

Bachelorarbeit

Jan Robert Rösler

Bildbasierte Navigation mit Neuronalen Netzen

Jan Robert Rösler

Bildbasierte Navigation mit Neuronalen Netzen

Bachelorarbeit eingereicht im Rahmen der Bachelorprüfung
im Studiengang Bachelor of Science Technische Informatik
am Department Informatik
der Fakultät Technik und Informatik
der Hochschule für Angewandte Wissenschaften Hamburg

Betreuender Prüfer: Prof. Dr.-Ing. Andreas Meisel
Zweitgutachter: Prof. Dr. rer.nat. Stephan Pareigis

Eingereicht am: 17.04.2019

Jan Robert Rösler

Thema der Arbeit

Bildbasierte Navigation mit Neuronalen Netzen

Stichworte

Deep Learning, Autonomes Fahren, Machine Learning, Transferlernen, Bildverarbeitung

Kurzzusammenfassung

In dieser Bachelorarbeit soll untersucht werden, wie ausschließlich kamerabasierte Navigation funktioniert. Konkret geht es um das Erkennen einer Fahrbahn mit einem Neuronalen Netz, bzw. um das Erzeugen von Lenkwinkeldaten auf Basis eines Bildes einer Fahrbahn. Hierzu wird ein trainiertes Neuronales Netz mittels Fine Tuning abgestimmt. Das wird direkt zur Anwendung gebracht auf einem RC Fahrzeug, inklusive Fahrten auf einer Teststrecke.

Jan Robert Rösler

Title of Thesis

Image based navigation with Neural Networks

Keywords

deep learning, CNN, machine learning, autonomous driving, data augmentation, saliency, transfer learning, preprocessing

Abstract

This thesis is concerned with the task of navigation, based on image data. The goal is to generate steering commands from a greyscale image of a model roadway. To achieve this, a trained convolutional neural network is fine tuned to the specific task. The network is integrated into a steering model for a remote-controlled-car and used to steer on a test track.

Inhaltsverzeichnis

Abbildungsverzeichnis	v
Tabellenverzeichnis	vi
Abkürzungen	viii
1 Einleitung	1
1.1 Autonome Navigation mit Bilddaten	2
2 Neuronale Navigation mit Bilddaten	3
2.1 Relevante Technik/Hintergrund	3
2.1.1 Deep Learning	3
2.1.2 CNN	4
2.1.3 ResNet	4
2.1.4 Pre-Trained und Fine Tuning	5
2.1.5 Data Augmentation	6
2.1.6 Stratified Sampling	6
2.1.7 Histogrammausgleich	6
2.1.8 Saliency-Map	7
2.2 Ansätze	7
2.2.1 ALVINN	7
2.2.2 NVIDIA DAVE-2	8
3 Idee	10
3.1 DroNet und Carolo-Cup	10
4 Entwurf	13
4.1 Hardware und Strecke	14
4.2 Trainingsdaten	15

4.3	Datenverarbeitung	16
4.3.1	Software	16
4.3.2	Preprocessing	17
4.3.3	Real-Time-Processing	19
4.4	Fine Tuning	21
4.4.1	Netzarchitektur	21
4.4.2	Trainingskonfiguration	22
4.5	Steuerung	24
5	Auswertung und Szenarien	26
5.1	Training	26
5.2	Testfahrt	27
5.3	Einzelzenarien	29
5.4	Visualisierung	31
6	Resümee	34
	Glossar	40
	Selbstständigkeitserklärung	42

Abbildungsverzeichnis

2.1	Residual Block	4
2.2	ALVINN Architektur (a) und simulierte Fahrbahn (b)	8
2.3	Komponenten des Trainings	9
3.1	Architektur DRONET	10
3.2	Einfacher schematischer Aufbau	11
4.1	Das Carolo-Cup Fahrzeug	14
4.2	Ein Ausschnitt der Teststrecke	15
4.3	Kameraaufnahme der Fahrbahn	16
4.4	Skalierung der Lenkwinkel-Wertebereiche	17
4.5	Lenkwinkelverteilung im Bilderset	18
4.6	Bildverarbeitungsschritte	20
4.7	Beispiele verschiedener Bearbeitungsstufen, zugeschnitten (a), nach Histogrammausgleich (b) und nach Rausch-Filter (c)	21
4.8	Angepasste Architektur	22
4.9	Struktur des Lernprozesses	23
4.10	Komponentenstruktur und Verbindung der Neuronalen Steuerung	25
5.1	Traningsfehler (train) und Validierungsfehler (val) über 100 Epochen	26
5.2	Fehlerszenarien	30
5.3	Kreuzungsszenario aus Sicht der Fahrzeugkamera	30
5.4	Ausschlaggebende Bildbereiche	33

Tabellenverzeichnis

5.1	Algorithmen im Vergleich	28
5.2	Vergleich der Autonomie	29

Abkürzungen

ALVINN Autonomous Land Vehicle In a Neural Network.

CNN Convolutional Neural Network.

IDS Imaging Development Systems GmbH.

NUC Next Unit of Computing.

UDS Unix Domain Sockets.

VSCoDe Virtual Studio Code.

1 Einleitung

Sobald ein System, welcher Art sei offen, mobil wird, also läuft, rollt, gleitet, schwebt oder schwimmt, steht es vor der Aufgabe der Navigation. Das kann zunächst bedeuten, zu Wissen, wo es sich befindet. Auf einer Karte oder auch relativ zu anderen Objekten in der Umgebung. In der Robotik nennt man diese Kompetenz Lokalisation. Wenn man weiß, wo man ist, könnte sich zusätzlich die Frage stellen, wie man zu einem bestimmten Ort hinkommt. Je nach Ziel oder Aufgabe des mobilen Systems, ist die in der Robotik Pfadplanung genannte Kompetenz von Bedeutung.

Um sich in einer Umgebung zu bewegen, kann es ebenfalls interessant sein, eine eigene Repräsentation der Umgebung zu erstellen. Das Aufbauen einer Karte ist in der Robotik das Mapping und beinhaltet als Disziplin auch das Interpretieren und Auswerten von den gesammelten Umgebungsinformationen in einer Karte.

Es wird vorausgesetzt, dass ein solches System bzw. ein solcher Roboter keinerlei Navigationshilfe (z.B. Steuersignale) von außen erfährt, sondern völlig autonom Entscheiden und navigieren muss.

Als Grundstein der Entwicklung solcher autonomer Systeme kann man die Erfindung des Neurophysiologen William Grey Walter festmachen [16]. Seine in den späten 40er Jahren entwickelten und „Elmer“ und „Elsie“ getauften Roboter, sollten ihm dabei helfen, das menschliche Gehirn besser zu verstehen. Beide Roboter, wegen ihrer Form auch Schildkröten genannt, konnten mit je einem Licht- und Berührungssensor, die wiederum jeweils mit einem Motor verbunden waren, unter anderem um Hindernisse herum navigieren. Die getrennte Ansteuerung der Motoren sollte Neuronen im Gehirn simulieren. Diese Gehirnanalogie findet sich in ähnlicher Weise in dieser Arbeit wieder, Neuronale Netze werden im Folgenden eine zentrale Rolle spielen.

Navigation in der Robotik setzt sich also aus verschiedenen Unterdisziplinen zusammen, die in ihrem Zusammenspiel ganz besonders aktuell viel Beachtung finden: Fahrzeuge der Firma Tesla sind bereits auf öffentlichen Straßen autonom unterwegs. Teil der technischen Ausstattung der Fahrzeuge (neben Ultraschallsensoren und Radar) sind Kameras zur Erfassung der Umgebung.

In dieser Arbeit wird gerade die visuelle, bildbasierte Navigation die zweite zentrale Rolle haben.

1.1 Autonome Navigation mit Bilddaten

Legt man der Navigationsaufgabe als einzigen Lösungsraum die Bilddaten einer Kamera zugrunde, dann bieten sich verschiedene Möglichkeiten an, diese zu verwenden. Objekterkennung ist häufig der erste Schritt, um sich in einer Umgebung zu orientieren und herauszufinden, aus was sich diese Umgebung überhaupt zusammensetzt. Zusätzlich muss entschieden werden, welche Teile dieser aus Objekten und Flächen aufgebauten Umwelt überhaupt betretbar beziehungsweise befahrbar ist. Für Systeme, die in Szenarien verwendet werden sollen, in denen auf Fahrbahnen, Straßen oder andersartig begrenzten Strecken navigiert werden soll, ist die Erkennung dieser Strecke die Schlüsselfunktion. In diesen Fällen bestimmt die Umgebung direkt, wo überhaupt gefahren werden darf, für die Navigation eine enorme Hilfe.

Um genau solche Szenarien soll es in dieser Arbeit gehen, speziell um das Fahren auf einer markierten Fahrbahn, die durch eine Kamera am Fahrzeugsystem erfasst wird.

2 Neuronale Navigation mit Bilddaten

2.1 Relevante Technik/Hintergrund

Hier erfolgt zunächst eine kurze Beschreibung der für Neuronale Navigation auf Bilddaten relevanten Technik. Grundlegendes wird nur der Vollständigkeit halber erwähnt, speziellere Aspekte kurz vorgestellt.

2.1.1 Deep Learning

Im Bereich des Maschinellen Lernens stellt das Deep Learning einen besonders populären Subbereich dar. Viele bekannte Anwendungen, die in den Medien auch als Künstliche Intelligenz bezeichnet werden, nutzen diese Technik. Eine Hierarchie aus Konzepten zu bauen, bei denen komplizierte Konzepte aus dem Produkt vieler einfacher Konzepte entstehen, erwies sich für das Lernen von Datenrepräsentationen als besonders geeignet. Diese Aufeinanderschichten von Berechnungsschritten in so genannten Layern, bildet ein tiefer Graph ab, auch Neuronales Netz genannt. Die Bezeichnung Deep Learning bezieht sich auf diese Struktur, mit der das Wissen aus Erfahrungswerten, den Trainingsdaten, extrahiert werden kann.

Deep Learning gliedert sich selbst in viele Unterthemen auf, eine Darstellung der Geschichte und Technikentwicklung soll hier nicht gegeben werden. Basiswissen zu maschinellem Lernen wird vorausgesetzt, Deep Learning im Speziellen wird in entsprechender Literatur detailliert erklärt, für diese Arbeit diente vor allem ein Hauptbuch ([4]) als begleitende Wissensquelle.

2.1.2 CNN

Convolutional Neural Network (CNN), haben sich gerade im Bereich der Bildverarbeitung als überlegen bewiesen. Aus der Biologie inspiriert, findet hier besonders das Prinzip des rezeptiven Feldes Anwendung. Die Aktivität jedes Neurons wird mithilfe einer Faltung berechnet, räumliche Informationen und Zusammenhänge werden so besser erhalten. 2012 konnte ein CNN, AlexNet [7], beim ImageNet-Wettbewerb den Benchmark-Rekord von 25,8 % auf 16,4 % drücken, seitdem sind alle gut platzierten Modelle CNNs. Nicht nur in der Bilderkennung, sondern auch in der Spracherkennung (Parsen, Satzmodellierung, Maschinelle Übersetzung) gelten CNNs als State-of-the-Art Methode und finden Anwendung in modernsten Technologien.

CNNs werden hier nicht detailliert erklärt, das Verständnis wird als Grundlage vorausgesetzt.

2.1.3 ResNet

Residual Neural Networks, oder kurz ResNet, ist eine weitere Technik, die ihren Ursprung in der Biologie hat. Das Verhalten so genannter Pyramidenzellen, Nervenzellen im menschlichen Gehirn, wird nachgebildet, indem Abkürzungen zwischen Layer eingebaut werden. Residual Netze wurden 2015 entwickelt, insbesondere ließ sich mit diesem Ansatz das Trainieren tiefer Netze verbessern [5]. Abbildung 2.1 zeigt den schematischen Aufbau eines so genannten Residual Blocks.

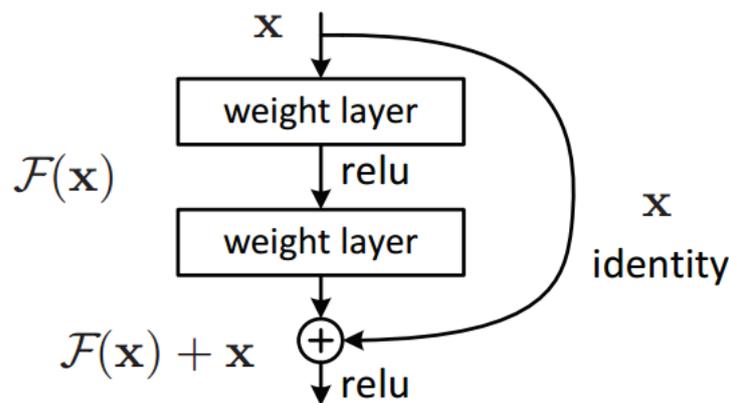


Abbildung 2.1: Residual Block
Quelle: [19]

Je tiefer ein Neuronales Netz ist, desto schwieriger wird das Trainieren aller Layer, ein Problem in diesem Zusammenhang ist das „Vanishing Gradient Problem“. Für tiefe Layer wird der berechnete Gradient so verschwindend klein, dass irgendwann keine Änderung der Gewichte in den Layern mehr stattfindet, so stagniert das Training und es können keine weiteren Fortschritte erzielt werden.

Der Residual-Ansatz fügt einem normalen Block gewichteter Layer eine Abkürzung hinzu. Wie in Abbildung 2.1 zu sehen, wird der Input x des Blocks direkt auf den Output addiert. Nimmt man an, dass es für den Input x eine richtige Gewichtsverteilung $H(x)$ der Layer im Block gibt, die erlernt werden soll, dann ist der Unterschied zwischen dem Input und dieser optimalen Verteilung $F(x)=H(x)-x$. $F(x)$ ist das „Residual“, stellt man die Funktion um, erhält man $H(x)=F(x)+x$. Statt der optimalen Gewichtsverteilung für den Block, lernt das Netz jetzt $F(x)$, also gerade den Unterschied zur Identitätsfunktion des Inputs x .

Die Annahme der Autoren ([5]) war, dass diese Residual-Funktion besser zu erlernen sei, als das originale Mapping. Selbst wenn das gelernte Residual $F(x)=0$, bekommt man für den Input x immernoch die Identitätsfunktion, also x selbst heraus. Das dieses Mapping meistens näher an der gewünschten optimalen Gewichtsverteilung liegt, war eine weitere Annahme.

In Versuchen mit Neuronalen Netzen verschiedener Tiefe konnten diese Annahmen bestätigt werden.

2.1.4 Pre-Trained und Fine Tuning

In dem Bereich des TRANSFER LEARNING gibt es verschiedene Verfahren. Fine Tuning beschreibt einen Prozess, in dem ein bereits trainiertes Neuronales Netz für eine ähnliche Aufgabe abgestimmt wird. Das Netz wird als PRE-TRAINED bezeichnet. Dabei können Teile der Layer des ursprünglichen Netzes ersetzt werden, oder neue hinzugefügt werden. Insbesondere bei Klassifizierungsaufgaben wird dazu häufig die Kategorisierung verändert, um zum Beispiel die von einem Netz erlernten Eigenschaften auf neue Kategorien anzuwenden.

In diesem Zusammenhang wird auch LAYER-FREEZING, also das Einfrieren von Layern vor dem Training verwendet. Eingefrorene Layer aktualisieren ihre Gewichte nicht und sind damit vom Trainingsprozess ausgeschlossen. So soll verhindert werden, dass bereits erlernte Eigenschaften eines Netzes, wie „Katzenohr“ oder auch „Linie“ nicht verloren

gehen. Dazu werden frühere Layer meist eingefroren, spätere auf einem neuen Datensatz trainiert, um die bereits erlernten Eigenschaften zu nutzen und nicht zu verändern und Eigenschaften für die neue, ähnliche Aufgabe zu erlernen.

2.1.5 Data Augmentation

Um qualitativ hochwertige Trainingsdaten zu erhalten, bietet sich häufig eine Vermehrung der Datenbasis an. Dieses Verfahren wird als DATA AUGMENTATION bezeichnet. In der Bildverarbeitung können zum Beispiel durch Spiegelung oder Verschieben neue Trainingsbilder generiert werden, die vorher noch nicht vorhanden waren. Dazu kann auch eine Anpassung der Label notwendig werden.

Data Augmentation kann auch verwendet, um die Varianz einer Datenbasis zu erhöhen. Dazu können in der Bildverarbeitung zum Beispiel Rausch-Filter angewandt werden.

2.1.6 Stratified Sampling

Wenn eine Kategorie einer Datenmenge überrepräsentiert ist, kann es sinnvoll sein, die Stichprobenumfänge der Kategorien einzuschränken. Diesen Vorgang nennt man STRATIFIED SAMPLING. Durch diese Beschränkung wird insbesondere bei Lernverfahren vermieden, dass die überrepräsentierte Kategorie sich im Ergebnis stärker auswirkt.

2.1.7 Histogrammausgleich

Der HISTOGRAMMAUSGLEICH ist ein Verfahren zur Regulierung der Helligkeit eines Bildes. Alle Grauwerte des Bildes werden um einen feste Konstante, entweder in den hellen oder den dunklen Bereich verschoben. Werte, die unten oder oben aus der SKala rausgeschoben werden, werden auf dem kleinsten beziehungsweise größten Wert der Skala gesetzt.

2.1.8 Saliency-Map

In der visuellen Verarbeitung sind bestimmte Qualitäten einzelner Pixel oder Bildbereiche von Interesse. SALIENCY MAPS helfen, diese Bereiche zu identifizieren und sichtbar zu machen. Saliency-Maps sind topographische Repräsentationen bedeutender Informationen. Je nach Anwendungsfall gibt es verschiedene Berechnungsverfahren.

2.2 Ansätze

Im folgenden wird auf zwei Ansätze der Navigation mit Neuronalen Netzen eingegangen, durch Gegenüberstellung erster Versuche mit einem modernen Ansatz soll folgenden Ausarbeitungen ein Rahmen gegeben werden.

2.2.1 ALVINN

Versuche durch neuronale Verarbeitung von reinen Bilddaten in einem Szenario zu navigieren, gab es bereits 1989 in Pomerleau's Arbeit, die man auf diesem Gebiet als Pionierarbeit verstehen kann[13]. Das Netzwerk Autonomous Land Vehicle In a Neural Network (ALVINN) sollte das NAVLAB steuern, ein Testfahrzeug für Autonome Navigation der Carnegie Mellon University. In 2.2a lässt sich die Architektur nachvollziehen. Der rein visuelle Input wird unterstützt durch eine laserbasierte Abstandsmessung und ein Inputneuron für die Kodierung der „Straßenintensität“, also ob die Straße heller oder dunkler wird. Der Bildinput ist die Blaustufenintensität des jeweiligen Bildpunkts. Aus heutiger Sicht ist das Netz mit nur einer hidden Layer mit 29 Neuronen sehr klein, die im weiteren angesprochenen Architekturen haben deutlich mehr Layer und mehrere Hunderttausend Parameter.

Zudem interpretiert ALVINN die Aufgabe des Spurfolgens nicht als Regressionsproblem, sondern als Klassifikation. Die Ausgangsneuronen sind eine lineare Repräsentation der Lenkrichtung, die das Fahrzeug in Richtung Fahrbahnmitte steuert. Neuronen in der Mitte stehen für eine Fahrt geradeaus, Neuronen links und rechts für die jeweilige Fahrtrichtung. Grob gesagt gibt das Neuron mit dem höchsten Aktivierungslevel den einzuschlagenden Lenkwinkel, also die Fahrtrichtung an. Im Ergebnis konnte das Netz nach 40 Epochen Training auf simulierten Fahrbahnbildern, zu sehen in 2.2b, einen 400 Meter Weg durch einen Wald mit $\frac{1}{2}$ m/s sicher abfahren.

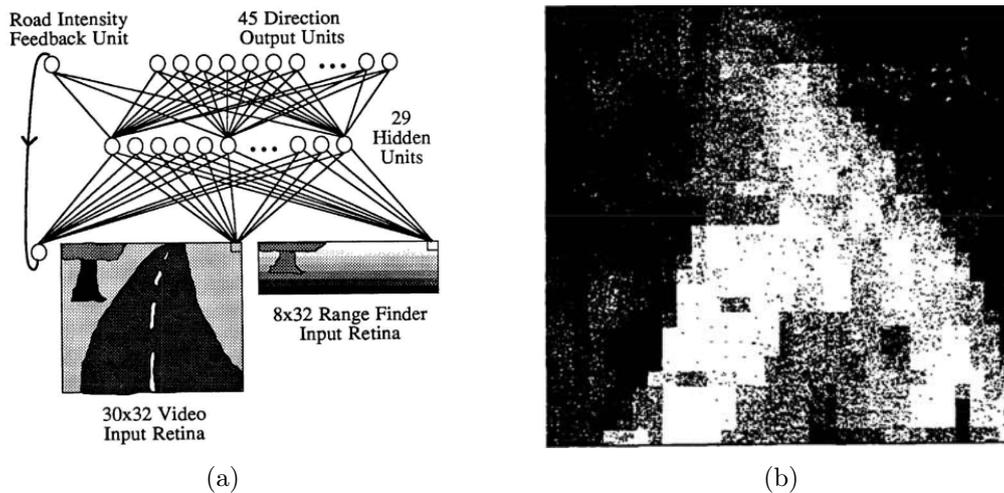


Abbildung 2.2: ALVINN Architektur (a) und simulierte Fahrbahn (b)

2.2.2 NVIDIA DAVE-2

Forschungserkenntnisse der folgenden Jahre trieben die technische Entwicklung voran, auch im Bereich der autonomen Navigation tat sich viel. Zur Orientierung wird eine aktuellere Forschungsarbeit vorgestellt, die einige Aufmerksamkeit auf sich zog. Im Jahr 2016 veröffentlicht das Technologieunternehmen NVIDIA einen eigenen Ansatz [1], basierend auf Versuchen mit dem „DARPA Autonomous Vehicle“ (DAVE) [17] wird dieser „Dave-2“ genannt. Daten werden hier durch Fahrten auf echten Straßen gesammelt, wofür drei Kameras in der Windschutzscheibe eines Autos angebracht und Steuerungsdaten über den CAN-Bus des Fahrzeuges ausgelesen werden. Mit diesen Daten wird ein CNN trainiert (2.3), was dann an einer Straßen-Simulation getestet wird. Hervorzuheben ist hier besonders die Verwendung von Convolutional Neural Networks (CNN) und die, im Gegensatz zum bereits erwähnten Ansatz 27 Jahre zuvor, stark gesteigerte Rechenleistung. Folglich können nicht nur Bilder besserer Qualität verarbeitet werden, die Netzarchitektur mit 9 Layern und 250.00 Parametern wäre 1989 nicht in annehmbarer Zeit trainierbar gewesen. Außerdem stellt sich NVIDIA dem Anspruch, eine neuronale Steuerung für öffentliche Straßen zu entwerfen, nicht nur für ein sehr begrenztes Testszenario.

Abbildung 2.3 zeigt die Komponenten des Trainingsprozesses.

Mit dem so trainierten CNN wurden sehr gute Ergebnisse erzielt. Sowohl in der Simulation, als auch auf Testfahrten in realen Straßensituationen, steuerte das neuronale Netz ein

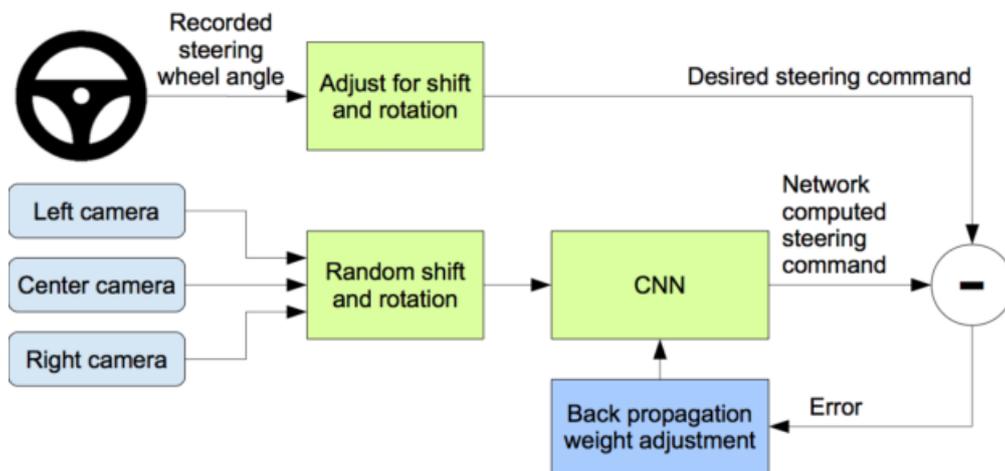


Abbildung 2.3: Komponenten des Trainings
Quelle: [18]

Auto nahezu fehlerfrei. Einige der Ansätze und Erkenntnisse aus dieser Arbeit lasse ich für den Entwurf und die Bewertung meiner Arbeit mit einfließen. Vor diesem Hintergrund wird im folgenden Kapitel die Entstehung der Idee zu dieser Arbeit erläutert.

3 Idee

3.1 DroNet und Carolo-Cup

DroNet Die ETH Zürich entwickelte 2018 eine eigene Architektur, mit dem Ziel durch Training auf Fahrbahnbildern eine Drohe zu steuern [9]. Das daraus entstandene, von Aufbau und Größe relativ einfach gehaltene Neuronale Netz, war der Anstoß für diese Arbeit.

Das Netz, in seinem Aufbau dargestellt in Abbildung 3.1, bekommt als Input ein 200x200 Pixel großes Bild in Graustufen, der Output ist ein Lenkwinkel und zusätzlich eine Kollisionswahrscheinlichkeit.

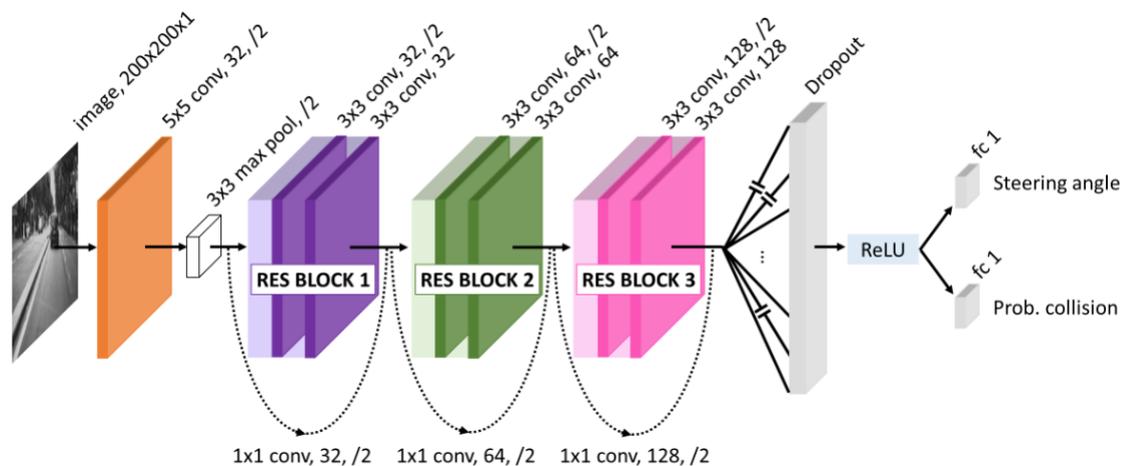


Abbildung 3.1: Architektur DRONET

Trainiert wurde das Netz auf frei verfügbaren Datensätzen der Firma Udacity, bestehend aus Bildern aufgenommen mit Kameras hinter der Windschutzscheibe eines Autos bei stundenlangen Fahrten über Amerikanische Highways. Die Aufnahmen sind mit Fahrdaten verbunden, Zeitstempel, GPS-Daten, Beschleunigungswerte und Lenkwinkel wurden für

jedes Bild der Aufnahmen gespeichert. Für das Training von DRONET werden nur die Bilder der Mittelkamera und der jeweilige Lenkwinkel genutzt.

Zusätzlich hat das Team der ETH Zürich eigene Aufnahmen mithilfe einer am einem Fahrrad montierten Kamera im Straßenverkehr gemacht und diese Aufnahmen manuell mit einer Kollisionswahrscheinlichkeit versehen. Wie bereits erwähnt hat das Netzwerk dementsprechend zwei verschiedene Outputs.

Für diese Arbeit ist aber nur der Lenkwinkel von Interesse, Kollision spielt als Szenario keine Rolle. Im Entwurf werden dementsprechend Anpassungen gemacht.

Es stellte sich heraus, dass das Modell der ETH Zürich hervorragend generalisierte und eine Drohne sicher durch ein Straßenszenario steuern konnte, wobei das Szenario sich deutlich von den gelernten Unterschied. Diese Eigenschaft von DRONET möchte ich mir im folgenden zu Nutze machen und auf dieser Basis ein Steuerungsmodell für ein RC-Fahrzeug entwickeln.

Carolo-Cup Die HAW Hamburg nimmt seit einigen Jahren am „Carolo-Cup“ teil, einem Wettbewerb der Technischen Universität Braunschweig. Hier treten Teams einiger deutscher Hochschulen mit RC-Fahrzeugen (Maßstab 1:10) in verschiedenen Disziplinen des autonomen Fahrens gegeneinander an. Der Wettbewerb findet jährlich in Braunschweig auf einem vorbereiteten Kurs statt.

Eine hauptsächlich von den HAW Studenten Nils Schönherr und Gunnar Wolfram aufgebaute Plattform, zu sehen in Abbildung 4.1, dient dieser Arbeit als Testplattform.



Abbildung 3.2: Einfacher schematischer Aufbau

Zum Entwickeln der Fahrzeuge steht an der HAW eine Teststrecke zur Verfügung, verschiedene Fahrzeugplattformen sind in der Entwicklung.

Vor diesem Hintergrund entstand die Idee für diese Arbeit.

Ziel Das Ziel dieser Bachelorarbeit ist, an einem konkreten Anwendungsfall zu zeigen, dass ein Fahrzeug autonom einen Streckenkurs abfahren kann, indem ein neuronales Netz live Bilder der Strecke auswertet und Lenkinformationen für das Fahrzeug berechnet, schematisch dargestellt in Abbildung (3.2). Da aktive Teams der HAW im Carolo-Cup aktuell klassische (Bildbasierte-) Navigationsansätze verfolgen (Kapitel 1.1), soll die Arbeit auch zeigen, wie eine nächste Generation der Fahralgorithmen für den Carolo-Cup aussehen kann.

Die autonome Fahrleistung auf der Teststrecke ist das Hauptaugenmerk, sie zu messen und zu analysieren ist Bestandteil der Arbeit.

4 Entwurf

In diesem Kapitel wird der vollständige Entwurf einer Steuerung für ein RC Fahrzeug dargestellt. Für dieses Kapitel war besonders Buch des Erfinders von Keras, Francois Chollet, hilfreich [2].

Wie im vorangegangenen Kapitel erläutert, entstand die Idee für die Steuerung eines RC-Fahrzeuges mit Neuronalen Netzen im Kontext einer Arbeit der ETH Zürich. Das dort entworfene DroNet wurde bereits kurz vorgestellt und wird die Basis für die neuronale Steuerung sein.

Basis DroNet ist ein 8-Layer Convolutional Neural Network, das hauptsächlich aus drei Residual-Blöcken besteht. Als Input bekommt das Netz ein 8-Bit Graustufenbild mit 200×200 Pixel. Es gibt zwei Outputs, einmal einen Lenkwinkel aus dem Intervall $[-1, 1]$ und einmal die Kollisionswahrscheinlichkeit in Prozent. hierbei gilt, Werte < 0 entsprechen einer Rechtskurve, Werte > 0 einer Linkskurve. DroNet hat 3.2×10^5 Parameter und schafft eine Verarbeitungsrate von 20 fps. Wie im vorigen Kapitel bereits erwähnt, wurde DroNet auf einem frei verfügbaren Datensatz trainiert.

In der Arbeit werden die Ergebnisse mit anderen Netzwerken verglichen, die mit dem selben Datensatz trainiert wurden. Anhand verschiedener Metriken zur Messung der Bestimmungsgenauigkeit, wird die Performance auf dem Datensatz bestimmt. Ein solcher Vergleich ist für diese Arbeit jedoch nicht durchgeführt, da ein konkretes Szenario untersucht wird.

4.1 Hardware und Strecke

Ein kurzer Überblick über die Hardwarebasis und Testumgebung.

Fahrzeug Das vom HAW-Team aufgebaute Fahrzeug für den Carolo-Cup 4.1, besteht, abgesehen von Chassis, Motorelektronik und Servos, im Kern aus einem Intel Next Unit of Computing (NUC), auf dem die vollständige Bildverarbeitung und Logik berechnet wird und der Kamera, die die Bilder liefert. Der Prozessor ist ein Intel i5 der dritten Generation. Die Kamera ist eine UYEYE Schwarzweißkamera der Firma Imaging Development Systems GmbH (IDS), die über USB mit dem NUC verbunden ist. Die Kontrolle per Fernsteuerung, zum Eingreifen im Fehlerfall und zum Positionieren des Fahrzeugs kommuniziert über Funk direkt mit dem Motorcontroller.

Auf dem Intel NUC ist ein Unix Betriebssystem eingerichtet. Eine funktionsfähige Hardware Abstraktion für den Motor und die Steuerungsservos ist vom Carolo-Cup Team bereits entwickelt und steht mir im Weiteren zur Verfügung. Diese ist in C++ implementiert.

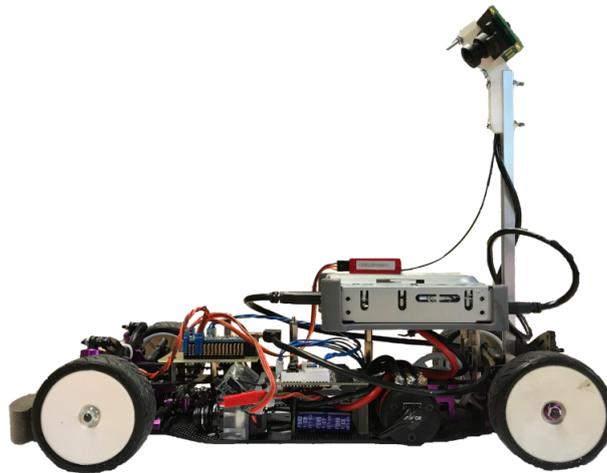


Abbildung 4.1: Das Carolo-Cup Fahrzeug

Strecke Die HAW Teststrecke ist ein Rundkurs mit verschiedenen Kurven und einem Kreuzungsszenario. Die Länge der äußeren Fahrbahn beträgt 36,1 Meter, die innere Fahrbahn ist 31,3 Meter lang.

Die Fahrbahn mit weißen Band auf schwarzem Untergrund abgeklebt und entspricht

der Erscheinung einer Straße, mit unterbrochener Mittellinie. Einige Besonderheiten der Strecke, wie zum Beispiel Parklücken, sind Teil der Aufgaben des Carolo-Cups, spielen in dieser Arbeit aber keine Rolle. Die Abbildung 4.2 zeigt einen Ausschnitt der Fahrbahn, zu sehen ist eine fast kreisförmige Kurve und die Kreuzungssituation. Der Teststreckenraum ist fensterlos, es wurde sowohl bei Aufnahme der Trainingsbilder, als auch bei den Testfahrten darauf geachtet, dass die volle Deckenbeleuchtung an ist, um für optimale und gleichbleibende Beleuchtungsverhältnisse zu sorgen.

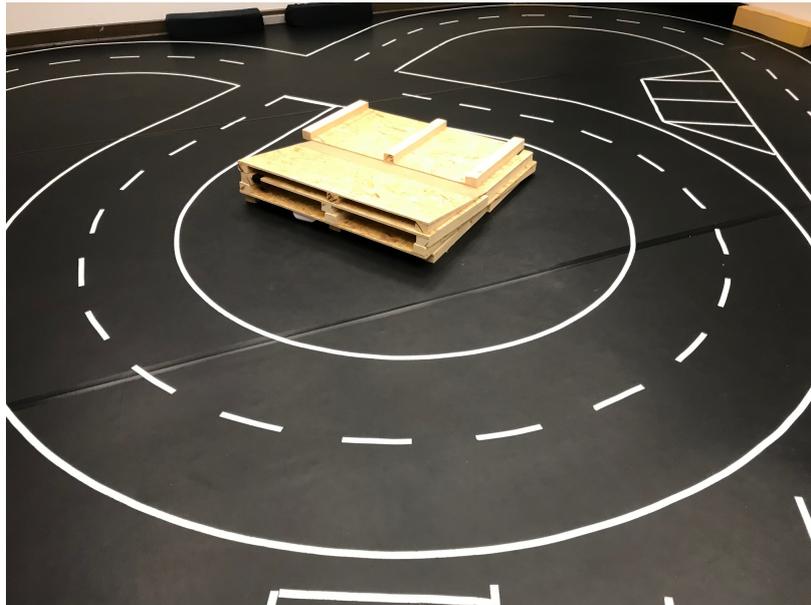


Abbildung 4.2: Ein Ausschnitt der Teststrecke

Rechnerhardware Bildverarbeitung und Training des Netzes werden auf einem Windows Computer (Windows 10) mit einer GeForce GTX 950 Grafikkarte berechnet. Da mit einer relativ kleinen Bildanzahl gearbeitet wird und das Neuronale Netz sehr kompakt in Hinblick auf die Parameteranzahl ist, wird keine High-end Grafikkarte benötigt.

4.2 Trainingsdaten

Um Trainingsdaten, also Bilder der Teststrecke mit dazugehörigem Lenkwinkel zu erzeugen, wird auf einen Algorithmus eines Carolo-Cup Teams (`TEAMWORSTCASE`) der HAW

zurückgegriffen. Qualitative Trainingsdaten per Handsteuerung mit der Fernbedienung zu generieren erwies sich als Fehleranfällig.

Datenbasis Auf mehreren Fahrten über den Rundkurs mit dem Algorithmus von TEAMWORSTCASE, wurden über 20.000 Bilder gesammelt. Fehlsteuerungen seitens des Algorithmus wurden im Anschluss per visueller Kontrolle aussortiert. Am Ende dieser Vorauswahl standen etwas über 6.000 Bilder für das Training zur Verfügung. Die Auflösung der Aufnahmen ist 752x480 Pixel. Die untere Hälfte der Bilder ist durch eine kamerainterne Vorverarbeitung bereits geschwärzt, TEAMWORSTCASE hat für ihre weitere Verarbeitung so direkt den Teil des Bildes ausgeblendet, auf dem das Fahrzeug selbst zu sehen ist. Da dieser Teil des Bildes im weiteren ohnehin weggeschnitten wird, hat das keine Auswirkungen.

Ein Beispiel aus diesen Fahrbahnaufnahmen zeigt Abbildung 4.3, die Aufnahme ist automatisch in Graustufen, die Kamera nimmt nur in diesem Modus auf. Zum Datensammeln wurde die Bildrate der Kamera erhöht, wozu die Belichtungszeit reduziert wurde. Die Aufnahmen sind aus diesem Grund dunkler. Diese Rohdaten sind die Basis für das Training und müssen dazu im Weiteren einer Vorverarbeitung unterzogen werden.

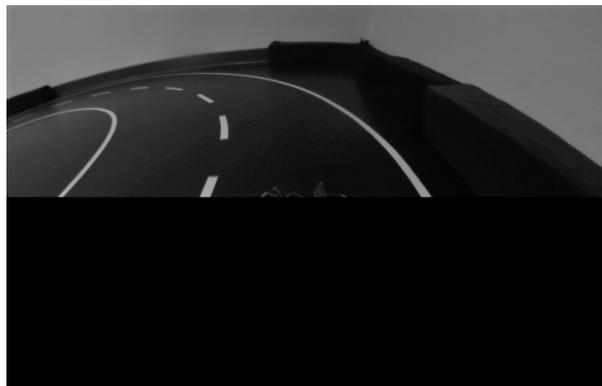


Abbildung 4.3: Kameraaufnahme der Fahrbahn

4.3 Datenverarbeitung

4.3.1 Software

Für die Umsetzung wurde folgende Software verwendet.

Die Bildverarbeitung und das Training sind mit Python programmiert. Für Operationen auf Bildern wird die OpenCV Bibliothek verwendet. Das Neuronale Netz und die Struktur für Verarbeitung der Bilder und Training sind mit Keras implementiert.

Einzelne Funktionen zur Auswertung und für das Training sind aus dem Repository der DroNet Gruppe der ETH Zürich übernommen, diese sind im Code entsprechend kenntlich gemacht.

Die Abstraktion für den Motorcontroller auf dem Fahrzeug ist in C++ implementiert, die Steuerungskontrolle auf Fahrzeugseite ist daher in C entwickelt.

Die Python Module laufen auf einem Windows Computer in einer virtuellen Umgebung, die mit Anaconda verwaltet wird. Es sind 2 Umgebungen mit Python 3.6.5 eingerichtet. Auf dem Fahrzeug (NUC) kommt zusätzlich Virtual Studio Code (VSCode) zum Einsatz, so wie eine Debugging Umgebung mit PyCharm für die Python Module. Keras wird in Version 2.1.6 auf einem Tensorflow-Backend in Version 1.10.0 verwendet.

4.3.2 Preprocessing

Um die Bilder für das Training aufzubereiten, wird eine Verarbeitungspipeline eingerichtet, die in der gleichen Form auch für die Vorverarbeitung im Steuerungsmodus genutzt wird. Die Bilder, die das Netz zum Training zu „sehen“ bekommt, sollen die gleiche Verarbeitung durchlaufen wie die Live-Bilder, die später zum Steuern benutzt werden.

Data-Label Processing Zunächst wird die Verteilung der Lenkwinkel betrachtet. Allerdings muss hier noch eine Skalierung erfolgen, denn die im Carolo-Cup-Fahrzeug verwendete Kodierung entspricht nicht der Kodierung, in der das trainierte neuronale Netz Inputdaten verarbeitet.

Links	Gerade	Rechts
1000	1500	2000
1	0	-1

Abbildung 4.4: Skalierung der Lenkwinkel-Wertebereiche

Wie Abbildung 4.4 zeigt, müssen die Wertebereiche umgerechnet werden. Der Intervall $[1000, 2000]$ wird auf $[1, -1]$ abgebildet. Die richtige Kodierung der Lenkwerte in Links und Rechts wurde dabei beachtet.

Die Lenkwinkel werden anhand einer Framenummer mit dem zugehörigen Bild verbunden und so für Trainings- und Validierungsordner gespeichert.

Data Augmentation Die Datenbasis soll erhöht werden, hierzu wird auf Bildspiegelung zurückgegriffen, ein Verfahren aus dem Bereich der Data Augmentation [3] [11].

In Abbildung 4.5 ist die Lenkwinkelverteilung grafisch aufbereitet. Die x-Achse bildet den Lenkwinkel aus $[-1, 1]$ ab, die y-Achse die Anzahl der Trainingsbilder mit dem jeweiligen Lenkwinkel. Grafik 4.5a zeigt die Verteilung der Lenkwinkel im Verhältnis zu der Anzahl der Bilder. Es wird sofort ersichtlich, dass die Mehrheit der gesammelten Lenkdaten von einer Fahrt geradeaus, mit Lenkwinkel um 0.0, stammen. Um eine möglichst ausgeglichene Verteilung zu erreichen wird eine Anpassung vorgenommen.

Stratified Sampling Zudem wird Stratified Sampling [8] angewendet, um die Überrepräsentation einer Datenkategorie zu vermeiden. Alle Bilder, mit Ausnahme derer, die mit einem Lenkwinkel von 0.0 assoziiert sind, werden gespiegelt. So kann die Trainingsdatensmenge verdoppelt werden und gleichzeitig eine ausgeglichene Verteilung der Lenkwinkel erreicht werden. Grafik 4.5b zeigt die Verteilung nach der Anpassung.

Die Spiegelung sorgt automatisch dafür, dass Aufnahmen der rechten Fahrbahnseite zu Aufnahmen der Linken werden. Diese Erweiterung der Trainingsdaten auf beide Spuren wird aber nicht als Problem betrachtet, die Annahme ist, dass Fahrbahneigenschaften unabhängig der Fahrbahnseite gelernt werden können und das Training dadurch robuster wird. So entsteht ein Trainingsbilder-Set von gut 11.000 Bildern.

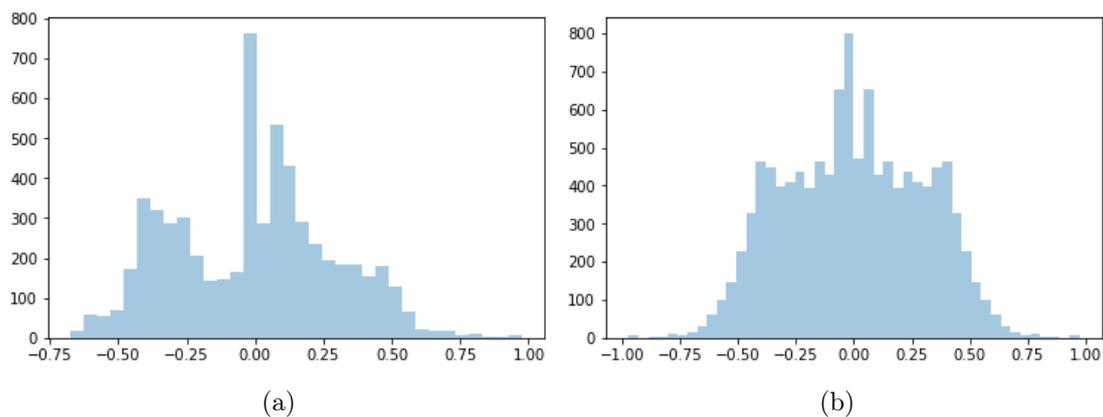


Abbildung 4.5: Lenkwinkelverteilung im Bildersetz

Weitere Methodiken der Data Augmentation, wie Bildverschiebung oder Bilddrehung, wurden nicht verwendet. In Versuchen konnte so keine Verbesserung erzielt werden.

Data Splitting Für die Verwendung im Trainingsprozess wird die Datenbasis mittels Data Splitting [12] [14] Trainingsdaten und Validierungsdaten aufgeteilt. Die hier verwendete Aufteilung ist im Verhältnis 4 zu 1. Damit entsteht ein Trainingsbildersset mit 8.800 Bildern und ein Validierungsbildersset mit 2.200 Bildern.

4.3.3 Real-Time-Processing

Processing Pipeline Mit den so vorbereiteten Daten wird im Weiteren eine Pipeline mit Bildoperationen eingerichtet. Die Daten-Label sind angepasst und Data Augmentation wurde durchgeführt. Die Processing Pipeline verarbeitet diese Daten und gibt den Output direkt an das neuronale Netz weiter. Die Bearbeitungsschritte der Pipeline erfolgen in Echtzeit, während die Daten geladen werden. Die Abbildung 4.6 macht die Struktur der Verarbeitung deutlich.

Als Input kommen entweder die ueye-Kamera auf dem Fahrzeug oder die Trainingsbasis in Frage. Sowohl für Trainings-, als auch für den Steuerungsmodus wird die Pipeline verwendet.

Skalierung Im einem ersten Schritt werden die Bilder skaliert und dann auf die Bildgröße 200x200 Bildpunkte zugeschnitten. Hier wurde speziell darauf geachtet, den Bildausschnitt mit dem größten Informationsgehalt zu erhalten, also möglichst viel der Fahrbahn im zugeschnittenen Bild zu sehen.

Histogrammausgleich Wie bereits angemerkt, sind die Trainingsbilder recht dunkel. Dem wird entgegengewirkt, es wird ein Histogrammausgleich für jedes Bild angewandt. Die Bilder werden heller.

Normalisierung Anschließend werden die Grauwerte auf den Wertebereich $[0, 1]$ normalisiert. Für die Berechnung in CNNs ein üblicher Schritt, die Produkte der Multiplikationen bleiben in einem kleinen Wertebereich und ermöglichen so ein effizienteres Training. Außerdem wird noch eine Umformung des Bildarrays von einem zweidimensionalen zu einem dreidimensionalen vorgenommen, dies ist im weiteren ebenfalls für die Verarbeitung im Netz von Bedeutung, auch wenn hier nur eine 1 für die eine Farbwertdimension angefügt wird.

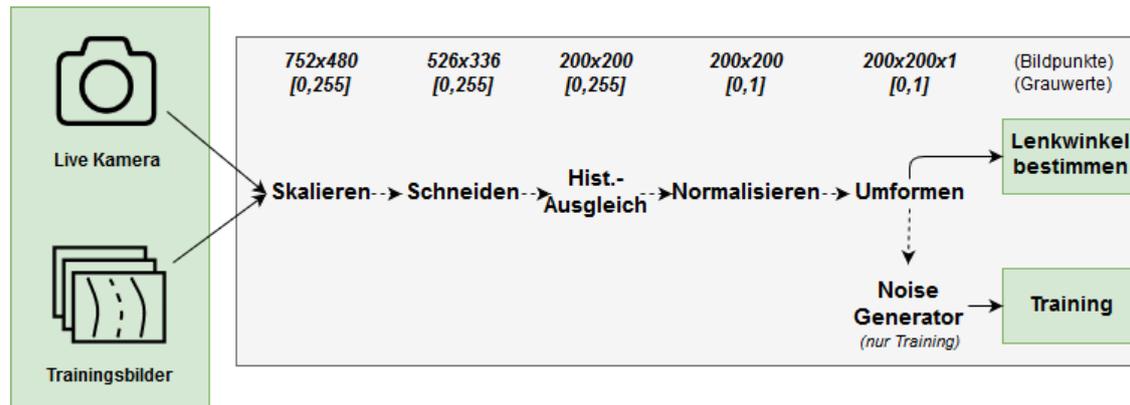


Abbildung 4.6: Bildverarbeitungsschritte

Varianzerhöhung Für das Training wird auf einem Teil der Bilder ein Filter angewendet, der das Bild optisch rauschen lässt, um das Lernen robuster zu machen. In 4.6 wird diese als Noise-Generator bezeichnet. Hierzu werden zufällige Werte aus einer Normalverteilung ($\mu = 0$) gezogen und auf die Pixelwerte addiert. Für positive Werte werden die Pixel somit heller, für negative dunkler. Das körnige unscharfe erscheinen des Bildes soll dazu dienen, die Varianz innerhalb des Datensatzes zu erhöhen.

Darstellung 4.7 zeigt Auszüge aus den Bearbeitungsschritten, nach dem Zuschneiden 4.7a, nach dem Histogrammausgleich 4.7b und nach Durchlaufen eines Rausch-Filters 4.7c.

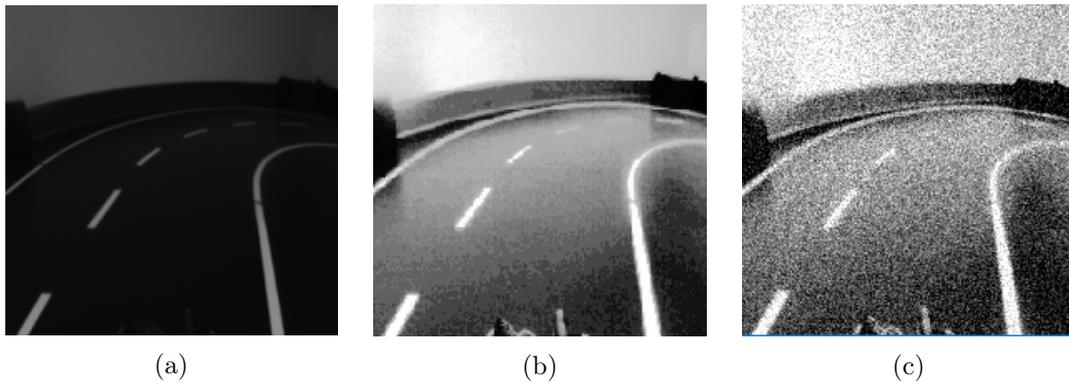


Abbildung 4.7: Beispiele verschiedener Bearbeitungsstufen, zugeschnitten (a), nach Histogrammausgleich (b) und nach Rausch-Filter (c)

4.4 Fine Tuning

4.4.1 Netzarchitektur

Das CNN DroNet, welches als Grundlage verwendet wird, ist bereits mit Bildern von Fahrbahnen aus dem regulären Straßenverkehr trainiert. Eigenschaften einer Fahrbahn sind also, so die Annahme, bereits in der Gewichtsverteilung der einzelnen Layer repräsentiert. Die für diese Arbeit interessante Strecke fällt natürlich auch in die Kategorie Fahrbahn, allerdings unterscheiden sich die Aufnahmen der Teststrecke von denen, einer echten Fahrbahn. Es ist keine Bebauung vorhanden, ebenso gibt es keine anderen Verkehrsteilnehmer und die Art der Straßenführung unterscheidet sich von realen Situationen.

Pre-Trained Statt die Gewichtsmatrizen des gesamten Netzwerkes anzupassen, wird nur ein Fine-Tuning des letzten Residual Blocks vorgenommen. Da mit DroNet ein Pre-Trained Netzwerk vorliegt, wird hier das Transfer-Learning [10] Verfahren verwendet. Die architektonische Aufteilung in diese Blöcke ermöglicht ein gutes Aufteilen des Netzes in einen Teil mit festgesetzten bzw. eingefrorenen Gewichten und den Teil, der trainiert wird.

Layer Freezing Abbildung 4.8 veranschaulicht diese Aufteilung. Der Teil des Netzes in roten Klammern wird vom Training ausgeschlossen, der grün eingeklammerte Block wird

trainiert. Die Annahme ist, dass die ersten beiden Blöcke bereits allgemeine Eigenschaften einer Fahrbahn erlernt haben, die gut auf neue Szenarien generalisieren. Der letzte Residual Block enthält knapp 70% der Parameter des gesamten Netzes. Die Annahme ist, dass hier die allgemeinen Eigenschaften zu einer komplexeren Repräsentation zusammenwachsen, die gut auf die Testfahrbahn generalisiert. Darüberhinaus soll vermieden werden, dass das recht kleine Bildersetz mit insgesamt 11.000 Bildern zu einer Überanpassung (Overfitting) führt. Das könnte auftreten, da die Aufnahmen auf Fahrsituationen der Teststrecke begrenzt sind, die keine große Heterogenität aufweisen. Nur einen Teil der Gewichte des Netzes zu verändern, erscheint auch in diesem Kontext sinnvoll.

Zusätzlich wird die Ausgabe des Netzes verändert. Die Kollisionswahrscheinlichkeit wird in dieser Arbeit nicht betrachtet. Die Trainingsdaten enthalten keine entsprechenden Label, daher wird das entsprechende Ausgabe-Layer entfernt. Das Feedback für die Berechnung der Gewichtsadjustierungen kommt nur vom Lenkwinkel.

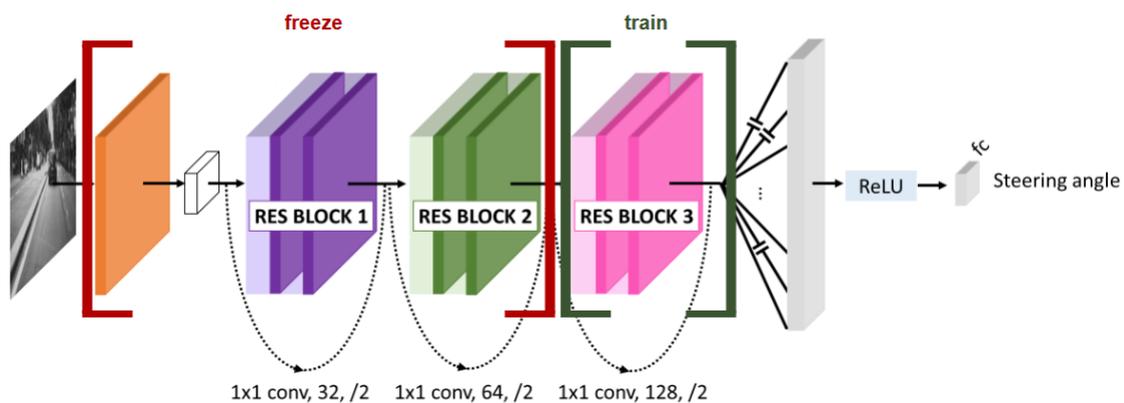


Abbildung 4.8: Angepasste Architektur

4.4.2 Trainingskonfiguration

Im Folgenden wird die Konfiguration für das Fine-Tuning vorgenommen und die Komponentenstruktur des Lernverfahrens erläutert.

Vor dem Fine-Tuning muss der Trainingsprozess konfiguriert werden, dafür werden vor dem Beginn die Hyperparameter festgelegt.

Hyperparameter Das Adam Optimierungsverfahren [6] wird als Optimierungsalgorithmus aus dem DroNet Training übernommen. Die Lernrate wird zu Beginn auf 0.0001 festgelegt mit einem Verfall (Decay) von 10×10^{-5} . Es werden 100 Trainingsepochen festgelegt und es wird in Gruppen (Batches) von jeweils 32 Bildern trainiert. Für das Training wird außerdem eine Shuffle-Funktion aktiviert, die Bilder werden so in einer zufälligen Reihenfolge trainiert.

Prozessstruktur Einen Überblick über das Lernverfahren zeigt Abbildung 4.9. Die Bilder durchlaufen im ersten Schritt die Preprocessing-Komponente, die Lenkwinkel werden ausgelesen und skaliert, wie bereits im Abschnitt zur Vorverarbeitung beschrieben. Das CNN generiert für ein Bild einen Lenkwinkel, welcher dann mit dem tatsächlichen (gewünschten) Lenkwinkel, der diesem Bild zugeordnet ist, verglichen wird. Der Unterschied zwischen den Lenkwerten, der Fehler, wird dem CNN als Feedback wieder zurückgegeben. Die Bestimmung des Fehlerwerts erfolgt immer für eine Batch, also eine Gruppe von 32 Bildern.

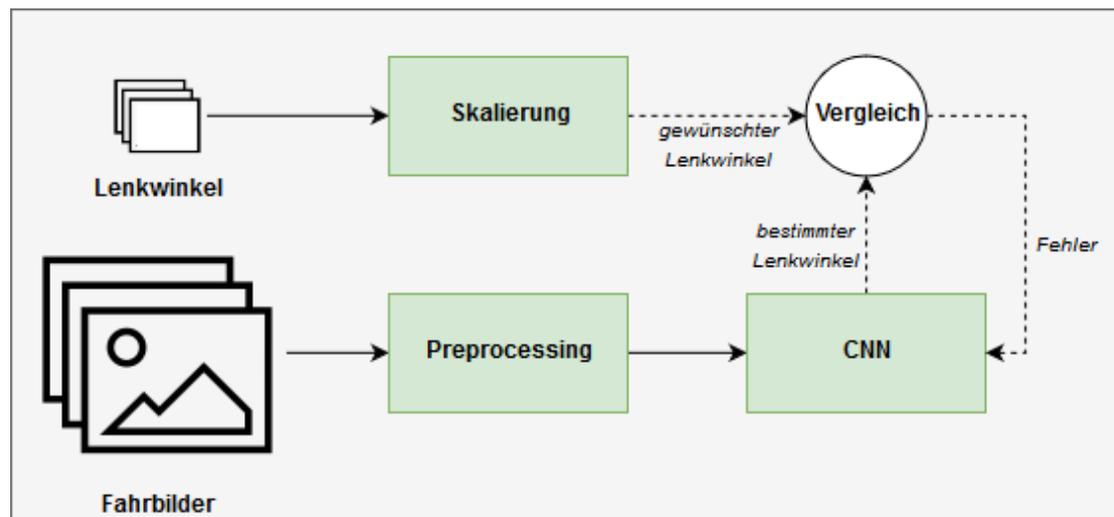


Abbildung 4.9: Struktur des Lernprozesses

4.5 Steuerung

Um aus der Hardware, also der Fahrzeugplattform und der Software, dem neuronalen Netz, eine Steuerungseinheit zu machen, müssen beide Teile verbunden werden. Hierbei ist besonders die Kommunikation wichtig, die Lenkdaten müssen von der erzeugenden Komponente (CNN) zur ausführenden Komponente (Hardwareabstraktion) übertragen werden. Die Steuerungsarchitektur ist in Abbildung 4.10 zu sehen.

Über eine Python Schnittstelle zur ueye-Kamera wird die Kamera konfiguriert und Bilddaten ausgelesen. Nach der bereits besprochenen Vorverarbeitung (Preprocessing) werden die Daten an das neuronale Netz weitergereicht.

Kommunikation Der hier bestimmte Lenkwinkel wird nun zur in C/C++ programmierten Steuerung weitergegeben. Dazu werden Unix Domain Sockets (UDS) verwendet. Die Kommunikation erfolgt statt über eine IP-Adresse über einen File Deskriptor im Unix Betriebssystem. Ein Stream-Protokoll, entspricht dem Internet Protokoll TCP, nutzt den File-Deskriptor als Kommunikationsendpunkt für die Interprozesskommunikation. Der UDS-Client auf der Python-Seite schickt die Lenkdaten an einen UDS-Server auf der C/C++ Seite. Dabei werden die Daten als UTF-8 kodierte Bytestreams verschickt. Die so erhaltenen Daten werden vom UDS-Server entpackt. Es erfolgt keine zeitliche Kontrolle auf Zugehörigkeit einzelner Lenkdaten zu Kamerabildern. Die Steuerung soll möglichst hohen Durchsatz haben um möglichst viele Frames in einer Sekunde zur Lenkwinkelermittlung nutzen zu können, daher werden immer die aktuellsten erhaltenen Lenkdaten genutzt. Wird ein Datum nicht übertragen, ist es aufgrund der dynamischen Fahrsituation ohnehin schon weniger als eine Sekunde später nicht mehr als Lenkinformation verwendbar.

Hardwareansteuerung Für die direkte Ansteuerung des Lenkungsservos wird der erhaltene Wert auf zwei Nachkommastellen gekürzt. Die Kodierung der Lenkwinkel in der Fahrzeughardware ist entgegengesetzt zu der trainierten Kodierung. Die Kodierung der Lenkwinkel wird daher von $[1, -1]$ zu $[-1, 1]$ umgerechnet und dann direkt an die Hardware weitergegeben. Die Geschwindigkeit des Fahrzeugs wird zu Beginn einer Fahrt auf einen konstanten Wert gesetzt.

Die so gebaute Steuerungskomponente kann zum Fahren des Fahrzeuges verwendet werden. Die Komponenten werden über eine ssh-Verbindung gestartet, die Kontrolle für den

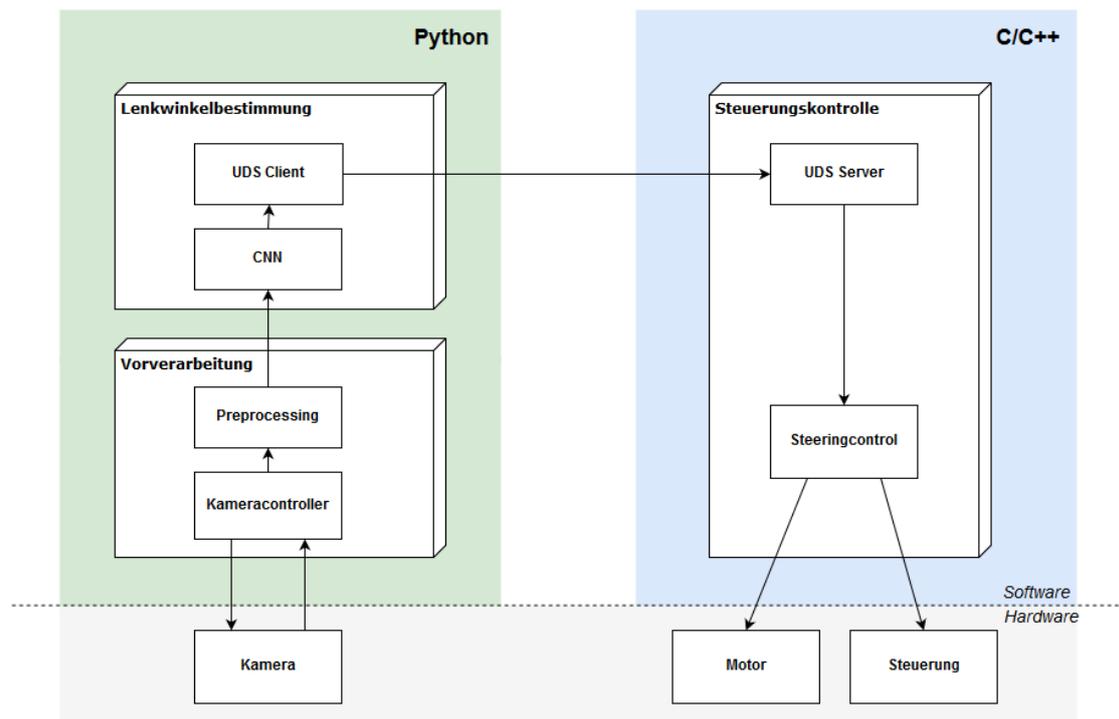


Abbildung 4.10: Komponentenstruktur und Verbindung der Neuronalen Steuerung

autonomen Modus wird dem Fahrzeug über die Funkfernbedienung übergeben. So ist auch ein Eingriff per Hand möglich.

Die Qualität der Steuerung und das Fahrverhalten ist im Weiteren Gegenstand einer Analyse, in der auch aufgezeigt wird, welche Fahrbahn-Eigenschaften das neuronale Netz interpretiert.

5 Auswertung und Szenarien

In diesem Kapitel wird der Trainingsprozess analysiert und kritisch bewertet, zudem wird das entworfene neuronale Steuerungssystem einem Test unterzogen. Verschiedene Fahrscenarien werden untersucht, zum Schluss bietet eine grafische Auswertung einen Einblick in die Perspektive aus Sicht des neuronalen Netzes.

5.1 Training

Das Fine-Tuning wurde mit den im vorangegangenen Kapitel festgelegten Konfigurationen durchgeführt. In diesem Abschnitt erfolgt eine Betrachtung des erfolgten Trainings. In Abbildung 5.1 sind Trainingsfehler und Validierungsfehler (y-Achse) über 100 Epochen (x-Achse) dargestellt.

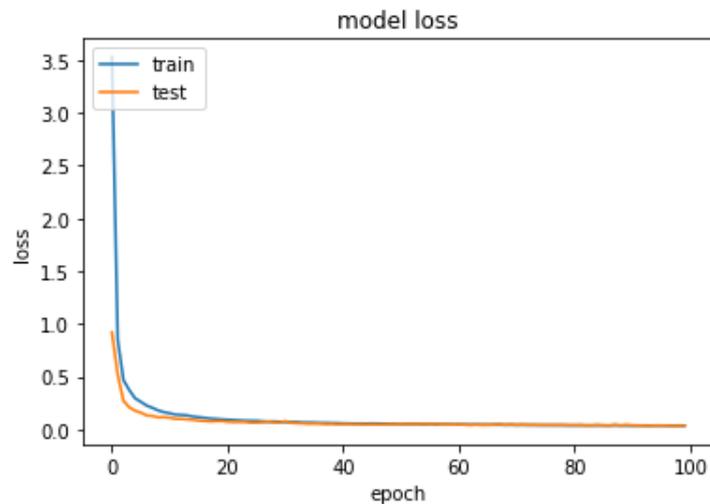


Abbildung 5.1: Trainingsfehler (train) und Validierungsfehler (val) über 100 Epochen

Festzustellen ist, dass beide Fehlerwerte sich zunächst stark fallend 0.0 annähern und zwischen den Epochen 20 – 25 und 100 gleichbleibend 0.0 zu bleiben scheinen. Aufgrund des Start-Trainingsfehles von etwa 3.5 sind kleine Werte nur schlecht grafisch zu beurteilen. Ein direkter Blick auf die zugrundeliegenden Fehlerwerte zeigt, dass beide sich im Bereich 10×10^{-2} weiter 0.0 annähern, mit dem kleinsten Validierungsfehler von 0.0344 in Epoche 197. Es besteht keine ausgeprägte Divergenz zwischen Trainings- und Validierungsfehler, das ist positiv zu beurteilen.

Bei kritischer Betrachtung muss angemerkt werden, dass die Regressionkurve, im konkreten Fall die Annäherung des Lenkwinkels, sehr rapide fällt. Das kann Zeichen eines Overfittings sein. Die Bilder der Teststrecke könnten in der Menge zu homogen sein, die Teststrecke ist im Angesicht der dort aufgenommenen Bildermenge relativ kurz, viele Bilder sind optisch ähnlich, mit nur kleinen Lenkwertunterschieden. Aufgrund der räumlichen Abgeschlossenheit der Teststrecke gibt es dazu wenig Varianz im Bildhintergrund, das könnte die Gleichartigkeit der Bilder verstärken.

Allerdings ist die schnelle Konvergenz nicht zwingend negativ anzumerken, das neuronale Netz war Pre-Trained. Es war mit einer verwandten Aufgabe auf einer ähnlichen Bildermenge trainiert worden. Dazu kommt, dass nur ein Teil der Layer überhaupt für das Training, also eine Veränderung der Gewichte, freigegeben war. Im Angesicht dieser Umstände können die Fehlerkurven in Abbildung 5.1 auch für eine schnelle, effiziente Anpassung der Gewichte des letzten Residual-Blocks stehen.

Wie das CNN als Steuerungslogik in realen Streckenszenarien abschneidet, wird in den nächsten Abschnitten untersucht.

5.2 Testfahrt

Um die Lenkwinkelbestimmung des Netzes zu Testen, wird zunächst frei auf der Strecke gefahren. Das Fahrzeug startet auf einer Geraden und fährt den Kurs überwiegend Fehlerfrei ab. Der Onboard-Rechner (NUC) des Fahrzeugs verarbeitet die Bilder mit $20fps$, getestet wird bis zu einer Geschwindigkeit von 1.2 m/s , ab da nimmt die Lenkfehlerhäufigkeit stark zu. Ein Lenkwinkelupdate ($\hat{=}$ 1 verarbeiteter Frame) pro gefahrene 6 cm ist die Obergrenze.

Metrik Die Fahrleistung auf der Strecke soll gemessen werden, um Sie direkt mit anderen Algorithmen vergleichen zu können. Dazu wird eine Autonomie-Metrik [1] bestimmt. Der Autonomiewert wird definiert als

$$\left(1 - \frac{\text{Anzahl Fehler} \cdot 2s}{\text{Fahrzeit in Sekunden}}\right) \cdot 100, \quad (5.1)$$

wobei die Anzahl der Fehler die Summe der Situationen ist, in der das Fahrzeug die Außen- oder Mittellinie mit mehr als zwei Reifen überquert hat. Das Fahrzeug kann sich danach selbst wieder auf die Strecke bringen, oder per Hand zurückgelenkt werden. Die Zeit, die vergeht, bis das Fahrzeug wieder sauber auf die Straße zurückgekehrt ist, wird mit 2 Sekunden angenommen. Die Fahrzeit in Sekunden beschreibt die Dauer des Versuchs.

Für den Test werden zwei Runden auf der Teststrecke gefahren, einmal im Uhrzeigersinn und einmal gegen den Uhrzeigersinn, beide Runden auf der jeweils Rechten Straßenseite. Als Geschwindigkeit wird $\frac{1}{2}$ m/s festgelegt. In jede Richtung der Strecke wird 60 Sekunden gefahren, das entspricht je einer Runde. Die Gesamtfahrzeit pro Test ist damit 120 Sekunden.

Verglichen wird das unveränderte DroNet, die nachtrainierte Variante dieser Arbeit, bezeichnet als BA-RR, und der Steuerungsalgorithmus, der von der diesjährigen Carolo-Cup-Projektgruppe entwickelt wurde. Der Steuerungsalgorithmus der Projektgruppe basiert auf klassischer Linienerkennung mit Bildverarbeitung. Die erste Runde ist im, die zweite gegen den Uhrzeigersinn. Die Testfahrten ergaben die in Tabelle 5.1 gesammelten Daten.

Tabelle 5.1: Algorithmen im Vergleich

Algorithmus	Fehler Runde 1	Fehler Runde 2
DroNet	16	12
Carolo-Projekt	7	11
BA-RR	3	5

Der Autonomiewert wird nach der Formel berechnet und liefert die in Tabelle 5.2 vermerkten Werte. Der Autonomiewert ist eine Prozentangabe und ist auf ganze Zahlen gerundet.

Der ursprüngliche DroNet Algorithmus ist nur 53% der Fahrzeit autonom unterwegs, was nicht überrascht, da er in einem anderen Anwendungsszenario entstand. Der Algorithmus

Tabelle 5.2: Vergleich der Autonomie

Algorithmus	Autonomiewert
DroNet	53 %
Carolo-Projekt	70 %
BA-RR	87 %

des aktuellen Carolo-Projektteams ist deutlich besser, hat allerdings auch viele Fahrfehler gemacht. Die in dieser Arbeit entwickelte Steuerung (BA-RR) ist 87% der Fahrzeit autonom unterwegs, hier zeigt sich die deutliche Verbesserung, die insbesondere im Gegensatz zum DroNet Algorithmus erreicht wurde. Außerdem wird deutlich, dass eine Steuerung mittels statistischer Auswertung von Bilddaten (CNN) nicht nur möglich ist, sondern einer Steuerung mittels klassischer Linienerkennung in diesem Fall sogar überlegen ist.

Im Folgenden wird das Verhalten des Fahrzeugs in speziellen Szenarien untersucht.

5.3 Einzelszenarien

Fahrbahn wiederfinden Im Hinblick auf die Eingangs angesprochene mögliche Overfitting-Problematik, wird hier eine praktische Herangehensweise an die Analyse gemacht. Im Trainingsbildersset sind keine Bilder enthalten, in denen das Fahrzeug aus einer Fehler-situation wieder auf die Straße navigiert. Genauer gesagt, in denen das Fahrzeug nicht oder nur teilweise auf der Strecke steht und den Weg in die richtige Fahrspur selbst findet. Somit konnten diese Szenarien beim Training auch nicht „auswendig“ gelernt werden. Diese Fehlersituationen werden jetzt künstlich erzeugt und das Fahrverhalten betrachtet. Abbildung 5.2 zeigt beispielhaft zwei solche Szenarien, einmal steht das Fahrzeug teilweise auf der Straße (5.2a), im anderen Beispiel steht es komplett außerhalb der Fahrbahn (5.2b).

Es wurden jeweils 10 verschiedene Szenarien mit dem Fahrzeug teilweise auf der Fahrbahn und 10 mit dem Fahrzeug außerhalb der Fahrbahn, jedoch mit Kamerasicht auf zumindest einen Teil der Fahrbahn, getestet. In 10/10 Szenarien findet das Fahrzeug den Weg auf die Fahrspur, wenn es teilweise darauf steht. In 9/10 Fällen findet es die Fahrspur, wenn es vollständig außerhalb der Fahrbahn steht.

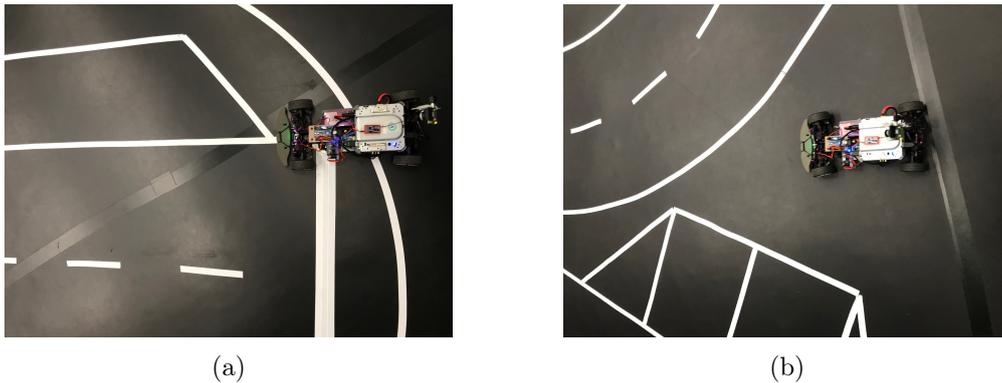


Abbildung 5.2: Fehlerszenarien

Aus diesem Versuch lässt sich die Vermutung ableiten, dass die Orientierung an Fahrbahneigenschaften nicht nur in den trainierten Fällen funktioniert. Die Fahrspur wird auch aus vorher nicht gesehenen Blickwinkeln gefunden.

Kreuzung Da die Teststrecke nur eine Kreuzung hat, sind in den Trainingsdaten nur wenige Bilder von Kreuzungsszenarien, wie dem in Abbildung 5.3 gezeigten, vorhanden. Das Verhalten in diesen speziellen Situationen, in denen ein Teil der Fahrbahnmarkierung fehlt, ist besonders interessant.



Abbildung 5.3: Kreuzungsszenario aus Sicht der Fahrzeugkamera

Tatsächlich erweisen sich die Kreuzungssituationen als größte Fehlerquelle. Wird die Kreuzung gerade angefahren, wird sie in 9/10 Versuchen sauber überquert. Ist das Fahrzeug allerdings nicht mittig auf der Fahrbahn, sondern fährt die Kreuzung in einem leicht veränderten Winkel an, wird sie nur noch in 5/10 Versuchen sauber durchfahren. In 50%

der Testfälle mit leicht verändertem Blickwinkel verlässt das Fahrzeug die Fahrspur und wechselt die Spur.

Fehlt die Seitenlinie zur Orientierung, erschwert das die Lenkwinkelbestimmung. Durch eine leicht schräge Anfahrt der Kreuzung (zum Beispiel nach einer nicht ganz sauber durchfahrenen Kurve) gerät schnell die andere Fahrbahn in den Blickwinkel, welche dann zur Orientierung verwendet wird. Das Fahrzeug wechselt die Fahrspur.

5.4 Visualisierung

Saliency Gerade vor dem Hintergrund der Analyse des Netzes ist es interessant zu wissen, welche Bereiche des Bildes für die Bestimmung des Lenkwinkels tatsächlich von Bedeutung sind. Als Mensch kennt man das Konzept einer Fahrbahnmarkierung und der daraus entstehenden Fahrspur sehr genau. Man könnte davon ausgehen, dass für ein neuronales Netz diese Bereiche eines Bildes deswegen auch besonders interessant sind, um die Fahrtrichtung zu bestimmen.

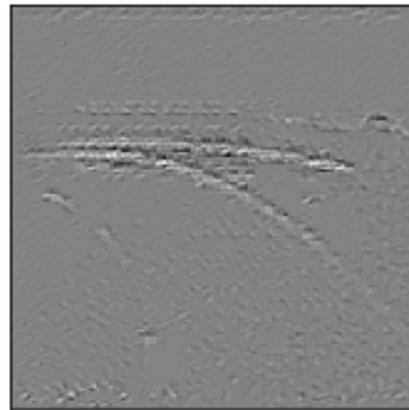
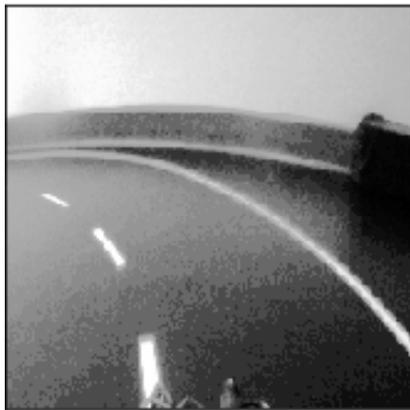
Auch in Bezug auf die in vorangegangenem Kapitel besprochenen Problematiken liegt ein gesteigertes Interesse vor, die wichtigen Bereiche der Fahrbahnbilder ausfindig zu machen.

Für die Visualisierung werden Saliency-Maps [15] verwendet. Die Idee ist, jene Bildpunkte zu identifizieren, welche für die größten Veränderungen im Output sorgen. Für diese Arbeit bedeutet das, genau die Bildpunkte visuell hervorzuheben, welche für eine große Veränderung im Lenkwinkeloutput sorgen. Dafür wird die Veränderung des Outputs in Bezug auf das Eingabebild berechnet, also das Verhältnis einer Änderung im Output zu einer Änderung im Input: $\frac{\partial \text{Output}}{\partial \text{Input}}$. Für diese Analyse wird Keras-vis [20] genutzt, eine Visualisierungs-API für Keras.

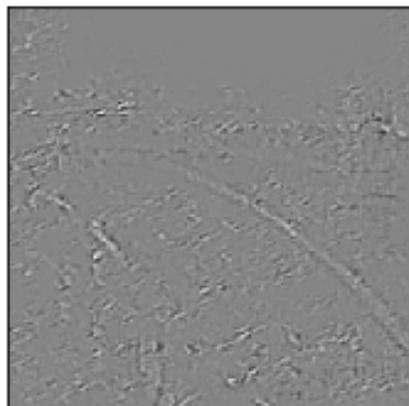
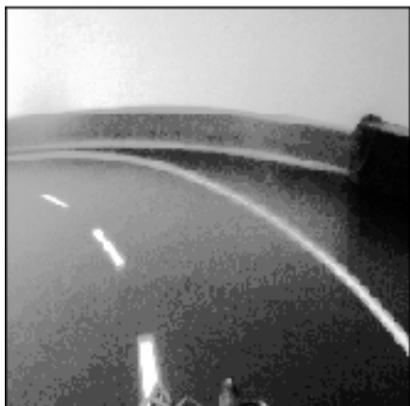
Lernprozess Um die Repräsentation der Bildeigenschaften im Netz deutlich zu machen, wird eine Saliency Map für jeden der drei Residual-Blöcke bestimmt. So lässt sich nachvollziehen, wie sich die ausschlaggebenden Bildbereiche auf dem Weg durch das Netz verändern. In Abbildung 5.4 sind diese drei Saliency Maps für ein Beispielbild einer Linkskurve dargestellt.

Die hellen Bildbereiche sind eben die, die für eine Erhöhung des Outputs sorgen, also für einen positiv höheren Lenkwinkel. Zur Erinnerung, ein positiver Lenkwinkel codiert eine Linkskurve. Die Saliency-Map wurde für die jeweils letzte Convolutional-Layer des Blocks berechnet.

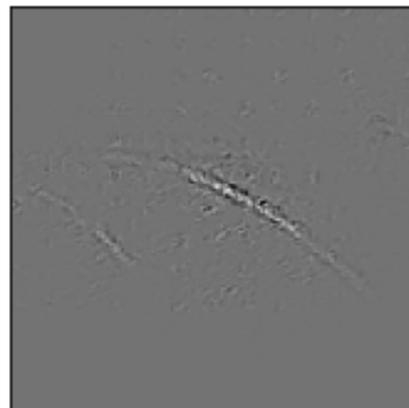
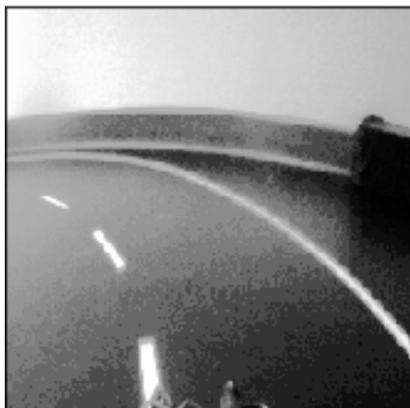
Zu sehen ist jeweils das Bild der Fahrbahn nach einem Histogrammausgleich, rechts daneben die berechnete Saliency-Map. Nach dem ersten Residual Block 5.4a scheint die Aufmerksamkeit insbesondere auf linienartigen Bereichen zu liegen, gut zu sehen an der hellen Hervorhebung der Bildpunkte. Neben der Fahrbahnbegrenzung spielt auch ein Teil der Wandlinien eine Rolle für die Bestimmung der Linkslenkung. In 5.4b, nach der letzten Convolutional-Layer des zweiten Residual-Blocks, zeigt sich eine Veränderung. Die Ausprägung der Linienstrukturen in der Saliency-Map beschränkt sich auf die Fahrbahnmarkierung, die unterbrochene Mittellinie tritt etwas deutlicher hervor. Insgesamt wirkt die Verteilung der prägnanten Bildbereiche zufälliger, fast wie ein Rauschen. Nach dem dritten und letzten Residual-Block 5.4c liegt der Aufmerksamkeitsfokus auf einem Stück der Außenlinie. Die Bildpunkte die hier liegen, sind die Entscheidenden für die Linkslenkung (Lenkwinkel $[0, 1]$). Hier muss Berücksichtigt werden, dass nur der letzte Residual-Block von Anpassungen der Filter betroffen war. Die starke Konzentration auf den Abschnitt der Außenlinie ist darauf zurückzuführen.



(a) Residual-Block 1



(b) Residual Block 2



(c) Residual Block 3

Abbildung 5.4: Ausschlaggebende Bildbereiche

6 Resümee

Zielsetzung Das Ziel dieser Arbeit war, eine bildbasierte neuronale Steuerung für ein RC-Fahrzeug zu entwickeln, was gelungen ist. Durch Fine-Tuning eines bereits trainierten Convolutional Neural Network (DroNet) entstand eine geeignete Steuerung. Zur Beurteilung der Qualität der Steuerung wurden Fahrten auf einer Teststrecke durchgeführt. Fahrten auf einer größeren Strecke konnten mangels Verfügbarkeit noch nicht durchgeführt werden. Zukünftige Testfahrten könnten unter Umständen auf der Teststrecke der TU Braunschweig durchgeführt werden, die ganzjährig aufgebaut ist.

Analyse Im Performance-Vergleich auf Testfahrten schneidet das CNN gut ab. Die Teststrecke kann nicht nur fast fehlerfrei durchfahren werden, im direkten Vergleich mit dem Steuerungsalgorithmus des Carolo-Cup Teams des WS18/19 liegt die hier entwickelte neuronale Steuerung vorn. Ein zusätzlicher Vergleich mit dem Ursprungsnetz DroNet zeigt, dass das Fine Tuning die Lenkwinkelbestimmung entscheidend verbessert hat. Einschränkend muss hier angemerkt werden, dass das Fine Tuning eine Anpassung auf einen eingeschränkten, störungsarmen Testbereich gemacht hat.

Zusätzlich wird eine grafische Analyse vorgenommen. Die Salient-Objects, also die für die Bestimmung des Lenkwinkels maßgeblichen Teile des Bilds wurden hervorgehoben. So ließ sich zeigen, dass bei dem CNN was einem Fine-Tuning unterzogen wurde, besonders die Fahrbahnmarkierungen ausschlaggebend waren, was der intuitiven Erwartung entspricht. Zusätzlich wurde das Verhalten der entworfenen Steuerung in neuen, nicht trainierten Szenarien betrachtet. In diesen Fehlerszenarien wurde getestet, ob das Fahrzeug die Fahrbahn findet, wenn es entweder nur teilweise oder gar nicht auf der Fahrbahn startet. Es konnte gezeigt werden, dass die Steuerung in nahezu allen Situationen auf die Fahrbahn navigiert und die Fahrspur sauber findet.

Technische Kritik Einschränkung muss erwähnt werden, dass sich einige Fahrsituationen als problematisch erwiesen. Dazu gehören Kreuzungen und Situationen, in denen durch den Kamerawinkel Teile der Fahrmarkierung nicht sichtbar sind. Außerdem ist die Framerate der Bildverarbeitung durch das Netz ein begrenzender Faktor, bei Geschwindigkeiten über 1.2 m/s nimmt die Anzahl der Fahrfehler stark zu.

Ergänzend kommt hinzu, dass das Generieren eines qualitativ hochwertigen Trainingsdatensatzes durch geringe Länge und Variabilität der Teststrecke erschwert wurde. Die aufgenommenen Bilder enthielten saubere Fahrsituationen, die zwar die Fahrt auf einer Modellstrecke ermöglichen konnten, auf einer Strecke mit fehlender Fahrbahnmarkierung oder ungewöhnlicher Fahrbahnführung zu Problemen aber führen könnten. Eine Untersuchung hierzu könnte auf einer größeren Teststrecke stattfinden, in der auch Straßensituationen wie zum Beispiel Kreuzungen verschieden modelliert werden können.

Kritik der Idee Im Rückblick muss auch die Idee im Grundsatz einer kritischen Betrachtung unterzogen werden. Zwar navigiert das Fahrzeug sicher durch den Testkurs, die ursprüngliche Idee entstand jedoch in Anlehnung an die Carolo-Cup Projektarbeit. Das sichere Navigieren ist nur die Grundlage in diesem Wettbewerb, darauf bauen eine Reihe weiterer Aufgaben, wie zum Beispiel Ein- und Ausparken, Hindernissen ausweichen und Zebrastreifen erkennen auf. Diese Aufgabenstellungen können durch die hier entwickelte neuronale Steuerung nicht abgedeckt. Die Lösung all dieser Aufgaben mit einem einzigen neuronalen Netz wäre aufgrund der Komplexität der einzelnen Aufgabenbereiche kaum möglich. Zudem bieten sich für einige dieser Aufgaben effizientere Lösungen als neuronale Netze.

Ausblick Dennoch könnte für aufbauende Versuche interessant sein, Hindernisse oder andere Verkehrsteilnehmer in das Training mit einzubauen. Hier stellt sich dann allerdings die Frage, wie diese Situationen in der Modellgröße modelliert werden können und wie die benötigten Daten einer sauberen Fahrt durch diese Szenarien generiert werden. Außerdem wäre eine Anpassung im Netzwerkoutput ein spannender Ansatz. Ein zusätzlicher Output für die gefahrene Geschwindigkeit könnte bedeutenden Einfluss auf das Fahrverhalten haben. Ein Abbremsen in engen Kurven und Beschleunigen auf Geraden könnte erwartet werden.

Zusammenfassend kann also festgestellt werden, dass das Steuern durch eine markierte Fahrbahn mit einem neuronalen Netz möglich ist, dazu aber Einschränkungen bei der

Aufgabenstellung gemacht werden müssen. Das Fahren auf einer Fahrbahn, auch im Modellbereich, ist komplex und in seiner Gesamtheit (noch) nicht durch neuronale Netze abzudecken, dazu ist die Menge der Erscheinungsbilder einer Fahrbahn oder Straße zu groß. Die Einflussfaktoren auf das Verhalten eines Fahrzeuges sind zahlreich, insbesondere im realen Straßenverkehr. Das Ableiten des Lenkverhaltens nur aus der Fahrbahnmarkierung funktioniert für ein eingeschränktes Testszenario allerdings gut.

Die Entwicklung autonomer Fahrzeuge ist weltweit in vollem Gang, wie sich die Rolle neuronaler Netze in diesem Zusammenhang entwickelt kann mit Spannung beobachtet werden. Vielleicht kann mit zukünftigen Modellen eine rein neuronale Steuerung im Straßenverkehr gelingen.

Literaturverzeichnis

- [1] BOJARSKI, Mariusz ; DEL TESTA, Davide ; DWORAKOWSKI, Daniel ; FIRNER, Bernhard ; FLEPP, Beat ; GOYAL, Prason ; JACKEL, Lawrence D. ; MONFORT, Mathew ; MULLER, Urs ; ZHANG, Jiakai u. a.: End to end learning for self-driving cars. In: *arXiv preprint arXiv:1604.07316* (2016)
- [2] CHOLLET, F.: *Deep Learning mit Python und Keras: Das Praxis-Handbuch vom Entwickler der Keras-Bibliothek*. mitp-Verlag, 2018 (mitp Professional). – URL <https://books.google.de/books?id=ouVcDwAAQBAJ>. – ISBN 9783958458406
- [3] DYK, David A. van ; MENG, Xiao-Li: The Art of Data Augmentation. In: *Journal of Computational and Graphical Statistics* 10 (2001), Nr. 1, S. 1–50. – URL <https://doi.org/10.1198/10618600152418584>
- [4] GOODFELLOW, Ian ; BENGIO, Yoshua ; COURVILLE, Aaron: *Deep Learning*. MIT Press, 2016. – <http://www.deeplearningbook.org>
- [5] HE, Kaiming ; ZHANG, Xiangyu ; REN, Shaoqing ; SUN, Jian: Deep Residual Learning for Image Recognition. In: *CoRR* abs/1512.03385 (2015). – URL <http://arxiv.org/abs/1512.03385>
- [6] KINGMA, Diederik P. ; BA, Jimmy: Adam: A method for stochastic optimization. In: *arXiv preprint arXiv:1412.6980* (2014)
- [7] KRIZHEVSKY, Alex ; SUTSKEVER, Ilya ; HINTON, Geoffrey E.: Imagenet classification with deep convolutional neural networks. In: *Advances in neural information processing systems*, 2012, S. 1097–1105
- [8] LIU, Tantan ; WANG, Fan ; AGRAWAL, Gagan: Stratified sampling for data mining on the deep web. In: *Frontiers of Computer Science* 6 (2012), Nr. 2, S. 179–196
- [9] LOQUERCIO, Antonio ; MAQUEDA, Ana I. ; BLANCO, Carlos R. D. ; SCARAMUZZA, Davide: Dronet: Learning to Fly by Driving. In: *IEEE Robotics and Automation Letters* (2018)

- [10] PAN, Sinno J. ; YANG, Qiang: A survey on transfer learning. In: *IEEE Transactions on knowledge and data engineering* 22 (2010), Nr. 10, S. 1345–1359
- [11] PEREZ, Luis ; WANG, Jason: The effectiveness of data augmentation in image classification using deep learning. In: *arXiv preprint arXiv:1712.04621* (2017)
- [12] PICARD, Richard R. ; BERK, Kenneth N.: Data splitting. In: *The American Statistician* 44 (1990), Nr. 2, S. 140–147
- [13] POMERLEAU, Dean A.: Alvin: An autonomous land vehicle in a neural network. In: *Advances in neural information processing systems*, 1989, S. 305–313
- [14] REITERMANOVA, Z: Data splitting. In: *WDS* Bd. 10, 2010, S. 31–36
- [15] SIMONYAN, Karen ; VEDALDI, Andrea ; ZISSERMAN, Andrew: Deep inside convolutional networks: Visualising image classification models and saliency maps. In: *arXiv preprint arXiv:1312.6034* (2013)
- [16] WALTER, W G.: An imitation of life. In: *Scientific American* 182 (1950), Nr. 5, S. 42–45

Internetquellen

- [I17] *Net-Scale Technologies Inc. Autonomous off-road vehicle control using end-to-end learning, July 2004.* <http://net-scale.com/doc/net-scale-dave-report.pdf>. – Accessed: 2019-03-08
- [I18] *NVIDIA Komponenten des Steuerungssystem.* <https://devblogs.nvidia.com/wp-content/uploads/2016/08/training-624x291.png>. – Accessed: 2019-03-08
- [I19] *Residual Block Schematischer Aufbau.* https://cdn-images-1.medium.com/max/1600/1*D0F3UitQ2l5Q0Ak-tjEdJg.png. – Accessed: 2019-03-10
- [I20] KOTIKALAPUDI, Raghavendra ; CONTRIBUTORS: *keras-vis*. <https://github.com/raghakot/keras-vis>. 2017

Glossar

Adam Ein Optimierungsalgorithmus für stochastische Gradientenverfahren.

ALVINN Bezeichnung für ein neuronales Netz der Carnegie Mellon Universität.

Anaconda Open Source Python Distribution für wissenschaftliches Programmieren.

Carolo-Cup Studentischer Wettbewerb der TU Braunschweig, Modellfahrzeuge treten in Disziplinen autonom gegeneinander an.

CNN Convolutional Neural Network, ein neuronales Netz mit Faltungsoperationen.

DroNet Bezeichnung für ein neuronales Netz, entwickelt von einer Arbeitsgruppe der ETH Zürich.

ETH Zürich Eidgenössische Technische Hochschule Zürich.

HAW Hamburg Die HAW Hamburg ist die ehemalige Fachhochschule am Berliner Tor.

IDS Hersteller von Industriekameras.

Intel NUC Kleiner Barebone-Computer entwickelt von der Firma Intel.

NAVLAB Eine Serie autonomer und semi-autonomer Fahrzeuge der Robotik-Gruppe der Carnegie Mellon Universität.

OpenCV OpenCV ist eine Bibliothek, die Funktionen für Bilderverarbeitung und Maschinelles Sehen anbietet.

PyCharm IDE speziell für Python.

Udacity Private Online-Bildungsorganisation gegründet von Sebastian Thrun.

UDS Socket Kommunikation mit File-Deskriptoren.

VSCoDe Code Editor für Windows, Linux und macOS.

Erklärung zur selbstständigen Bearbeitung einer Abschlussarbeit

Gemäß der Allgemeinen Prüfungs- und Studienordnung ist zusammen mit der Abschlussarbeit eine schriftliche Erklärung abzugeben, in der der Studierende bestätigt, dass die Abschlussarbeit „– bei einer Gruppenarbeit die entsprechend gekennzeichneten Teile der Arbeit [(§ 18 Abs. 1 APSO-TI-BM bzw. § 21 Abs. 1 APSO-INGI)] – ohne fremde Hilfe selbständig verfasst und nur die angegebenen Quellen und Hilfsmittel benutzt wurden. Wörtlich oder dem Sinn nach aus anderen Werken entnommene Stellen sind unter Angabe der Quellen kenntlich zu machen.“

Quelle: § 16 Abs. 5 APSO-TI-BM bzw. § 15 Abs. 6 APSO-INGI

Erklärung zur selbstständigen Bearbeitung der Arbeit

Hiermit versichere ich,

Name: _____

Vorname: _____

dass ich die vorliegende Bachelorarbeit – bzw. bei einer Gruppenarbeit die entsprechend gekennzeichneten Teile der Arbeit – mit dem Thema:

Bildbasierte Navigation mit Neuronalen Netzen

ohne fremde Hilfe selbständig verfasst und nur die angegebenen Quellen und Hilfsmittel benutzt habe. Wörtlich oder dem Sinn nach aus anderen Werken entnommene Stellen sind unter Angabe der Quellen kenntlich gemacht.

Ort Datum Unterschrift im Original