus im Realeinsatz liegen dadurch 20 Gewichtsprädiktionen vor. Für die finale Prädiktion der Masse des Greiferinhalts werden die prädizierten Gewichte ausschließlich derer oberen und unteren 10 % gemittelt. Die Einbindung dieser Bewertungsmethode in die Ladungserfassung erhöht die Robustheit derselben gegenüber wechselnden Maschinenbedienern und Umgebungsfaktoren, da die oberen und unteren Extremwerte der 20 Schätzungen nicht berücksichtigt werden.

Der Testdatensatz besteht aus den 31 zufällig ausgewählten Ladezyklen. Keiner dieser Zyklen wurde beim Training oder zur Validierung des CNN verwendet. Die Ladezyklen wurden von zwei verschiedenen Bedienern mit unterschiedlichem Erfahrungsstand durchgeführt, einem fortgeschrittenen Anfänger und einem Profi. Insgesamt summieren sich die Einzelmassen, welche während dieser Zyklen geladen wurden, zu 6.888 kg. Die vom CNN für alle Zyklen geschätzte Masse beträgt insgesamt 6.873 kg, was zu einem Fehler von - 0,22 % führt. Abbildung 7.10 zeigt den Vorhersagefehler (VF) des Testdatensatzes unter Verwendung des Bagging. Der VF der einzelnen Stämme liegt in einem Bereich von -7,73 % bis 10,73 % mit einem mittleren VF von 1,20 %, der Median liegt bei 1,32 %.

Der Bereich des VF im Testdatensatz entspricht sehr gut dem Fehlerbereich im Validierungsdatensatz. Dies unterstreicht die Stabilität und Robustheit des CNN. Die Tatsache, dass der absolute Fehler höher als 10 % sein kann, ist kein kritisches Argument gegen die gezeigte Methode und Netzarchitektur, da nur ein Minimum an Daten zum Training verwendet wurde. Eine Erhöhung der Trainingsdaten wird den Fehlerbereich voraussichtlich deutlich reduzieren.

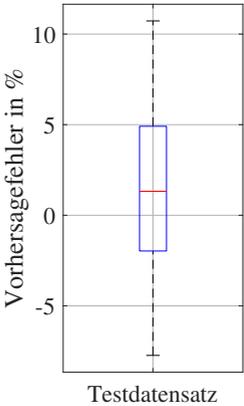


Abbildung 7.10: Vorhersagefehler der datenbasierten Kranwaage beim Test

## 8 Zusammenfassung und Ausblick

**Zusammenfassung** Der voll-mechanisierte Holzernteprozess Cut-to-Length stellt bei der Bedienung der dafür notwendigen Forstmaschinen eine herausfordernde Arbeitsumgebung dar. Dies zeigt sich vor allem in einer langen Lernzeit von 9 Monaten, bis ungeübte Bediener eine konstante Produktivität erreicht haben. Vor allem in den ersten Monaten der Lernphase weisen die ungeübten Bediener eine sehr geringe Produktivität auf.

Die vorliegende Arbeit greift diese Problemstellung auf und hat das Ziel, einen Lösungsansatz zur Effizienzsteigerung bei ungeübten Bedienern der Forstmaschine Forwarder zu bieten. Hierzu wurde ein Assistenzsystem entwickelt und erfolgreich getestet, welches den Bediener durch die Teilautomatisierung der Ladeprozesse unterstützt. Diese besitzen mit 45 % den höchsten Anteil an der Arbeitszeit während des Rückens und stellen die Arbeitstätigkeit mit dem höchsten Komplexitätsgrad dar. Das dafür notwendige Steuerungskonzept des Assistenzsystems besteht zu einem aus dem Informationsmodul zur Stammerkennung und Attributsbestimmung, welches die Stammattribute Länge, Durchmesser und Position an den zweiten Bestandteil, den Steuermodulen, weitergibt. Die Steuermodule der automatischen Kranbewegung und des automatischen Greifens sind in einem Zustandsautomaten eingliedert, welcher die zeitlich konsistente Abfolge der Arbeitsabläufe sicherstellt. Die notwendigen Signale zur Aktuierung der Arbeitskinematik werden über das Steuermodul Kranspitzensteuerung an den Forwarder gesendet, welcher im Gegenzug die Sensordaten der Arbeitskinematik und -hydraulik an die Steuerung rückmeldet.

Die erste Forschungsfrage

*Gibt es ein Steuerungskonzept, welches eine Automatisierung des Greifvorgangs im Ladeprozess für einen Einzelstamm zulässt?*

kann durch die in Kapitel 3 gezeigte Architektur sowie den erfolgreichen Tests unter Labor- und Realbedingungen bejaht werden.

Wie im Stand der Technik und Forschung aufgezeigt, fehlt bisher für eine zielführende Automatisierung des Ladeprozesses die aktuelle Position des zu ladenden Stammes. Bis dato wurden feste Zielpunkte vorgegeben, welche jedoch nicht das vorliegende Arbeitsszenario in der Einschlagsfläche widerspiegeln. Zur Lösung dieses Defizits wurden Methoden des Maschinellen Sehens angewandt. Im ersten Schritt wurde der Datensatz MobimaLogs aufgebaut, da kein passender Datensatz mit annotierten Bildern für die Arbeitsszenarien eines Forwarders existierte. Dieser besteht aus 2.123 Bildern, wobei die Objekte in den Bildern auf Pixelebene in 9 verschiedene Objektklassen annotiert wurden. Auf der Basis des Fully Convolutional Neural Network YOLACT++ mit einem ResNet101 als Backbone wurde ein einstufiges Netzwerk zur Instanzsegmentierung mittels Transfer-Lernen auf dem Datensatz MobimaLogs mit einer Genauigkeit von 56,65 mAP für Masken erfolgreich trainiert. Das trainierte Netzwerk ist in der Lage, Objektmasken in Bildern, die zu den verschiedenen Klassen gehören, unter Laborbedingungen und in realen Arbeitsszenarien zu bestimmen. Durch die Verwendung einer Stereokamera können durch Extraktion aus der semantisch segmentierten Punktwolke die zum Stamm gehörenden 3D-Punkte, welche mit den 2D-Pixeln im segmentierten Bild korrespondieren, die Stammmerkmale Länge und Durchmesser mit einer Genauigkeit im Zentimeterbereich bestimmt werden. Die daraus berechenbare Position des Stammes dient als Input für die Automatisierung und spiegelt in Echtzeit die aktuelle Arbeitssituation in der Einschlagsfläche wider.

Die Grundlage für eine automatische Kranbewegung ist das Steuerungsmodul der Kranspitzensteuerung. Das Assistenzsystem gibt den notwendigen Geschwindigkeitsvektor der Kranspitze aus. Die Kranspitzensteuerung berechnet über die gewichtete Pseudo-Inverse der Arbeitskinematik die Ansteuerung der einzelnen hydraulischen Verbraucher, damit die Kranspitze mit dem vorgegebenen Geschwindigkeitsvektor bewegt wird. Dabei wird im Speziellen das Hydrauliksystem mit dem verbauten Hydro-Transformator (HT-System) berücksichtigt, durch welchen der Hub- und Wipppylinder für eine Energieregeneration direkt miteinander gekoppelt ist. Um diesen Effekt auszunutzen, wurde die Gewichtungsmatrix derart gesetzt, dass möglichst häufig eine simultane Bewegung von Haupt- und Wipparm vorliegt. Durch die Nutzung des in die Kranspitzensteuerung eingegliedert HT-Systems kann

die benötigte Energie pro Ladezyklus bei gleichbleibender Zykluszeit um 12,6 % reduziert werden.

Das Assistenzsystem wurde unter einer reproduzierbaren Laborumgebung mittels zweier ungeübter Bediener, welche den Referenz-Ladezyklus ausführten, getestet und seine Funktion verifiziert. Dabei konnte die benötigte Zeit für die Ladezyklen, bezogen auf den Median von jeweils 30 Messungen, um 35,6 % (Bediener 1) respektive 40,2 % (Bediener 2) reduziert werden. Dies entspricht einer Produktivitätssteigerung um den Faktor 1,6 und beantwortet damit die zweite Forschungsfrage:

*In welcher Höhe ändert sich die Produktivität eines ungeübten Bedieners durch eine Teilautomatisierung des Referenzzyklus mittels eines automatischen Greifens von Einzelstämmen?*

Zudem wurde beobachtet, dass die Streuung der Zykluszeiten signifikant verringert werden konnte und die Bediener durch die Nutzung der Teilautomatisierung sehr ähnliche Zykluszeiten untereinander aufweisen.

Zeitgleich wurden bei den Versuchen die benötigte Energie pro Zyklus betrachtet, um die dritte Forschungsfrage

*In welcher Höhe ändert sich der Energiebedarf eines ungeübten Bedieners durch eine Teilautomatisierung des Referenzzyklus mittels eines automatischen Greifens von Einzelstämmen?*

zu beantworten. Der Energiebedarf wurde durch die Teilautomatisierung um 29,8 % (Bediener 1) respektive 4,5 % (Bediener 2) reduziert. Dies zeigt das hohe Potential des Assistenzsystems, da besonders die Auswirkungen fehlender Kompetenz von ungeübten, variierenden Bedienern vermindert werden und starke Abweichungen zwischen diesen im Vergleich zur konventionellen Kransteuerung ausgeglichen werden.

Um die aktuelle Zuladung des Forwarders zu bestimmen, wurde eine datenbasierte Kranwaage entwickelt. Diese besteht aus einer selbst entworfenen Architektur eines Convolutional Neural Network und verarbeitet die Signale des Forwarders während des Ladens. Damit kann die Zuladung pro Ladezyklus errechnet werden und dient somit als Grundlage für eine Produktivitätsbestimmung unter realen Einsatzbedingungen. Auf dem Testdatensatz weist das Neuronale Netzwerk einen Fehler

für die Gewichtsbestimmung im Mittel von 1,2 % auf. Dies beantwortet die vierte Forschungsfrage:

*Mit welcher Genauigkeit kann die Zuladung bei Rückzügen erfasst werden?*

Durch die Beantwortung aller Forschungsfragen kann die Forschungshypothese *Assistenzsysteme ermöglichen eine effiziente Teilautomatisierung des Ladeprozesses bei Forwardern für ungeübte Bediener*

verifiziert werden. Unterstrichen wird das Ergebnis durch erfolgreiche Tests des Assistenzsystems unter realen Arbeitsbedingungen in einer Durchforstung.

**Ausblick** Die echtzeitfähige Erkennung der zu ladenden Stämme als einer der letzten fehlenden Bausteine für einen vollständig autonomen Ladeprozess wurde in dieser Arbeit realisiert. Mit der bereits bestehenden Forschung und den in dieser Arbeit entwickelten Steuer- und Informationsmodulen können die Ladephasen I - III, das Greifen des Stammes sowie die Hin- und Rückbewegung des Krans, vollständig automatisiert werden. Die letzte Ladephase, die Positionierung der Stämme im Rungenkorb, benötigt für die Automatisierung lediglich eine aktuelle Füllstandshöhe des Rungenkorbs, welche durch einen einfachen Radarsensor oder eine weitere Stereokamera ermittelt werden kann.

Als konsekutive Erweiterung des Assistenzsystems AutoLoad kann eine Kollisionsvermeidung mit den umstehenden Bäumen sowie der Maschine integriert werden. Mit dem Informationsmodul Objekterkennung kann nach selbigen Verfahren zur Positionsbestimmung der Stämme auch die Position der stehenden Bäume bestimmt werden, da diese vom CNN ebenfalls erkannt werden und dadurch aus der semantisch segmentierten Punktwolke extrahiert werden können. Durch das Vorliegen des aktuellen Geschwindigkeitsvektors der Kranspitze sowie der Baumpositionen können mögliche Kollisionen prädiert und die Kranbewegung vorher gestoppt werden.

Die Objekterkennung im forstlichen Hieb bietet einen Rahmen für verschiedene Automatisierungs- oder Assistenzsysteme. Die korrekte Klassifizierung eines Rundholzsortiments ist entscheidend für das sortenreine Poltern und damit für den finanziellen Ertrag der Holzernte. Diese Aufgabe ist besonders für unerfahrene Bediener anspruchsvoll. Das Informationsmodul Objekterkennung kann dabei zur Sortiments-

bestimmung der Stämme genutzt werden. Basierend auf den Dimensionen des Objekts Stamm könnte eine automatisierte Kategorisierung in ein bestimmtes Sortiment vorgenommen und so fehlerhafte Sortimentszuweisungen reduziert werden.

Weiterführend ist eine Nutzung für die Dokumentation des Arbeitsfortschritts möglich, indem die Anzahl der geladenen Stämme erfasst wird.

Mittels einer Kopplung von der Objekterkennung und der CNN-basierten Kranwaage können durch den Vergleich des theoretischen Gewichts eines gesunden Stammes mit dem von der Kranwaage geschätzten realen Gewicht qualitätsmindernde Eigenschaften wie Käferbefall oder Rotfäule erkannt werden. [32]



# Abbildungsverzeichnis

2.1	Produktivitätsverlauf neuer Forwarderbediener [15] . . . . .	6
2.2	Unterteilung des Ladezyklus in 4 Ladephasen . . . . .	7
2.3	Forwarder und dessen Joystickbelegung nach [115] . . . . .	9
2.4	Joystickbelegung für die Kranspitzensteuerung nach [43] . . . . .	13
2.5	Einfluss einer zwischen Teleskopauge und Rotator montierten Kranwaage: Links mit Kranwaage, Rechts ohne Kranwaage . . . . .	17
2.6	Maschinelles Sehen: Semantische Segmentierung, Klassifizierung, Objekterkennung, Instanz Segmentierung (links nach rechts) [69] . . . . .	19
3.1	Architektur des Assistenzsystems AutoLoad . . . . .	29
4.1	Allgemeine Messtechnik auf dem Versuchsträger Forwarder . . . . .	34
4.2	Schaltplan des HT-Systems einschließlich Sensorsignale nach [50] . . . . .	36
4.3	Bewegungsablauf bei der Energieregeneration . . . . .	37
4.4	Histogramm zur Verteilung und Anzahl der Greifposition . . . . .	40
4.5	Positionierung des Stammes für den Referenzzyklus . . . . .	41
5.1	Physikalisches Grundprinzip zur Nutzlastbestimmung . . . . .	44
5.2	Architektur des ersten Zweigs des CNN . . . . .	50
5.3	Ergebnis des Trainings des Neuronalen Netzwerks . . . . .	53
5.4	Ablaufdiagramm des automatisierten Wiegeprozesses . . . . .	54
5.5	Ablaufdiagramm der Objekterkennung . . . . .	58
5.6	Ergebnisse von YOLACT++ auf dem Validierungsdatensatz von <i>MobimaLogs</i> . . . . .	63
5.7	Viusalisierung des Kreisfittings auf der zum Stamm gehörigen Punktwolke . . . . .	68
5.8	Genauigkeit der Bestimmung der Stammattribute . . . . .	70

6.1	Forstkran mit seinen Variablen . . . . .	72
6.2	Bereichsweiser, radiusabhängiger Verlauf des Gewichtungsfaktors $c_3$ .	77
6.3	Verlauf des Gewichtungsfaktors $JLA_i$ zur Vermeidung der Gelenkgrenzen: Um das Anfahren eines Gelenkes in einen seiner Endanschläge zu vermeiden, steigt der Gewichtungsfaktor zum Minima und Maxima der Gelenkauslenkungen an . . . . .	79
6.4	Zusammenhang zwischen normierten Volumenstrom $Q$ und normierten Ventilstrom $I$ : Volumenstrom steigt aufgrund der positiven Überdeckung des Ventilschiebers ab dem Minimalstrom des Ventils stetig an .	80
6.5	Evaluation der Positionsgenauigkeit der Kranspitze in r- und z-Richtung	81
6.6	Evaluation der Genauigkeit der Geschwindigkeiten der Gelenke von Hauptarm $\theta_1$ , Wipparm $\theta_2$ , Teleskop $\theta_3$ . . . . .	81
6.7	Evaluation des Sensortotwegs des Drehgebers am A-Bolzen . . . . .	82
6.8	Ablaufdiagramm der Zustandsautomaten zum Assistenzsystem AutoLoad	85
6.9	Veranschaulichung der Sphäre um den zu greifenden Stamm. . . . .	86
6.10	Bereichsweiser Geschwindigkeitsverlauf der Kranspitze in Abhängigkeit zum Abstand des Greifpunkts, welcher durch das Assistenzsystem gesetzt wird . . . . .	88
6.11	Positionsverlauf der Greiferspitze in vertikaler Richtung in Abhängigkeit des Zylinderhubs einschließlich graphischer Visualisierung . . . .	89
7.1	Vergleich der Zykluszeit von 2 ungeübten Fahrern zur Produktivitätsanalyse . . . . .	94
7.2	Kranposition, Bediener signale und Greiferdrücke für die konventionelle Steuerung und das Assistenzsystem für Bediener 1 . . . . .	95
7.3	Verlauf der Zykluszeiten zur Beurteilung der Lernkurve von Bediener 2	96
7.4	Vergleich des Energiebedarfs von 2 ungeübten Bedienern zwischen der Serienausführung und der Ausführung mit Assistenzsystem . . . . .	98
7.5	Vergleich des Bewegungsablauf zwischen Bediener 1 und Bediener 2 im Seriensystem . . . . .	99
7.6	Vergleich der Zykluszeit und des Energiebedarfs für den Bediener 3 (geübter Bediener) zwischen dem Serien- und HT-System im Referenzsystem für Messtag #1 und Messtag #2 . . . . .	100

---

7.7	Vergleich des Leistungsbedarfs im Referenzzyklus für das Serien- und HT-System . . . . .	102
7.8	Vergleich der Druckverläufe der Einzelverbraucher und des LS-Meldedrucks für das Serien- und HT-System . . . . .	104
7.9	Darstellung der Positions- und Druckverläufe der Verbraucher $\theta_1 - \theta_3$ für das Serien- und HT-System . . . . .	105
7.10	Vorhersagefehler der datenbasierten Kranwaage beim Test . . . . .	108



## Tabellenverzeichnis

4.1	Übersicht der Datenaufnahme . . . . .	39
5.1	Eingangsdaten in das Neuronale Netzwerk . . . . .	47
5.2	Statistische Analyse des CNN . . . . .	53
5.3	Durchschnittliche Genauigkeit auf dem Validierungsdatensatz nach dem Training . . . . .	61
5.4	Einfluss des Ausreißerverhältnis $R$ und der Anzahl gefitteter Kreise $C$ auf die Bestimmung des Stammdurchmessers . . . . .	67



## Literatur

- [1] AMAZONEN-WERKE H. DREYER GmbH & Co. KG: UX AmaSpot. 2017. URL: <https://info.amazone.de/DisplayInfo.aspx?id=45907> (besucht am 01. 02. 2021).
- [2] Aschoff, T. und Spiecker, H.: Algorithms for the Automatic Detection of Trees in Laser Scanner Data. In: Laser-Scanners for Forest and Landscape Assessment. Proceedings of NATSCAN-Conference on Laser-Scanners for Forest- and Landscape Assessment, Freiburg, 3.-6. Oktober 2004. Hrsg. von M. Thies et al. International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, 2004, S. 71–75.
- [3] Bayrisches Staatsministerium für Ernährung, Landwirtschaft und Forsten: Holzvermessung und Holzmerkmale. 2021. URL: [https://www.stmelf.bayern.de/wald/waldbesitzer\\_portal/054775/index.php](https://www.stmelf.bayern.de/wald/waldbesitzer_portal/054775/index.php) (besucht am 18. 10. 2021).
- [4] Beiner, L. und Mattila, J.: An improved pseudoinverse solution for redundant hydraulic manipulators. In: Robotica 17.2 (1999), S. 173–179. ISSN: 0263-5747. DOI: 10.1017/S0263574799001216.
- [5] Bennett, N.; Walawalkar, A. und Schindler, C.: Payload Estimation in Excavators: Model-Based Evaluation of Current Payload Estimation System. In: CVT2014 3rd Commercial Vehicle Technology Symposium, Kaiserslautern, 11.-13. März 2014. Hrsg. von Karsten Berns et al. Bd. Volume 3. Shaker Verlag, 2014, S. 333–346.

- [6] Bienert, A. und Cao, C.: Tree detection and diameter estimations by analysis of forest terrestrial laserscanner point clouds. In: ISPRS Workshop on Laser Scanning 2007 and SilviLaser 2007, Espoo, Finland, (2007), S. 50–55.
- [7] Blume, T. et al.: Objekterkennung und Positionsbestimmung in der Landwirtschaft am Beispiel eines Ankoppelassistenten. In: LAND-TECHNIK 73 (2018), S. 1–9. DOI: 10.15150/lt.2018.3176.
- [8] Bodla, N. et al.: Soft-NMS – Improving Object Detection With One Line of Code. In: arXiv arXiv:1704.04503 (2017), S. 1–9.
- [9] Bolya, D.: GitHub repository yoact. URL: <https://github.com/dbolya/yoact> (besucht am 10.02.2021).
- [10] Bolya, D. et al.: YOLACT: Real-time Instance Segmentation. In: 2019 IEEE/CVF International Conference on Computer Vision (ICCV), Seoul, 27. Okt. - 3. Nov. 2019. IEEE/CVF International Conference on Computer Vision. 2019, S. 9157–9166.
- [11] Bolya, D. et al.: YOLACT++: Better Real-time Instance Segmentation. In: IEEE transactions on pattern analysis and machine intelligence 42 // 44.1 // 2 (2019 // 2022), S. 1108–1121. ISSN: 0162-8828. DOI: 10.1109/TPAMI.2020.3014297.
- [12] Braunschweiger Zeitung: Borkenkäfer frisst Gewinn der Landesforsten. 2019. URL: <https://www.braunschweiger-zeitung.de/politik/article226231743/Borkenkaefer-frisst-Gewinn-der-Landesforsten.html> (besucht am 07.10.2021).
- [13] Bundesministerium für Ernährung und Landwirtschaft, (Hrsg.): Der Wald in Deutschland: Ausgewählte Ergebnisse der dritten Bundeswaldinventur. 3. korrigierte Auflage, Juli 2018; 16.000 bis 28.000 Exemplare. Berlin, 2018.

- 
- [14] Bundesministerium für Ernährung und Landwirtschaft, (Hrsg.): Holzmarktbericht 2020: Abschlussergebnisse für die Forst- und Holzwirtschaft des Wirtschaftsjahres 2020. Bonn, 2020.
- [15] Burger Pagnussat, M.; Silva Lopes, E. und D. Seidler, R.: Behavioural profile effect of forestry machine operators in the learning process. In: *Journal of Forest Science* 65.No. 4 (2019), S. 144–149. ISSN: 12124834. DOI: 10.17221/27/2019-JFS.
- [16] Cacot, E.; Bigot, M. und Cuchet, E.: 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 the World, Idaho, 30. Juli - 2. Aug. 2006. 2006, S. 46–54.
- [17] Chan, T. F. und Dubey, R. V.: A weighted least-norm solution based scheme for avoiding joint limits for redundant joint manipulators. In: *IEEE Transactions on Robotics and Automation* 11.2 (1995), S. 286–292. ISSN: 1042296X. DOI: 10.1109/70.370511.
- [18] Chernov, N.: MATLAB code for circle fitting algorithms. 2021. URL: <https://people.cas.uab.edu/~mosya/cl/MATLABcircle.html> (besucht am 18. 10. 2021).
- [19] Conkur, E. S. und Buckingham, R.: Clarifying the definition of redundancy as used in robotics. In: *Robotica* 15.5 (1997), S. 583–586. ISSN: 0263-5747. DOI: 10.1017/S0263574797000672.
- [20] Deiters, H.: Standardisierung von Lastzyklen zur Beurteilung der Effizienz mobiler Arbeitsmaschinen. Dissertation. Braunschweig: Technische Universität Carolo-Wilhelmina, 2009.

- [21] Deutsche Welle: Stürme, Dürre, Borkenkäfer: Größte Holzernte seit 2007 in Deutschland. 2019. URL: <https://www.dw.com/de/st%C3%BCrme-d%C3%BCrre-borkenk%C3%A4fer-gr%C3%B6%C3%9Fte-holzernte-seit-2007-in-deutschland/a-48429328> (besucht am 07. 10. 2021).
- [22] Deutsches Institut für Normung: DIN ISO 6814: Forstmaschinen - Mobile und selbstfahrende Maschinen. Berlin: Beuth Verlag GmbH, 2016.
- [23] Deutsches Institut für Normung: DIN ISO 9245: Erdbaumaschinen: Leistung der Maschinen - Begriffe, Formelzeichen und Einheiten. Berlin: Beuth Verlag GmbH, 1995.
- [24] Devineau, G. et al.: Convolutional Neural Networks for Multivariate Time Series Classification using both Inter-& Intra-Channel Parallel Convolutions. In: RFIAP 2018 Reconnaissance des Formes, Image, Apprentissage et Perception, Marne la vallée (France), 26. - 28. Juni 2018, S. 1–8.
- [25] Englund, M.: Semi-automated forwarder crane – Development and evaluation in a simulator: Arbetsrapport Från Skogforsk nr. 932–2017. Hrsg. von Skogforsk, Uppsala. 2017.
- [26] Englund, M. et al.: Machine simulator study on the effects of a semi-automatic forwarder crane on operator workload and performance. In: Forest Engineering Conference (FEC) 2018, Rotorua, 16.-19. April 2018 (2018), S. 1–15.
- [27] Everingham, M. et al.: The Pascal Visual Object Classes (VOC) Challenge. In: International Journal of Computer Vision 88.2 (2010), S. 303–338. ISSN: 0920-5691. DOI: 10.1007/s11263-009-0275-4.

- 
- [28] Fodor, S.: Towards semi-automation of forestry cranes: Automated trajectory planning and active vibration damping. Bd. 9. Robotics and control group. Dissertations. Umeå: Department of applied physics and electronics, Umeå University, 2017. ISBN: 978-91-7601-776-0.
- [29] Frederic, B.: Dynamic, Continuous, and Center of Gravity Independent Weighing with a Loader. Dissertation. Kaiserslautern: Technischen Universität Kaiserslautern, 2015.
- [30] Geiger, C. und Geimer, M.: Efficiency Optimisation of a Forestry Crane by Implement Hydraulics with Energy Recovery, 5th International Conference on Agricultural Engineering - LAND.TECHNIK AgEng 2017 - The Forum for Agricultural Engineering Innovations, Hannover, 10.-11. November 2017. In: VDI-Berichte. Bd. 2300. Düsseldorf: VDI Verlag GmbH, 2017, S. 117–125.
- [31] Geiger, C.; Weiser, C. und Geimer, M.: Real-time Object Detection on a Forestry Logging Site based on Convolutional Neural Networks combined with a specialized Feature Estimation for Logs to be Loaded: REVIEW PENDING. In: LANDTECHNIK (2021), S. 1–11.
- [32] Geiger, C. et al.: Assistance System for an Automated Log-Quality and Assortment Estimation based on Data-Driven Approaches using Hydraulic Signals for Forestry Machines. In: 12th International Fluid Power Conference (2020), S. 83–92. DOI: 10.25368/2020.97.
- [33] Geiger, C. et al.: Assistance System for an Automatic Loading Process. 53rd International Symposium on Forest Mechanization (FORMEC), Corvallis, 27.-30. Okt. 2021. In: Proceedings of The Joint 43rd Annual Meeting of Council on Forest Engineering (COFE) & the 53rd International Symposium on Forest Mechanization (FORMEC) (2021), S. 5–7.

- [34] Geiger, C. et al.: Entwicklung und Evaluation eines Wiegesystems für Forstkräne auf Basis von künstlichen neuronalen Netzen. In: LANDTECHNIK Bd. 74 Nr. 5 (2019), S. 102–117. DOI: 10.15150/lt.2019.3213.
- [35] Geiger, C. et al.: Reduzierung des Energieverbrauchs bei Ladevorgängen von Forstmaschinen durch hydraulische Transformatoren. In: 11. Kolloquium Mobilhydraulik. Hrsg. von Marcus Geimer. Karlsruhe: KIT Scientific Publishing, 10. September 2020, S. 115–131.
- [36] Geimer, M., (Hrsg.): Mobile Working Machines. Warrendale, USA: SAE International, 2020. ISBN: 978-0-7680-9432-9.
- [37] Goodfellow, I.; Bengio, Y. und Courville, A.: Deep Learning. Cambridge, USA: MIT Press, 2016.
- [38] Goyal, P. et al.: Accurate, Large Minibatch SGD: Training ImageNet in 1 Hour. In: arXiv arXiv:1706.02677v2 (2017), S. 1–12.
- [39] Greff, D.: Investigating the development of a dynamic weighing system for forestry machines: -using a data driven approach-. Master's thesis. Karlsruhe: Karlsruher Institut für Technologie, 2019.
- [40] Groß, W. et al.: Predicting Time Series with Space-Time Convolutional and Recurrent Neural Networks. In: European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning (2017), S. 71–76. ISSN: 978-287587039-1.
- [41] Haala, N. et al.: Combination of terrestrial Laser Scanning with high resolution panoramic Images for Investigations in Forest Applications and tree species recognition. In: Proceedings of the ISPRS working group V/1, IAPRS - XXXIV (PART 5/W16). Panoramic Photogrammetry Workshop. 2004, S. 1–4. ISBN: 1682-1750.

- 
- [42] Hahto, A.; Mattila, J. und Koivisto, H.: AUTOMATED OBJECT LOCATOR IN A FOREST FORWARDER. In: *Applied Artificial Intelligence* 24.7 (2010), S. 711–721. ISSN: 0883-9514. DOI: 10.1080/08839514.2010.499501.
- [43] Hansson, A. und Servin, M.: Semi-autonomous shared control of large-scale manipulator arms. In: *Control Engineering Practice* 18.9 (2010), S. 1069–1076. ISSN: 09670661. DOI: 10.1016/j.conengprac.2010.05.015.
- [44] Harzer Kurier: Harz: Zwischen toten Fichten keimt überall neues Leben Harz: Zwischen toten Fichten keimt überall neues Leben. 2019. URL: <https://www.harzkurier.de/region/article226284589/Zwischen-toten-Fichten-keimt-ueberall-neues-Leben.html>.
- [45] Hastie, T.; Tibshirani, R. und Friedman, J. H., (Hrsg.): *The elements of statistical learning: Data mining, inference, and prediction*. Second edition, corrected at 12th printing 2017. Springer series in statistics. New York, NY: Springer, 2017. ISBN: 978-0-387-84858-7.
- [46] He, K. et al.: Deep Residual Learning for Image Recognition, 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, 26. Juni - 01. Juli 2006. In: *IEEE Conference on Computer Vision 2016*. 2016, S. 770–778. DOI: 10.1109/CVPR.2016.90.
- [47] He, K. et al.: Mask R-CNN. In: *arXiv arXiv:1706.02677v2 ()*, S. 1–12.
- [48] Hellström, T.; Hohnloser, P. und Ringdahl, O.: Tree diameter estimation using laser scanner. *Technischer Bericht*. Umeå: Department of Computing Science Umeå University, 2013.
- [49] Heubaum, F.: Bodenschutz im Staatsbetrieb Sachsenforst: Projekte zur Technologieerprobung. 2015. URL: <https://www.sbs.sachsen.de/>

- download/Bodenschutz\_Projekte\_2015\_09\_30.pdf (besucht am 07. 10. 2021).
- [50] Hohenlohe, F.: Gebrauchsmusterschrift. DE 20 2014 006 861 U1. 2015.
- [51] Hohenloher Spezial-Maschinenbau GmbH & Co. KG: HSM 208F. 2018. URL: [https://www.hsm-forest.net/hsm-208f-11-t-kombi-kurz-lang.html?file=files/hsm/downloads/Datenblaetter\\_2018/HSM\\_208F\\_Kombi\\_DE.pdf](https://www.hsm-forest.net/hsm-208f-11-t-kombi-kurz-lang.html?file=files/hsm/downloads/Datenblaetter_2018/HSM_208F_Kombi_DE.pdf) (besucht am 29. 08. 2021).
- [52] Hollerbach, J. und Suh, K.: Redundancy resolution of manipulators through torque optimization. In: IEEE Journal on Robotics and Automation 3.4 (1987), S. 308–316. ISSN: 0882-4967. DOI: 10.1109/JRA.1987.1087111.
- [53] Hoppe, W.: Ein heftiges Käferjahr. In: Forst & Technik 1 (2019), S. 38–41.
- [54] Jason Yosinski et al.: How transferable are features in deep neural networks? In: arXiv arXiv:1411.1792 (2014), S. 1–9. DOI: 10.5555/2969033.2969197.
- [55] John Deere: In the Forest. 2018. URL: <https://www.deere.at/assets/publications/index.html?id=e57fed6b#14> (besucht am 25. 11. 2021).
- [56] John Deere: Intelligente Kransteuerung IBC. 2019. URL: <https://www.deere.de/de/forstmaschinen/ibc/> (besucht am 07. 05. 2019).
- [57] John Deere: Precision Forestry. 2021. URL: <https://www.deere.com/en/technology-products/forestry-and-logging-technology/precision-forestry-technology/> (besucht am 29. 08. 2021).
- [58] John Deere: TimberMatic. 2019. URL: <https://www.deere.de/de/forstmaschinen/timbermatic-karten/> (besucht am 25. 11. 2021).

- 
- [59] Jutila, J.; Kannas, K. und Visala, A.: Tree Measurement in Forest by 2D Laser Scanning. In: International Symposium on Computational Intelligence in Robotics and Automation (2007), S. 491–496. DOI: 10.1109/CIRA.2007.382858.
- [60] Kim, J. et al.: Towards database-free vision-based monitoring on construction sites: A deep active learning approach. In: Automation in Construction. Bd. 120, S. 1–10. DOI: 10.1016/j.autcon.2020.103376.
- [61] Kjelland, M. B. et al.: Tool-Point Control for a Redundant Heave Compensated Hydraulic Manipulator, 2012 IFAC Workshop on Automatic Control in Offshore Oil and Gas Production, Trondheim, 31. Mai - 1. Juni 2012. In: IFAC Proceedings Volumes 45.8 (2012), S. 299–304. ISSN: 14746670. DOI: 10.3182/20120531-2-NO-4020.00034.
- [62] Komatsu Forest AB: MaxiXT. 2021. URL: <https://www.komatsuforest.de/forstmaschinen/kontroll-und-informationssystem> (besucht am 09.08.2021).
- [63] Komatsu Forest AB: Options Forwarders. 2019. URL: <https://www.komatsuforest.com/forest-machines/our-forwarders/forwarder-options> (besucht am 13.04.2019).
- [64] Korten, S. und Kaul, C.: Optimierung der Transportprozesse bei Holzernte und Rundholztransport durch den Einsatz von Wechselbrücken. Schlussbericht. München: Lehrstuhl für Forstliche Arbeitswissenschaft und Angewandte Informatik der TU München, 2012.
- [65] Kuptz, D. et al.: Optimale Bereitstellungsverfahren für Holzhackschnitzel. In: Berichte aus dem TFZ. Hrsg. von Technologie- und Förderzentrum (TFZ) im Kompetenzzentrum für Nachwachsende Rohstoffe. Straubing, 2015.

- [66] Kuzniar, K. und Zajac, M.: Some methods of pre-processing input data for neural networks. In: *Computer Assisted Methods in Engineering and Science* 22 (2015), S. 141–151.
- [67] LeCun, Y. et al.: Backpropagation Applied to Handwritten Zip Code Recognition. In: *Neural Computation* 1.4 (1989), S. 541–551.
- [68] Lehner, J. et al.: Patch Refinement - Localized 3D Object Detection. In: *Machine Learning for Autonomous Driving Workshop at the 33rd Conference on Neural Information Processing Systems (NeurIPS 2019)*, Vancouver, Canada. 2019, S. 1–10.
- [69] Li, F.-F.; Johnson, J. und Yeung, S.: Detection and Segmentation, CS231n: Convolutional Neural Networks for Visual Recognition. Vorlesungsuntelagen. Stanford: Stanford University.
- [70] Liang, X. und Hyypä, J.: Automatic stem mapping by merging several terrestrial laser scans at the feature and decision levels. In: *Sensors (Switzerland)* 13.2 (2013), S. 1614–1634. ISSN: 14248220. DOI: 10.3390/s130201614.
- [71] Liégeois, A.: Automatic Supervisory Control of the Configuration and Behavior of Multibody Mechanisms. In: *IEEE Transactions on Systems, Man, and Cybernetics* 7.12 (1977), S. 868–871. ISSN: 0018-9472. DOI: 10.1109/TSMC.1977.4309644.
- [72] Lin, T.-Y. et al.: Microsoft COCO: Common Objects in Context, 13th European Conference on Computer Vision (ECCV), Zürich, 6.-12. Sep. 2014. In: *European Conference on Computer Vision 2014*. Bd. 8693. 2014, S. 740–755. DOI: 10.1007/978-3-319-10602-1-48.
- [73] Lindberg, E. et al.: Estimation of stem attributes using a combination of terrestrial and airborne laser scanning. In: *European Journal of Forest Research* 131.6 (2012), S. 1917–1931. ISSN: 1612-4669. DOI: 10.1007/s10342-012-0642-5.

- 
- [74] Löfgren, B.: Kinematic control of redundant knuckle booms with automatic path following functions. Dissertation. Stockholm: KTH Royal Institute of Technology.
- [75] Lottes, P. et al.: Effective Vision-based Classification for Separating Sugar Beets and Weeds for Precision Farming. In: *Journal of Field Robotics* 34.6 (2017), S. 1160–1178. ISSN: 15564959. DOI: 10.1002/rob.21675.
- [76] Lottes, P. et al.: Fully Convolutional Networks With Sequential Information for Robust Crop and Weed Detection in Precision Farming. In: *IEEE Robotics and Automation Letters* 3.4 (2018), S. 2870–2877. DOI: 10.1109/LRA.2018.2846289.
- [77] Manner, J. et al.: Forwarder crane’s boom tip control system and beginner-level operators. In: *Silva Fennica* 51.2 (2017), S. 1–10. DOI: 10.14214/sf.1717.
- [78] Manner, J. et al.: Load level forwarding work element analysis based on automatic follow-up data. In: *Silva Fennica* 50.3 (2016), S. 1–19. DOI: 10.14214/sf.1546.
- [79] MathWorks: smooth. 2021. URL: [https://de.mathworks.com/help/curvefit/smooth.html?s\\_tid=doc\\_ta#d123e45462](https://de.mathworks.com/help/curvefit/smooth.html?s_tid=doc_ta#d123e45462) (besucht am 14. 10. 2021).
- [80] Milioto, A., Lottes, P., Stachniss, C.: Real-Time Blob-Wise Sugar Beets vs Weeds Classification for Monitoring Fields using Convolutional Neural Networks. In: *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. Bd. IV-2/W3. 2017, S. 41–48. DOI: 10.5194/isprs-annals-IV-2-W3-41-2017.
- [81] Morales, D. O. et al.: Increasing the Level of Automation in the Forestry Logging Process with Crane Trajectory Planning and Control. In: *Journal of Field Robotics* 31.3 (2014), S. 343–363. ISSN: 15564959. DOI: 10.1002/rob.21496.

- [82] Morales, D. O. et al.: Path-Constrained Motion Analysis: An Algorithm to Understand Human Performance on Hydraulic Manipulators. In: *IEEE Transactions on Human-Machine Systems* 45.2 (2015), S. 187–199. ISSN: 2168-2291. DOI: 10.1109/THMS.2014.2366873.
- [83] Mortensen, A. K. et al.: Semantic Segmentation of Mixed Crops using Deep Convolutional Neural Network. In: *CIGR-AgEng conference 2016*, Aarhus, Denmark, 26. - 29. Juni. 2016, S. 1–6.
- [84] Moskal, L. M. und Zheng, G.: Retrieving Forest Inventory Variables with Terrestrial Laser Scanning (TLS) in Urban Heterogeneous Forest. In: *Remote Sensing* 4.1 (2012), S. 1–20. DOI: 10.3390/rs4010001.
- [85] Nair, V. und Hinton, G. E.: Rectified linear units improve restricted boltzmann machines, 27th International Conference on Machine Learning (ICML 2010), Kaifa, 21.-24. Juni 2010. In: *ICML'10 Proceedings of the 27th International Conference on International Conference on Machine Learning (2010)*, S. 807–814.
- [86] Nurmi, J. und Mattila, J.: Global Energy-Optimal Redundancy Resolution of Hydraulic Manipulators: Experimental Results for a Forestry Manipulator. In: *Energies* 10.5 (2017), S. 1–31. DOI: 10.3390/en10050647.
- [87] Nurmi, J. und Mattila, J.: Global energy-optimised redundancy resolution in hydraulic manipulators using dynamic programming. In: *Automation in Construction* 73 (2017), S. 120–134. ISSN: 09265805. DOI: 10.1016/j.autcon.2016.09.006.
- [88] Nurminen, T.; Korpunen, H. und Uusitalo, J.: Time consumption analysis of the mechanized cut-to-length harvesting system. In: *Silva Fennica* 40.2 (2006), S. 335–363. DOI: 10.14214/sf.346.

- 
- [89] Nurunnabi, A.; Sadahiro, Y. und Lindenberg, R.: Robust Cylinder Fitting in Three-Dimensional Point Cloud Data. In: ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences XLII-1/W1 (2017), S. 63–70. DOI: 10.5194/isprs-archives-XLII-1-W1-63-2017.
- [90] Padilla, R. et al.: A Comparative Analysis of Object Detection Metrics with a Companion Open-Source Toolkit. In: Electronics 10.3 (2021), S. 1–28. DOI: 10.3390/electronics10030279.
- [91] Park, Y. et al.: 3D Log Recognition and Pose Estimation for Robotic Forestry Machine. In: 2011 IEEE International Conference on Robotics and Automation (2011), S. 5323–5328.
- [92] Pedersen, M. M.; Hansen, M. R. und Ballebye, M.: Developing a Tool Point Control Scheme for a Hydraulic Crane Using Interactive Real-time Dynamic Simulation. In: Modeling, Identification and Control: A Norwegian Research Bulletin 31.4 (2010), S. 133–143. ISSN: 0332-7353. DOI: 10.4173/mic.2010.4.2.
- [93] Penrose, R.: A generalized inverse for matrices. In: Math. Proc. Camb. Phil. Soc. (Mathematical Proceedings of the Cambridge Philosophical Society). Bd. 51, S. 406–413. DOI: 10.1017/S0305004100030401.
- [94] Ponsse Plc: Active Crane. 2021. URL: <https://www.ponsse.com/de/produkte/individuelle-losungen/produkte/-/p/activecranebisonbuffaloelephant#/> (besucht am 09. 08. 2021).
- [95] Ponsse Plc: Die beste Informationstechnologie zur Unterstützung des Fahrers. 2021. URL: <https://pim.ponsse.com/media/ponsse-pim-api/api/content/getfile/13419603.pdf> (besucht am 29. 08. 2021).
- [96] Ponsse Plc: Ponsse Attachements add Value to your Machine. URL: [http://www.toimilgruas.com/pdf/Attachment\\_ENGL.pdf](http://www.toimilgruas.com/pdf/Attachment_ENGL.pdf) (besucht am 13. 04. 2019).

- [97] Purfürst, T.: Der Einfluss des Menschen auf die Leistung von Harvestersystemen. Dissertation. Dresden: Technische Universität Dresden, 2009.
- [98] Redmon, J. et al.: You Only Look Once: Unified, Real-Time Object Detection. In: arXiv arXiv:1506.02640v5 (2015), S. 1–10.
- [99] Ringdahl, O.: Automation in Forestry –Development of Unmanned Forwarders. Dissertation. Umea: Umea University, 2011.
- [100] Ringdahl, O. et al.: Enhanced Algorithms for Estimating Tree Trunk Diameter Using 2D Laser Scanner. In: Remote Sensing 5.10 (2013), S. 4839–4856. DOI: 10.3390/rs5104839.
- [101] Rousseeuw, P. J. und van Driessen, K.: Computing LTS Regression for Large Data Sets. In: Data Mining and Knowledge Discovery 12.1 (2006), S. 29–45. ISSN: 1384-5810. DOI: 10.1007/s10618-005-0024-4.
- [102] Ruigrok, T. M. L. et al.: A robust plant localization and identification system for precision farming: The effects of uncontrolled illumination on an end-to-end deep-learning plant detection algorithm. In: Land.Technik AgEng 2019 : Hannover, Nov. 8th + 9th 2019 : 77th International Conference on Agricultural Engineering. VDI Verlag GmbH Düsseldorf, 2019, S. 383–390.
- [103] Ruzgiene, B. und Förstner, W.: Ransac for Outlier Detection. In: Geodesy and Cartography 31.3 (2005), S. 83–87. DOI: 10.1080/13921541.2005.9636670.
- [104] Savia, M. und Koivo, H.: On-Line Payload Estimation of a Moving Loader using Neural Networks, 15. Triennial World Congress, Barcelona, 21.-26. Juli 2002. In: IFAC Proceedings Volumes 35.1 (2002), S. 37–42. ISSN: 14746670. DOI: 10.3182/20020721-6-ES-1901.01157.

- 
- [105] Schulz, C.: Berufspolitisches Engagement gefragt! Interview von Christoph Schulz mit Christian Feußner, beide Angestelltenvertreter im Gesamtpersonalrat von Hessen-Forst. In: BDF aktuell 58.1 (2017), S. 20–21.
- [106] Al-Sharadqah, A. und Chernov, N.: Error analysis for circle fitting algorithms. In: *Electronic Journal of Statistics* 3 (2009), S. 886–911. ISSN: 1935-7524. DOI: 10.1214/09-EJS419.
- [107] Siciliano, B. und Khatib, O., (Hrsg.): *Springer handbook of robotics*. Berlin und Heidelberg: Springer, 2008. ISBN: 978-3-540-23957-4.
- [108] Steindl, J.: Kran. EP 3 378 823 A1.
- [109] Tang, S.; Roberts, D. und Golparvar-Fard, M.: Human-object interaction recognition for automatic construction site safety inspection. In: *Automation in Construction*. Bd. 120, S. 1–16. DOI: 10.1016/j.autcon.2020.103356.
- [110] Thies, M. et al.: Three-dimensional reconstruction of stems for assessment of taper, sweep and lean based on laser scanning of standing trees. In: *Scandinavian Journal of Forest Research* 19.6 (2004), S. 571–581. ISSN: 0282-7581. DOI: 10.1080/02827580410019562.
- [111] Usui, K. et al.: Log detection based on deep convolutional neural networks, 2 International Symposium on Forestry Mechanization, Sopron, 6. - 10. Oktober 2019. In: *Proceedings of the 52nd International Symposium on Forestry Mechanization*. 2019, Poster.
- [112] Walawalkar, A. und Heep, S.: A method for payload estimation in excavators, 4th Commercial Vehicle Technology Symposium (CVT 2016), Kaiserslautern, 8.-10. März 2016. In: *Proceedings of the 4th Commercial Vehicle Technology Symposium (CVT 2016)*. Hrsg. von Karsten Berns et al. Aachen: Shaker Verlag, 2016, S. 2–16. ISBN: 978-3-8440-4229-0.

- [113] Walawalkar, A. und Schindler, C.: Validation of an analytical method for payload estimation in excavators, 5th Commercial Vehicle Technology Symposium (CVT 2018), Kaiserslautern, 13.-15. März 2018. In: Commercial vehicle technology 2018. Hrsg. von Karsten Berns et al. Proceedings. Wiesbaden: Springer Vieweg, 2018, S. 3–16. ISBN: 978-3-658-21299-5. DOI: 10.1007/978-3-658-21300-8.
- [114] Westerberg, S.: Semi-automating forestry machines: Motion planning, system integration, and human-machine interaction. Bd. 6. Robotics and control lab. Umeå: Department of applied physics and electronics, Umeå Universitet, 2014. ISBN: 978-91-7601-061-7.
- [115] Westerberg, S. und Shiriaev, A.: Virtual Environment-Based Teleoperation of Forestry Machines: Designing Future Interaction Methods. In: Journal of Human-Robot Interaction 2.3 (2013). DOI: 10.5898/JHRI.2.3.Westerberg.
- [116] Whitney, D.: Resolved Motion Rate Control of Manipulators and Human Prostheses. In: IEEE Transactions on Human-Machine Systems 10.2 (1969), S. 47–53. ISSN: 2168-2291. DOI: 10.1109/TMM S.1969.299896.
- [117] Wide, M. I.: Väg rätt redan i skogen. Hrsg. von Skogforsk, Uppsala. 2012. URL: <https://www.skogforsk.se/kunskap/kunskapsbanken/2012/Vag-ratt-redan-i-skogen/> (besucht am 28. 12. 2022).
- [118] Wippel, B. und Viergutz, M.: Stärkung der Kooperationsstrukturen von Forstunternehmern in Baden-Württemberg: Abschlussbericht. 2014.
- [119] Xi, Z.; Hopkinson, C. und Chasmer, L.: Automating Plot-Level Stem Analysis from Terrestrial Laser Scanning. In: Forests 7.12 (2016), S. 252–272. DOI: 10.3390/f7110252.

- 
- [120] Xiang, Y.: AI and IoT Meet Mobile Machines: Towards a Smart-Working Site. Dissertation. Karlsruhe: Karlsruher Institut für Technologie, 2021.
- [121] Xiao, B. und Kang, S.-C.: Development of an Image Data Set of Construction Machines for Deep Learning Object Detection. In: *Journal of Computing in Civil Engineering* 35.2 (2021), S. 1–18. ISSN: 0887-3801. DOI: 10.1061/(ASCE)CP.1943-5487.0000945.
- [122] Xuehui et al.: Dataset and benchmark for detecting moving objects in construction sites. In: *Automation in Construction* 122 (2021), S. 1–18. ISSN: 09265805. DOI: 10.1016/j.autcon.2020.103482.
- [123] Yung, I.: Automation of Front-End Loaders: Electronic Self Leveling and Payload Estimation. Dissertation. Sweden: Umea University, 2017.
- [124] Zheng, Y. et al.: Laser scanning measurements on trees for logging harvesting operations. In: *Sensors (Basel, Switzerland)* 12.7 (2012), S. 9273–9285. DOI: 10.3390/s120709273.
- [125] Zhou, Q.-Y.; Park, J. und Koltun, V.: Open3D: A Modern Library for 3D Data Processing. In: *arXiv arXiv:1801.09847* (2018), S. 1–6.



## A Vollständige Liste eigener Publikationen

Geiger, C. et al.: Assistance System for an Automatic Loading Process. 53rd International Symposium on Forest Mechanization (FORMEC), Corvallis, 27.-30. Okt. 2021. In: Proceedings of The Joint 43rd Annual Meeting of Council on Forest Engineering (COFE) & the 53rd International Symposium on Forest Mechanization (FORMEC) (2021), S. 5–7.

Geiger, C.; Beiser, S. und Geimer, M.: Automated Driving on a Skid Road with a Forwarder in a CTL Logging Process. 53rd International Symposium on Forest Mechanization (FORMEC), Corvallis, 27.-30. Okt. 2021. In: Proceedings of The Joint 43rd Annual Meeting of Council on Forest Engineering (COFE) & the 53rd International Symposium on Forest Mechanization (FORMEC) (2021), S. 135.

Geiger, C. et al.: Assistance System for an Automated Log-Quality and Assortment Estimation based on Data-Driven Approaches using Hydraulic Signals for Forestry Machines. In: 12th International Fluid Power Conference (2020), S. 83–92. DOI: 10.25368/2020.97.

Geiger, C. et al.: Reduzierung des Energieverbrauchs bei Ladevorgängen von Forstmaschinen durch hydraulische Transformatoren. In: 11. Kolloquium Mobilhydraulik. Hrsg. von Marcus Geimer. Karlsruhe: KIT Scientific Publishing, 10. September 2020, S. 115– 131.

Geiger, C. et al.: Entwicklung und Evaluation eines Wiegesystems für Forstkräne auf Basis von künstlichen neuronalen Netzen. In: LANDTECHNIK Bd. 74 Nr. 5 (2019), S. 102–117. DOI: 10.15150/lt.2019.3213.

Geiger, C.; Happel, J. und Geimer, M.: Sustainable Logging Process by a Forwarder with an Innovative Hydro-Pneumatic Suspension, The Sixteenth Scandinavian International Conference on Fluid Power, Tampere, 22.-24. Mai 2019. In: The Sixteenth Scandinavian International Conference on Fluid Power. Hrsg. von Kalevi Huhtala; Seppo Tikkanen und Janne Uusi-Heikkilä. 2019, S. 79–88. ISBN: 978-952-03-1302-9.

Geiger, C. et al.: The Potential of a Weight Detection System for Forwarders using an Artificial Neural Network, 51 Anniversary of the International Symposium on Forestry Mechanization, Madrid, 24.-28. Sep. 2018. In: FORMEC 2018 – Improved Forest Mechanisation: mobilizing natural resources and preventing wildfires. Hrsg. von Fundación Conde del Valle de Salazar. 2018, S. 157–164. ISBN: 978-84-96442-84-9.

Geiger, C. und Geimer, M.: Efficiency Optimisation of a Forestry Crane by Implement Hydraulics with Energy Recovery, 5th International Conference on Agricultural Engineering - LAND.TECHNIK AgEng 2017 - The Forum for Agricultural Engineering Innovations, Hannover, 10.-11. November 2017. In: VDI-Berichte. Bd. 2300. Düsseldorf: VDI Verlag GmbH, 2017, S. 117–125.

Geiger, C.: Wärmetransportoptimierung in Biogasanlagen durch innovative Wärmeübertrager und Konzeptevaluation mittels CFDMethoden, 74. Internationale Tagung „LAND.TECHNIK 2016“, Köln, 22.-23. Nov. 2016. In: VDI-Berichte. Bd. 2273. Düsseldorf: VDI Verlag GmbH, 2016, S. 219–225. DOI: 10 . 5445 / IR / 1000067257.

Hohenlohe, Felix, zu; Geiger, C. und Geimer, M.: Hybridantrieb für den Ladekran einer Forstmaschine. In: Hybride und energieeffiziente Antriebe für mobile Arbeitsmaschinen : 7. Fachtagung, 20. Februar 2019, Karlsruhe. Hrsg. von Wissenschaftlicher Verein für Mobile Arbeitsmaschinen. Karlsruhe: KIT Scientific Publishing, 2019. DOI: 10.5445/IR/1000091554.

Starke, M. und Geiger, C.: Field Setup and Assessment of a Cloud- Data Based Crane Scale (CCS) Considering Weight- and Local GreenWood Density-Related Volume References. In: Croatian journal of forest engineering 43.1 (2022), S. 29–45. ISSN: 18455719. DOI: 10.5552/crojfe.2022.1186.

Wydra, M.; Bauer, A.; Geiger, C.; Geimer, M.:Moderne Steueralgorithmen für Forstkräne mittels künstlichen neuronalen Netzen imitieren und optimieren. In: LANDTECHNIK Bd. 75 Nr. 2 (2020), S. 118-140. DOI: 10.15150/lt.2020.3241

Geiger, C.; Weiser, C. und Geimer, M.: Real-time Object Detection on a Forestry Logging Site based on Convolutional Neural Networks combined with a specialized Feature Estimation for Logs to be Loaded: REVIEW PENDING. In: LANDTECHNIK.