

Bachelorarbeit

Video-basierte Erkennung von Fahrspurmarkierungen auf mobilen Robotern

Jan Wille 1535115

09.05.2022 – 07.09.2022

Erstprüfer: Prof. Dr.-Ing. Hanno Homann
Zweitprüfer: Prof. Dr.-Ing. Martin Mutz

Selbstständigkeitserklärung

Hiermit bestätige ich, dass die folgende Arbeit eigenständig von mir allein erstellt und unter Berücksichtigung der zur Verfügung gestellten Aufgabenstellung sowie dem Arbeitsmaterial unter Angabe aller verwendeten Quellen erarbeitet wurde. Die Regelungen und Konsequenzen eines Plagiats, inklusive disziplinarischer Maßnahmen, sind mir bewusst. Insbesondere wurden alle Zitate und gedanklichen Übernahmen als solche kenntlich gemacht.

Jan Wille

Abstract

kommt als letztes

Inhaltsverzeichnis

Abstract	IV
Inhaltsverzeichnis	V
Glossar	VII
1 Einleitung	1
1.1 Problemstellung	1
1.2 Aufgabenstellung	1
1.3 Inhalt der Arbeit	1
2 Stand der Technik	2
2.1 Techniken zur Fahrspurerkennung	2
2.1.1 Geometrische und algorithmische Ansätze	2
2.1.2 Deep Learning Ansätze	3
2.2 OpenCV	3
2.3 Das Robot Operating System	4
2.4 Der JetBot Roboter	4
2.4.1 Performance Baseline	5
3 Kamera Kalibrierung	6
3.1 Intrinsische Kalibrierung	6
3.1.1 Radiale Verzerrung	6
3.1.2 Tangentiale Verzerrung	7
3.2 Durchführung der intrinsischen Kalibrierung	8
3.2.1 Python Script zur Durchführung der Kalibrierung	8
3.2.2 Anwenden der Kalibrierung in einer ROS Node	11
4 Fahrspurerkennung	15
4.1 Konzeptionierung in Python	15
4.1.1 Kantenerkennung mittels Canny-Edge-Detektor	17
4.1.2 Klassifizierung der Kantenpixel	18
4.1.3 Linienbildung	21
4.2 Implementierung in eine ROS Node	23
4.2.1 Performance Betrachtung	27
5 Fazit	29
6 Ausblick	30
Literatur	31
Abbildungsverzeichnis	33
Tabellenverzeichnis	34

Codeverzeichniss

35

Glossar

C++

Eine relativ hardwarenahe Programmiersprache

Callback-Funktion

Eine Funktion die unter bestimmten Bedingungen automatisch aufgerufen wird. Im Bezug aus ROS geht es meistens um Funktion die für jede Nachricht auf einem abonierten Topic mit deren Inhalt aufgerufen werden.

Canny-Edge-Detektor

Ein Algorithmus zur Erkennung von Kanten in Bildern.

Gaussscher Filter

Eine Filterfunktion um Bilder zu glätten. Sie bildet den mittels einer 2D-Gaußfunktion gewichten Mittelwert einer Nachbarschaft.

Gradientenorientierung

Richtung des Farbgradienten in einer Pixelnachbarschaft. Verläuft von dunklen Bildbereichen zu hellen Bildbereichen.

JetBot

Der in dieser Arbeit verwendete Roboter. Gesteuert wird er von einem NVIDIA Jetson Nano Entwicklerboard, auf welchem die hier erstellten Programme laufen. Weiteres ist in Abschnitt 2.4 beschrieben.

Kernel

Eine Matrix die beim Filtern und verarbeiten von Bildern verwendet wird. Mit ihr werden Pixelnachbarschaften gewichtet.

OpenCV

OpenCV ist eine Open Source Software Bibliothek mit typischen Algorithmen und Funktionen für die Bildverarbeitung, *Computer Vision* und maschinelles Lernen.

Pixel

Ein einzelner Bildpunkt. Er hat einen Wert zwischen Schwarz (0) und Weiß (255)

Pixelnachbarschaft

Ein Bereich festgelegter Größe um einen relevanten Hauptpixel.

Python

Eine abstrakte, sehr einfach zu benutzende Programmiersprache.

ROI, kurz für Region of Interest

Ein Bildbereich, der für die derzeitige Anwendung relevant ist. Das restliche Bild wird vernachlässigt.

ROS, kurz für Robot Operating System

Das Robot Operating System ist eine Sammlung von Softwarebibliotheken und Werkzeugen die hilfreich beim erstellen von Roboter Applikationen sind. Von Treibern bis moderne Algorithmen, ROS birgt alles was für das nächste Robotic Projekt benötigt wird. Dabei ist es vollständig Open Source.

ROS Node

Eine ROS Node ist ein Teilprogramm welches von ROS verwaltet wird. Es kann Informationen als Topic veröffentlichen und Topics Abonieren um die dort veröffentlichen Informationen weiter zu verarbeiten.

ROS Nodelet

Ein ROS Nodelet ist ein Programm welches in einem Verbund mit mehreren anderen Nodelets mittels ROS gestartet wird. Alle Nodelets einer Gruppe haben die Möglichkeit auf geteilten Anwendungsspeicher zuzugreifen.

ROS Topic

wie beschreiben??

Weltkoordinaten

Ein 3D-Koordinatensystem das die gesamte Scene/Welt des derzeitigen Systems umfasst.

1 Einleitung

1.1 Problemstellung

Auf der Projektfläche *Autonomes Fahren* des Instituts für Konstruktionselemente, Mechatronik und Elektromobilität (IKME) der Hochschule Hannover ist eine große urbane Kreuzung im Maßstab 1:18 nachgebildet. Hier sollen in Zukunft automatisierte Logistikkonzepte mit mobilen Roboterfahrzeugen entwickelt und getestet werden. Die Roboter sind jeweils mit einer nach vorne gerichteten Videokamera ausgerüstet. Um die Fahrzeuge damit sicher steuern zu können, soll damit eine zuverlässige Fahrspurerkennung benötigt.

1.2 Aufgabenstellung

Ziel der Arbeit ist es, eine echtzeitfähige Erkennung der Fahrspurmarkierungen aus dem Video-Bilddatenstrom zu realisieren und die Position der Markierungen relativ zum Fahrzeug anzugeben. Um eine geometrisch richtige Darstellung zu erhalten, soll zunächst eine Bestimmung der intrinsischen und extrinsischen Kamera-Kalibrierung durchgeführt werden. Mit den so bestimmten intrinsischen Parametern so dann eine Rektifizierung der Bilder durchgeführt werden. Auf den rektifizierten Bildern soll dann die eigentliche Erkennung der Spurmarkierungen erfolgen. Dies kann entweder kanten-basiert oder mit tiefen neuronalen Netzen erfolgen. Die extrinsische Kalibrierung soll dann genutzt werden, um die Position der Markierungen in Fahrzeug-Koordinaten umzurechnen. Zusätzlich kann die Farbinformation des Bildes genutzt werden um zwischen weißen und gelben Linien zu unterscheiden. Gegebenenfalls kann auch das zeitliche Tracking eines Spurmodells umgesetzt werden.

Die Bildverarbeitung sollte unter ROS auf der Jetson-nano Hardware unter ROS in Echtzeit lauffähig sein. Eine erste Implementierung kann mit Python erfolgen. Für den längerfristigen Einsatz wäre eine Umsetzung in C++ mit ROS Nodelets wünschenswert.

1.3 Inhalt der Arbeit

Überblick, jedes Kapitel vorstellen

2 Stand der Technik

2.1 Techniken zur Fahrspurerkennung

Das Thema Fahrspurerkennung beschäftigt die Wissenschaft und auch die Automobilindustrie bereits seit einigen Jahren. Im Folgenden möchte ich daher die existierenden üblichen Ansätze zu diesem Thema erläutern. Dabei ist besonders interessant, wie diese in diese Arbeit einfließen.

2.1.1 Geometrische und algorithmische Ansätze

Bei den klassischen und ältesten Methoden wird an die Thematik mit mathematisch-geometrischen Ansätzen herangegangen. Diese werden zu Algorithmen verknüpft, um unterschiedliche Informationen herauszuarbeiten, zu verknüpfen und das Ergebnis zu verfeinern.

Grundlage bilden hierbei verschiedene Operationen, mit welchen sich Bilder verändern lassen. Solche Operationen verknüpfen eine bestimmte Menge an Pixeln eines Ursprungsbildes mittels einer mathematischen Operation, um ein neues Pixel für das Zielbild zu ermitteln. Ein relativ simples Beispiel hierfür ist das Bilden eines Mittelwertes von jeweils drei Farbpixeln, um ein Schwarzweißbild zu erzeugen.

Der sehr grobe Ablauf, welcher solche Operationen zu einem Algorithmus verknüpft, ist in Abbildung 2.1 skizziert. Dabei sind die Einzelschritte in der Realität jedoch häufig sehr kompliziert. Begonnen wird eigentlich immer mit einem Vorbereitung-Schritt, da die Bilder einer Kamera nur selten direkt verwendet werden können. Teilweise ist eine solche Vorverarbeitung aber auch Hardwareseitig oder in vorgelagerten Programmteilen umgesetzt. Meistens wird das Bild außerdem in ein Schwarzweißbild umgewandelt, da so nur ein Drittel der Pixel untersucht werden müssen, was die Performance verbessert.

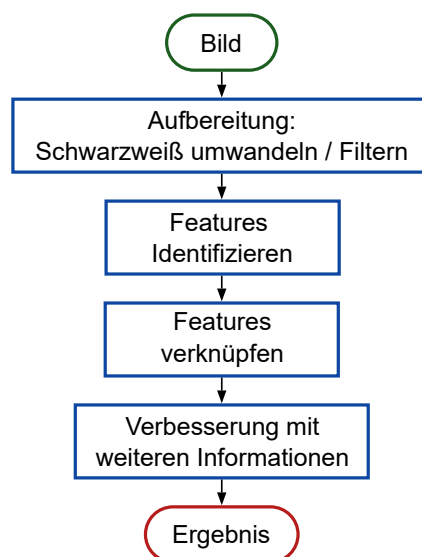


Abb. 2.1: Generischer Ablauf von Fahrspurerkennung (nach [KK15])

Bei den sogenannten Features handelt es sich um spezifische, möglichst eindeutige Muster

im Bild. Im Fall von Fahrspurmarkierungen sind dies eigentlich immer Kanten und Ecken ebendieser. Häufig wird hier der Canny-Edge-Detektor eingesetzt, der von John Canny in [Can86] entwickelt wurde. Dieser Algorithmus ist sehr gut zum Identifizieren von Kantenpixeln geeignet und erzeugt ein Binärbild, in dem nur noch ein Pixel dicke Umrisse verbleiben.

Das genaue Vorgehen um Features zu finden und zu verknüpfen, hängt von der Methode ab. In [KK15] werden verschiedene Möglichkeiten die Hough Transformation zu verwenden miteinander verglichen und [WHF05] verwendet zusätzlich eine Methode zum Kombinieren von einzelnen Liniensegmenten. [Lop+05] demonstriert einen Ansatz, um direkt Mittellinien von Fahrspurmarkierungen anhand von bekannten Größenparametern abzuleiten.

Das Ergebnis kann durch das Einbeziehen weiterer Informationen noch weiter verbessert werden. Oft wird hier das originale Farbbild mit einbezogen (siehe [KK15]), aber auch das Zurückgreifen auf das vorherige Bild, wie in [Lu+19] eingesetzt, ist möglich.

Da diese Techniken bereits langfristig erprobt und daher sehr stark optimiert sind, eignen sie sich besonders gut für den Einsatz in dieser Arbeit. Auch der gezeigte Ablauf wird in dieser Arbeit so angewendet.

Insbesondere die gezeigten Methoden des Canny-Edge-Detektor werden später noch einmal aufgegriffen. Die in vielen Quellen erwähnte Hough Transformation wurde aber bereits im Voraus als zu rechenintensiv ausgeschlossen.

Stand der Technik: Was ist Spruerkennung? wie wird das zurzeit immer gemacht??

- ein absatz klasisch kantenbasiert
- ein absatz Kategorien von Deep learning ansätzen

2.1.2 Deep Learning Ansätze

Alternativ zu den traditionellen Ansätzen gibt es die neuen Deep Learning Methoden. Hier werden sogenannte *Convolutional Neural Networks* (kurz *CNN*) verwendet. Diese Netzwerke bestehen aus mehreren Schichten, welche von einem Eingangsbild nacheinander durchlaufen werden.

Was ist das?
Warum hier nicht?
Was ist ungeeignet?

2.2 OpenCV

Das Open-Source-Projekt OpenCV (kurz für *Open Source Computer Vision Library*) ist eine Sammlung von Softwaremodule die der Bildverarbeitung und dem maschinellen Lernen dienen. Sie verfügt über mehr als 2500 optimierte Algorithmen mit denen Anwendungen wie Objekterkennung, Bewegungserkennung und 3D-Modell Extraktion erstellt werden können. Daher ist sie eine der standard Bibliotheken, wenn es um digitale Bildverarbeitung geht und wird fast immer zur Demonstration neuer Konzepte benutzt. Da sie sowohl in C/C++, Java und Python genutzt werden kann, ist sie außerdem sehr vielseitig und hat den Vorteil, dass Konzepte in einer abstrakten Sprache wie Python getestet werden und später relativ simple in eine Hardwarenahe Programmiersprache übersetzt werden können. Für mehr Informationen kann die Webseite des Projektes [Ope22a] besucht werden.

In dieser Arbeit wird diese Bibliothek daher insbesondere für die Entwicklungsphase verwendet. Da der Bibliothekskunde jedoch auch viele potenziell nicht benötigte Zusatzfunktionen mit bring, wird auch ein wechsel auf eine eigene Implementierung mit besserer Performance in Betracht gezogen.

2.3 Das Robot Operating System

Das Robot Operating System (kurz: ROS) ist eine Sammlung von Software Bibliotheken und Werkzeugen die zum Erstellen von Roboter Applikationen dienen. Es bietet eine eigene Paketverwaltung über die verschiedenste bestehende Bibliotheksfunktionen für die Verwendung heruntergeladen werden können. Dabei handelt es sich um verschiedenste Anwendungen, angefangen Treiben, über fertige, direkt anwendbare Algorithmen bis zu Nutzer nahen Steueroberflächen und sogar (Lern-)Spiele. Die Webseite des Projektes [Rob22] bietet hierzu weitere Informationen. Außerdem bietet ROS Integrationen mit anderen bestehenden Projekten, wie zum Beispiel OpenCV.

Auch wenn es sich bei ROS genaugenommen um kein vollständiges Betriebssystem handelt, stellt es für ein solches typische Funktionalitäten zur Verfügung. Beispiele hierfür sind Hardware-Abstraktion, tiefgehende Geräteverwaltung, Verwaltung von Prozessen sowie Informationsweitergabe zwischen diesen und die eben genannte Paketverwaltung und damit verbundene Abstraktion von generischen, allgemein benötigten Funktionen. [Rob18]

Für diese Arbeit ist ROS deshalb interessant, da sich die Ergebnisse so modular an potenzielle weitere Prozesse weitergeben lassen. Dies wird durch ROS Fähigkeit möglich, Einzelprozesse als sogenannte ROS Nodes zu erstellen. Jede Node kann eigene Informationen als sogenannte Topics veröffentlichen und andere, parallel laufende Nodes können diese abonnieren.

Sobald eine Information in einem Prozess bereit ist, verpackt dieser sie in einem der definierten Datentypen. Dieser wird dann als Message veröffentlicht und an alle Abonnenten des Topics verschickt. Diese können dann bei Erhalt der Nachricht auf diese reagieren.

So lassen einzelne Komponenten dieser Arbeit abgekapselt voneinander umsetzen und stellen ihre Ergebnisse auf potenziellen, später noch entwickelten Prozessen zur Verfügung.

ROS's ??

2.4 Der JetBot Roboter



Abb. 2.2: SparkFun JetBot AI Kit V2.1 [Spa22]




Abb. 2.3: CPU Auslastung des JetBots ohne ROS

2.4.1 Performance Baseline

Baseline Auslastung ohne irgendwelche laufenden Prozesse $\approx 8\%$.




Abb. 2.4: CPU Auslastung mit laufender Kamera und ROS-Core

Mit ROS-Core und laufendem Kameratreiber $\approx 38\%$

3 Kamera Kalibrierung

Damit der später beschriebene Fahrspurerkennung möglichst zuverlässig funktioniert und möglichst reproduzierbar ist, wird eine Kalibrierung vorgenommen. Das Vorgehen dazu und die Ergebnisse sind im folgenden Kapitel dokumentiert.

3.1 Intrinsische Kalibrierung

Bedingt durch den technischen Aufbau des Linsensystems und Ungenauigkeiten bei der Herstellung sind die von der Kamera gelieferten Bilder merklich verzerrt. In Abbildung 3.1 ist dies gut anhand der Linien des Schachbrettes zu erkennen, die in der Realität natürlich alle parallel verlaufen, im Bild aber gekrümmt aussehen.




Abb. 3.1: Unkalibriertes Kamerabild mit tonnenförmiger Verzeichnung

3.1.1 Radiale Verzerrung

Die erste mögliche Art der Verzerrung ist die radiale Verzerrung. Diese ist die auffälligste Art der Verzerrung und wird häufig auch *Fischaugen Effekt* genannt. Bedingt durch die Brechung des Lichtes an den Kanten der Blende und der Linse entsteht eine Ablenkung der Lichtstrahlen in der Kamera, die mit der Entfernung vom Mittelpunkt immer weiter zu nimmt. Nimmt die Ablenkung mit der Entfernung zu, spricht man von positiver, kissenförmige Verzerrung, den umgekehrte Fall nennt man negative, tonnenförmige Verzerrung. Zur Verdeutlichung ist in Abbildung 3.2 die Auswirkung dieser Verzerrung auf ein Rechteckmuster gezeigt.

Mathematisch lässt sich die Veränderung eines Punktes durch die Verzerrung wie in Gleichung 3.1 beschrieben berechnen. Dabei beschreiben x und y die unverzerrten Pixelkoordinaten, k_1 , k_3 und k_5 die Verzerrungskoeffizienten. Theoretisch existieren noch weitere Koeffizienten, aber in der Praxis haben sich die ersten drei als ausreichend herausgestellt. [Han11]

$$\begin{aligned}x_{\text{distorted}} &= x(1 + k_1 r^2 + k_2 r^4 + k_3 r^6) \\y_{\text{distorted}} &= y(1 + k_1 r^2 + k_2 r^4 + k_3 r^6)\end{aligned}\tag{3.1}$$




Abb. 3.2: Darstellung der optischen Verzerrung (nach [Wik22])

3.1.2 Tangentielle Verzerrung

Die tangentielle Verzerrung entsteht durch kleine Ausrichtungsfehler im Linsensystem. Dadurch liegt die Linse nicht perfekt in der Bildebene und der Bildmittelpunkt sowie die Bildausrichtung können leicht verschoben sein.




Abb. 3.3: Probleme in der Ausrichtung von Sensor und Linse (nach [Mat22])

Mathematisch wird diese Verzerrung durch den folgenden Zusammenhang beschrieben. [Han11]

$$\begin{aligned} x_{\text{distored}} &= x + \left[2p_1xy + p_2(r^2 + 2x^2) \right] \\ y_{\text{distored}} &= y + \left[p_1(r^2 + 2y^2) + 2p_2xy \right] \end{aligned} \quad (3.2)$$

Durch beide Verzerrungsarten zusammen werden also durch fünf Parameter beschrieben, die sogenannten Verzerrungskoeffizienten. Historisch begründet wird dabei k_3 an das Ende geschrieben, da dieses Parameter früher kaum berücksichtigt wurde.

$$D_{\text{coeff}} = (k_1, k_2, p_1, p_2, k_3) \quad (3.3)$$

Um die Parameter bestimmen zu können, müssen also mindestens fünf Punkte gefunden werden, von denen die Weltkoordinaten und die Bildkoordinaten bekannt sind. Da sich die Punktpaare aber nur schwer mathematisch perfekt bestimmen lassen, werden mehr Paare benötigt, um ein überbestimmtes Gleichungssystem zu erhalten und dieses nach dem geringsten Fehler zu lösen. [Ope22b]

In der Praxis werden 2D-Muster verwendet, um Punktpaare zu bestimmen. Da sich alle Punkte dieser Muster in einer Ebene befinden, kann der Ursprung der Weltkoordinaten in eine Ecke des Musters gelegt werden, sodass die Z-Koordinate keine Relevanz mehr hat und wegfällt. [Fra+09]

Dabei werden Muster so gewählt, dass es möglichst einfach fällt die Weltkoordinaten der Punkte zu bestimmen. Beispielsweise sind bei einem Schachbrettmuster die Entfernungen alle identisch und können als 1 angenommen werden, wodurch die Koordinaten der Punkte direkt ihrer Position im Muster entsprechen.

3.2 Durchführung der intrinsischen Kalibrierung

Zur Durchführung der Kalibrierung wird ein Python-Script erstellt, um die den Vorgang einfach und wiederholbar zu machen. Als Vorlage für dieses dient die Anleitung zur Kamera Kalibrierung aus der OpenCV Dokumentation [Ope22b].

Außerdem wird eine ROS Nodelet erstellt, welches die Kalibrierung auf den Video-Stream anwendet und korrigierte Bilder veröffentlicht.

3.2.1 Python Script zur Durchführung der Kalibrierung

Grundlage für die Kalibrierung ist es, eine Reihe von Bildern mit der zu kalibrierenden Kamera aufzunehmen, auf denen sich ein Schachbrettartiges Kalibriermuster befindet. Wichtig ist es, dasselbe Muster und dieselbe Auflösung für alle Bilder verwendet werden. Es muss sich dabei nicht um eine quadratische Anordnung handeln, jedoch muss die Anzahl der Zeilen und spalten im Code angegeben werden. Dabei ist allerdings nicht die Anzahl der Felder gemeint, sondern die Anzahl der inneren Kreuzungspunkten. Ein normales Schachbrett hat beispielsweise 8×8 Felder, aber nur 7×7 interne Kreuzungen. Zur Verdeutlichung sind die Kreuzungspunkte des Verwendeten Kalibriermuster in Abbildung 3.4 grün markiert.




Abb. 3.4: Schachbrett Kalibriermuster mit markierten inneren Kreuzungen

Es wird nun ein Standard Schachbrett als Kalibriermuster verwendet, wie es bereits in Abbildung 3.4 zu sehen ist. Dessen Kalibriermustergröße von 7×7 wird im Code als Konstante definiert:

Code 3.1: Definition der Größe des Kalibriermuster

```
1 # define the grid pattern to look for
2 PATTERN = (7,7)
```

Entsprechend der Anleitung [Ope22b] werden benötigte Variablen initialisiert (siehe Code 3.2). Nun werden alle im aktuellen Ordner befindlichen Bilder eingelesen und in einer Liste abgespeichert. Jedes Listenelement wird eingelesen und in ein Schwarzweißbild umgewandelt.

Code 3.2: Initialisierung von Variablen für die Kalibrierung

```
1 # termination criteria
2 criteria = (cv.TERM_CRITERIA_EPS + cv.TERM_CRITERIA_MAX_ITER, 30,
3             0.001)
4 # prepare object points, like (0,0,0), (1,0,0),..., (6,5,0)
5 objp = np.zeros((PATTERN[0]*PATTERN[1],3), np.float32)
6 objp[:, :2] = np.mgrid[0:PATTERN[0], 0:PATTERN[1]].T.reshape(-1,2)
7 # Arrays to store object points and image points from all the
8   images.
9 objpoints = [] # 3d point in real world space
10 imgpoints = [] # 2d points in image plane.
```

Dieses wird dann an die OpenCV Funktion `findChessboardCorners()` übergeben, welche die Kreuzungspunkten findet und zurückgibt.

Code 3.3: Finden und Verarbeiten der Kalibrierbilder

```
1 # get all images in current directory
2 folder = pathlib.Path(__file__).parent.resolve()
3 images = glob.glob(f'{folder}/*.png')
4
5 # loop over all images:
6 for fname in images:
7     img = cv.imread(fname)
8     gray = cv.cvtColor(img, cv.COLOR_BGR2GRAY)
9
10    # Find the chess board corners
11    ret, corners = cv.findChessboardCorners(gray, PATTERN, None,
12                                           flags=cv.CALIB_CB_ADAPTIVE_THRESH)
```

Dabei ist es gar kein Problem, wenn nicht in jedem Bild das Kalibriermuster gefunden werden kann, solange insgesamt ausreichend nutzbare Bilder vorhanden sind. Bei nicht nutzbaren Bildern gibt `findChessboardCorners()` `None` zurück und das Bild wird einfach übersprungen. Für alle nutzbaren Bilder werden die in Code 3.2 erstellten Punktbezeichnungen zur Liste der gefundenen Objekte hinzugefügt. Die Genauigkeit der gefunden Eckkoordinaten wird über die Funktion `cornerSubPix()` erhöht und diese werden an die Liste der gefundenen Bildpunkte angehängt.

Code 3.4: Abspeichern der Gefundenen Bildpunkte

```
1 # If found, add object points, image points
2 if ret == True:
3     objpoints.append(objp)
4     corners2 = cv.cornerSubPix(gray, corners, (11,11), (-1,-1),
5                                criteria)
6     imgpoints.append(corners2)
```

Jetzt kann die eigentliche Kalibrierung mittels der OpenCV Funktion `calibrateCamera()` durchgeführt werden. Diese nimmt die zuvor erstellten Listen von Objektkoordinaten und Bildpunkten und löst damit die in Abschnitt 3.1 beschriebenen Gleichungen. Als Ergebnis liefert sie die Kameramatrix K und die Verzerrungskoeffizienten D_{coeff} zurück. [Ope22b]

Code 3.5: Ermitteln der Kalibrierwerte mittels OpenCV

```
1 # get calibration parameters:  
2 ret, K, D_coeff, rvecs, tvecs = cv.calibrateCamera(objpoints,  
    imgpoints, gray.shape[::-1], None, None)
```

Der gesamte Code wird nun auf einen Datensatz von Bildern angewandt, um die Ergebnisse für den vorliegenden Roboter zu erhalten. Der Datensatz ist auf dem GitLab Server unter der [Wil22a] abgelegt. Damit ergeben sich die folgenden Kalibrierungsergebnisse.

$$\begin{aligned}k_1 &= -0,42049309612684654 \\k_2 &= 0,3811654512587829 \\p_1 &= -0,0018273837466050299 \\p_2 &= -0,006355252159438178 \\k_3 &= -0,26963105010742416 \\K &= \begin{pmatrix} 384,65 & 0 & 243,413 \\ 0 & 384,31 & 139,017 \\ 0 & 0 & 1 \end{pmatrix}\end{aligned}$$

Um zu zeigen, wie sich das Bild damit verbessern lässt, werden die Ergebnisse auf eines der Bilder angewandt. Da sich die Abmessungen des entzerrten Bildes von denen des verzerrten unterscheiden, wird zuerst die OpenCV Funktion `getOptimalNewCameraMatrix()` verwendet, welche eine weiter skalierte Kameramatrix ermittelt, mit der die Abmessungen zueinander passen. Diese liefert außerdem eine ROI, also den Bildbereich der nur relevante (nicht leere) Pixel enthält.

Mit dieser zusätzlichen Matrix kann nun die OpenCV Funktion `undistort()` auf das Bild angewandt werden. Diese produziert das entzerrte Bild mit leeren Pixeln in den Bereichen, wo keine Informationen im Originalbild vorlagen. Um diese leeren Pixel zu entfernen wird das Bild auf die ROI reduziert.

In Abbildung 3.5 ist die Entzerrung des Beispielsbildes mit dem Zwischenschritt mit Leerpixeln gezeigt.




Abb. 3.5: Schritte der intrinsischen Kalibrierung

Reprojektions-Fehler

Um eine Aussage über die Genauigkeit der gefundenen Kalibrierungs-Parameter treffen zu können, wird der Reprojektions-Fehler bestimmt. Dieser gibt den Abstand zwischen einem im Kalibriermuster gefundenen Kreuzungspunkt und den mittels der Kalibrierung Ergebnisse

berechneten Weltkoordinaten. Der Mittelwert aller Abweichungen in allen verwendeten Bilder gibt den Reprojktions-Fehler für den ganzen Kalibriervorgang an.

Der Code 3.6 zeigt die Berechnung mittels von OpenCV zur Verfügung gestellten Funktionen und den zuvor ermittelten Kalibrierdaten. Für jeden Satz an theoretischen Weltkoordinaten des Kalibriermusters in `objpoints` werden die Punkte im Bild mit der OpenCV Funktion `projectPoints()` bestimmt und mit den gefundenen Punkten verglichen. Dazu wird die OpenCV Funktion `norm()` verwendet, die direkt die summe aller Differenzen zwischen den beiden Punktelisten liefert.

Das Ergebnis wird auf dem Bildschirm ausgegeben.

Code 3.6: Berechnen des Reprojktions-Fehlers

```
1 # calculate re-projection error
2 mean_error = 0
3 for i in range(len(objpoints)):
4     imgpoints2, _ = cv.projectPoints(objpoints[i], rvecs[i],
5                                     tvecs[i], mtx, dist)
6     error = cv.norm(imgpoints[i], imgpoints2,
7                     cv.NORM_L2)/len(imgpoints2)
8     mean_error += error
9 print(f"total error: {mean_error/len(objpoints)}")
```

Mit dem verwendeten Datensatz ergibt sich ein Reprojktions-Fehler von 0,049, was genau genug für diesen Anwendungsfall ist.

3.2.2 Anwenden der Kalibrierung in einer ROS Node

Um die Kalibrierungsergebnisse auf jedes Bild, dass vom Kamera Treiber veröffentlicht wird, anzuwenden, wird eine weitere Node erstellt. Diese entzerrt jedes erhaltene Bild und veröffentlicht die korrigierte Version als eigens Topic. Das korrigierte Bild wird sowohl in Farbe als auch in Schwarz-Weiß veröffentlicht. Die Beziehung der Topics ist in Abbildung 3.6 Grafisch dargestellt.




Abb. 3.6: Beziehungen der entzerrer Node zu bestehenden Nodes

Initialisieren der Node

Beim Start der Node wird die `main()` Funktion aufgerufen, welche die notwendigen ROS Funktionen zur Initialisierung aufruft, das benötigte Topic abonniert, eine Callback-Funktion anhängt und die eigenen Topics veröffentlicht.

Außerdem werden die Kalibrierdaten aus einer Konfigurationsdatei im YAML-Format eingelesen und in Variablen übernommen. Die Verzerrungsparameter werden als Vektor eingelesen und

Code hierzu?

die Kameramatrix wird in eine OpenCV Matrix umgewandelt. Außerdem wird die Bildgröße benötigt und aus der Konfigurationsdatei gelesen. Code 3.7 zeigt den Ablauf. Es ist sinnvoll, dies bereits in der `main()` Funktion durchzuführen, um die Callback-Funktion zu entlasten und dort Rechenzeit einzusparen.

Code 3.7: Einlesen der Kalibrierungsergebnisse aus einer YAML-Datei

```
1 // open YAML-file and get config
2 std::string configFilePath =
3     "./tools/calibration/calibration.yaml";
4 YAML::Node full_config = YAML::LoadFile(configFilePath);
5
6 // read distortion coefficients and convert to OpenCV vector
7 auto distortion_YAML = camera_config["intrinsic"]["distortion"]
8     .as<std::vector<double>>();
9 cv::Mat distortion ( distortion_YAML );
10
11 // read camera matrix and convert to OpenCV matrix
12 auto cameraMatrix_YAML = camera_config["intrinsic"]["matrix"]
13     .as<std::vector<std::vector<double>>>();
14 cv::Mat cameraMatrix = toMat( cameraMatrix_YAML );
15
16 // read image size
17 cv::Size imageSize(
18     full_config["images"]["size"]["width"].as<int>(),
19     full_config["images"]["size"]["height"].as<int>()
20 );
```

Mit diesen Werten können nun *Mappings* erzeugt werden, welche die geometrische Beziehung zwischen einem Pixel im Originalbild und einem Pixel im entzerrten Bild abspeichern. Es werden zwei *Mappings* für die X und die Y-Koordinate erzeugt, welche in globalen Variablen abgelegt werden. Das ist notwendig damit die Informationen der Callback-Funktion zur Verfügung stehen.

Zuvor ist es aber noch sinnvoll, eine umskalierte, optimierte Kameramatrix zu erzeugen. OpenCV stellt hierzu die Funktion `getOptimalNewCameraMatrix()` zur Verfügung. Diese erstellt die neue Matrix abhängig von einem freien Skalierungsparameter α . Für $\alpha = 0$ ist die zurückgegebene Matrix so gewählt, dass das entzerrte Bild möglichst wenig unbekannte Pixel enthält. Das bedeutet aber, dass einige Pixel des Originalbildes außerhalb des neuen Bildbereiches liegen und vernachlässigt werden. Mit $\alpha = 1$ enthält das entzerrte Bild alle Pixel des Originalbildes, allerdings bleiben einige Pixel schwarz. Da die Funktion zusätzlich eine ROI liefert, welches den Bildausschnitt ohne schwarze Pixel beschreibt, wird hier $\alpha = 1$ verwendet. Die veröffentlichten Bilder werden zwar auf die ROI reduziert, aber die vorhandenen Informationen werden grundsätzlich erhalten und bei Bedarf kann das Programm einfach angepasst werden, um die vollständigen Bilder zu veröffentlichen.

Callback-Funktion zur Handhabung der Einzelbilder

Die Callback-Funktion `callback_undistort_image()` wurde während der Initialisierung an das Topic `/img/raw` angehängt und wird nun für jedes dort veröffentlichte Bild aufgerufen. Der Code 3.9 zeigt eine vereinfachte Version der Implementierung, ohne Umwandlung in ein Schwarzweißbild und ohne Laufzeitmessung.

Code 3.8: Bestimmen der Pixel-Mappings zu Entzerrung

```
1 // get scaled camera matrix
2 auto scaledCameraMatrix =
    cv::getOptimalNewCameraMatrix(cameraMatrix, distortion,
    imageSize, 1, imageSize, &ROI);
3
4 // calculate undistortion mappings
5 cv::initUndistortRectifyMap(cameraMatrix, distortion, cv::Mat(),
    scaledCameraMatrix, imageSize, CV_16SC2, rectifyMapX,
    rectifyMapY);
```

Da das Bild als ROS eigener Datentyp übergeben wird, muss es zuerst in ein mit OpenCV kompatibles Format umgewandelt werden. Die dazu notwendigen Funktionen sind im ROS-Paket `cv_bridge` zur Verfügung gestellt. Dessen Funktion `toCvCopy()` kopiert die Daten des Originalbildes in eine OpenCV Matrix, welche weiter verwendet werden kann.

Das Bild kann nun mit der OpenCV Funktion `remap()` entzerrt werden. Diese benutzt die zuvor bestimmten *Mappings*, um jeden Pixel des Originalbildes an die korrekte Position im entzerrten Bild zu übertragen. Dabei wird linear interpoliert.

Das Erhalten Bild wird auf die ROI reduziert und unter dem Topic `/img/color` veröffentlicht. Außerdem wird ein Schwarz-Weiß Version erzeugt und diese als `/img/gray` veröffentlicht (was hier aber nicht gezeigt ist).

Code 3.9: Vereinfachte Version der Callback-Funktion zur Durchführung der Entzerrung

```
1 void callback_undistort_image(sensor_msgs::Image original) {
2     cv::Mat undistortedImage;
3
4     // convert from ROS msg-type to opencv matrix
5     cv_bridge::CvImagePtr imagePtr = cv_bridge::toCvCopy(original);
6
7     // apply the calculated maps to undistort the image
8     cv::remap(imagePtr->image, undistortedImage, rectifyMapX,
        rectifyMapY, cv::INTER_LINEAR);
9
10    // crop relevant section from image
11    undistortedImage = undistortedImage(ROI);
12
13    // publish images
14    cv_bridge::CvImage colorImage(std_msgs::Header(), "rgb8",
        undistortedImage);
15    pub_colorImage->publish(colorImage.toImageMsg());
16 }
```

Performance Betrachtung

Da diese Node eine Grundlagenfunktion darstellt und parallel zu jeder anderen Anwendungen laufen muss, ist es wichtig, dass sie möglichst Performant ist und wenig Ressourcen des JetBots verbraucht.
Daher wurde die mittlere CPU Auslastung und die durchschnittliche Laufzeit der Callback-Funktion, welche ja für jedes Bild durchlaufen wird, gemessen.




Abb. 3.7: CPU Auslastung des JetBots mit laufender Kamera und entzerrer Node

Der jtop Screenshot in Abbildung 3.7 zeigt die CPU Nutzung bei aktivem ROS-Core, Kamera-treiber und der neu erstellten Entzerrer Node. Die durchschnittliche CPU Auslastung liegt bei ungefähr 38,75 %, ist also nur sehr geringfügig höher als die in Unterabschnitt 2.4.1 gemessene Grundauslastung ohne die neue Node.
Um die Laufzeit der Node zu bestimmen wird die aktuelle Zeit wie sie von der Funktion `ros::Time::now()` zurückgegeben wird verwendet. Die aktuelle Zeit beim Start der Callback-Funktion wird abgespeichert. Nach Durchlauf der Funktion wird erneut die aktuelle Zeit bestimmt und die Differenz in Sekunden als Debug-Nachricht ausgegeben. Die Laufzeit der Node wird über einige Zeit gemittelt. Dabei ergibt sich eine Laufzeit von $\approx 3,9$ ms.

Tab. 3.1: Gemessene Laufzeit bei 10 Durchläufen der Callback-Funktion

Durchlauf Nr.	gemessene Laufzeit
1	3,885 ms
2	4,068 ms
3	3,969 ms
4	3,712 ms
5	3,970 ms
6	4,086 ms
7	4,025 ms
8	3,897 ms
9	3,753 ms
10	4,096 ms

ist die Tabelle überhaupt sinnvoll?

4 Fahrspurerkennung

Dieses Kapitel thematisiert, wie die Erkennung der Fahrspurmarkierungen umgesetzt wird. Begonnen wird mit einer konzeptionellen Version in Python, mit der der Ablauf des Algorithmus geplant und getestet wird. Danach wird die Logik in einer C++ Node umgesetzt, um die best möglichst Performance zu erhalten.




Abb. 4.1: Zusammenhang der Fahrspurmarkierung-Erkennungs Node mit den bestehenden Nodes

Wie diese neuen Nodes mit den bestehenden Nodes in Beziehung stehen soll, ist in Abbildung 4.1 grafisch dargestellt. Neu ist dabei, dass diese Node das korrigierte Schwarz-Weiß Bild von der in Unterabschnitt 3.2.2 beschriebenen entzerrer Node abonniert und die eigenen Ergebnis als neues Topic zur Verfügung stellt.

4.1 Konzeptionierung in Python

Die Entwicklung und Konzeptionierung des Algorithmus Erfolg in Python, da diese Sprache nicht kompiliert werden muss, was das Testen beschleunigt, und generell einfacher zu verwenden ist.

Der Algorithmus lässt sich in mehrere Einzelschritte aufteilen und wird daher in den folgenden Unterkapitel beschreiben. Zur Übersicht ist aber der gesamte Ablauf in Abbildung 4.2 vereinfacht skizziert. Angefangen wird dort mit dem Erhalten des Bildes, womit sowohl manuelles Laden eines Beispielsbildes, als auch das Erhalten des Bildes über ein Topic gemeint ist.

Während einer Testfahrt des JetBots wurden von der entzerrer Node veröffentlichte Bilder abgespeichert, sodass sie zum lokalen Testen zur Verfügung stehen. Diese wurden unter [Wil22b] abgelegt. In Abbildung 4.3 ist eines dieser Bilder gezeigt, mit dem im Folgenden die Einzelschritte demonstriert werden.

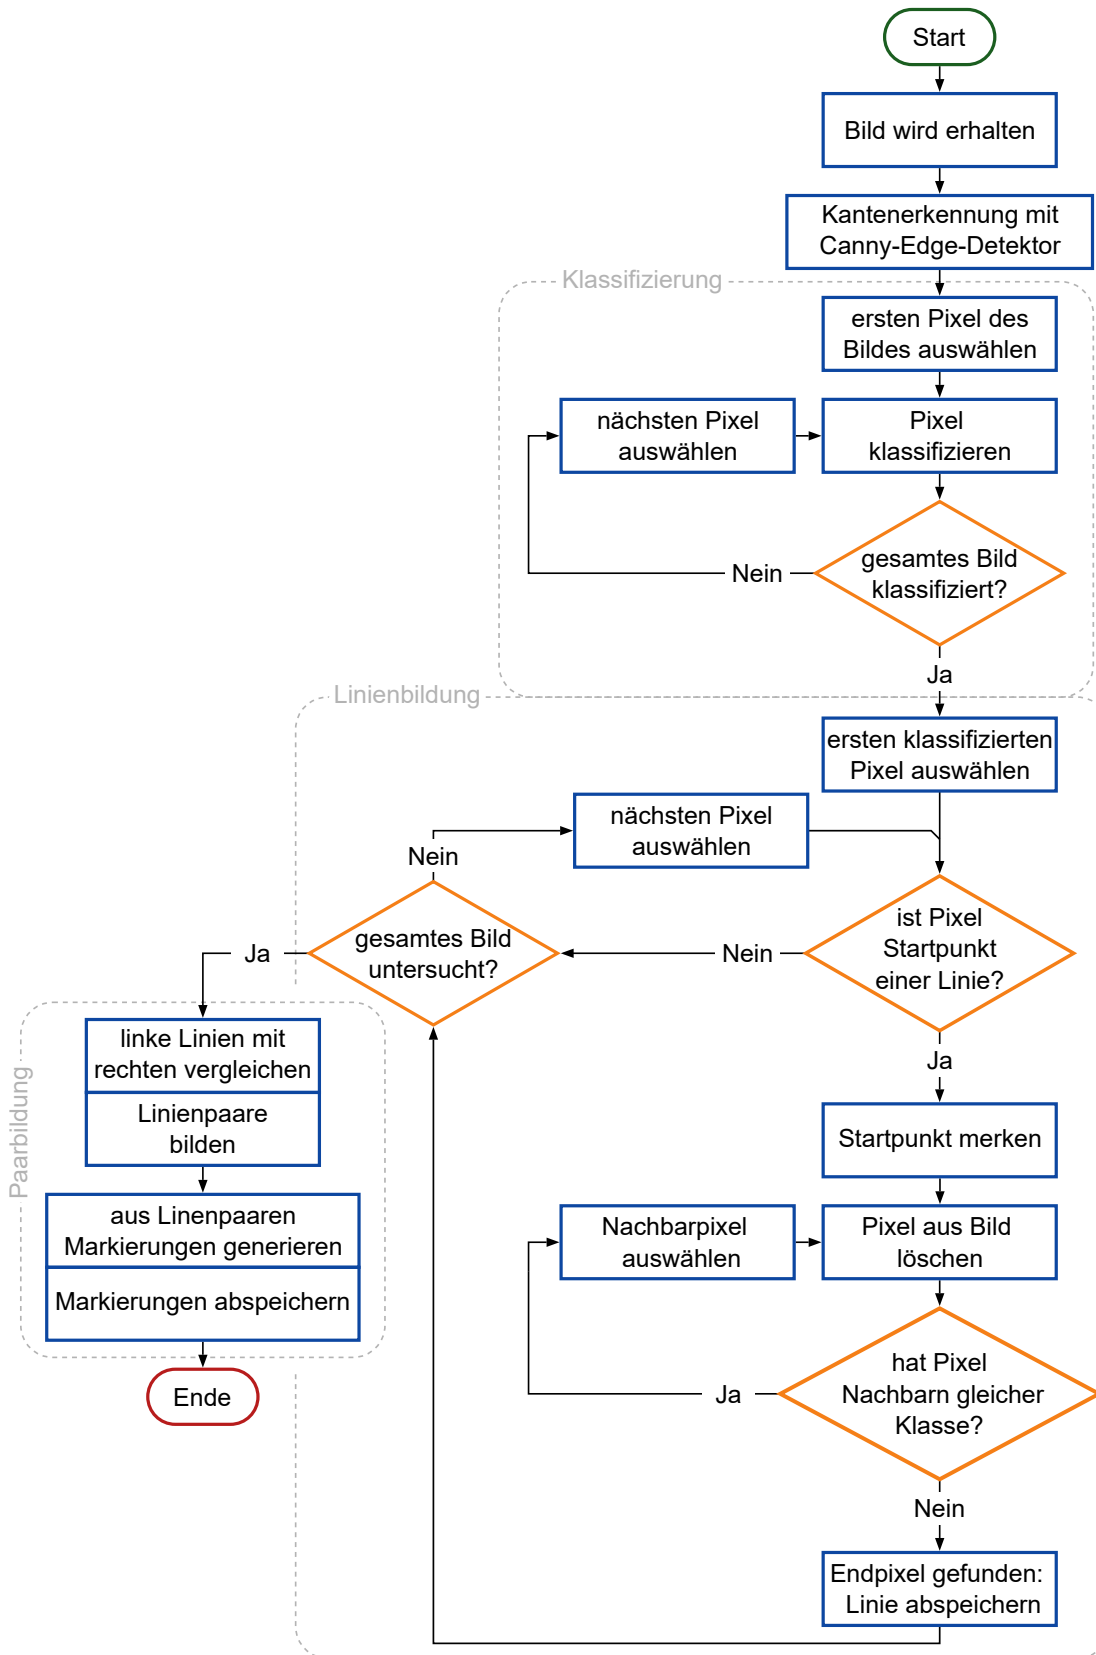


Abb. 4.2: Ablauf des Algorithmus zur Erkennung von Fahrspurmarkierungen



Abb. 4.3: Ein Beispiel Bild an dem der Ablauf demonstriert wird

4.1.1 Kantenerkennung mittels Canny-Edge-Detektor

Begonnen wird mit der Detektion von Kante im Bild. Dazu wird das Bild zuerst mit OpenCV geladen.

Absatz Ja/Nein?

Um kleine Störungen im Bild, welche bestehende Kanten verzerren oder als falsche Kante erkannt werden könnten, zu reduzieren, wird das Bild mit einem Gaußschen Filter geglättet. Es wird ein 3×3 Kernel mit einer Normalverteilung von $\sigma = 1,5$ verwendet. OpenCV stellt hierzu die Funktion `GaussianBlur()` zur Verfügung, der das geladene Bild, die Kegelgröße und der Wert für σ übergeben wird.

Die eigentliche Kantenerkennung wird mittels eines Canny-Edge-Detektors durchgeführt. Dabei handelt es sich um einen von John Canny 1993 entwickelten und in [Can86] veröffentlichten Algorithmus. Dieser bestimmt für jeden Pixel den Gradientenbetrag der Gradienten in X- und Y-Richtung. Dann werden diejenigen Pixel unterdrückt, welche entlang der Gradientenrichtung kein Maximum darstellen. Zum Abschluss wird das Bild mit einem Hysterese-Schwellwert binarisiert. Das bedeutet, dass alle Pixel über einem initialen, oberen Schwellwert als Kanten gesetzt werden und mittels eines zweiten, niedrigeren Schwellwerte, Lücken zwischen diesen Pixeln geschlossen werden. [Nis+12]

Auch dieser Algorithmus ist in OpenCV bereits implementiert und wird für den ersten Entwurf verwendet. Die Funktion bekommt das geladene und geglättete Bild sowie die beiden Hysterese-Schwellwerte übergeben. Diese ist auch in Code 4.1 gezeigt.

Code 4.1: Laden, glätten eines Bildes und durchführen der Kantenerkennung mit OpenCV

```
1 # load image (should be gray, so convert)
2 img = cv2.imread("./image.png")
3 img = cv2.cvtColor(img, cv2.COLOR_RGB2GRAY)
4
5 # edge detection
6 img = cv2.GaussianBlur(img, (3,3), 1.5)
7 canny = cv2.Canny(img, 180, 40)
```

Wird dieser Code auf das Beispielbild 4.3 angewendet und das Ergebnis des Canny-Edge-Detektors ausgegeben, ergibt sich Abbildung 4.4. Im Gegensatz zu alternativen, wie einer reinen Grabantenbetrachtung, liefert der Canny-Edge-Detektor Kantenmarkierungen (hier in weiß) die nur ein Pixel breit sind. Dies ermöglicht die in den folgenden Unterkapiteln beschriebenen Schritte.

einen?




Abb. 4.4: Vom Canny-Edge-Detector gefundene Kanten

4.1.2 Klassifizierung der Kantenpixel

Nur die Identifikation von Pixeln als Kantenpixeln reicht nicht aus, um bereits Linienmarkierungen zu erkennen. Uns Menschen fällt es zwar Leicht in Abbildung 4.4 die gesuchten Linien zu identifizieren, für den Algorithmus handelt es sich aber nur um eine „zufällige“ Ansammlung von weißen Pixeln. Es werden weiter Informationen benötigt.

„zufällige“ OK?

Deshalb werden jedem Kantenpixel eine Klasse entsprechend seiner Orientierung zugeordnet. Um die Datenmenge gering und die Laufzeit schnell zu halten, werden lediglich die vier Klassen *Vertikal*, *Horizontal*, *Diagonal 1* und *Diagonal 2* verwendend. Zusätzlich wird noch die Richtungsinformation als Vorzeichen abgespeichert.

Die Klassifizierung erfolgt anhand der Gradientenorientierung eines Pixels. Dazu werden mit 3×3 Sobel-Kernen die Gradienten d_x und d_y bestimmt. Mit der $\text{atan2}()$ Funktion kann aus diesen beiden Größen der Winkel des Gradientenvektors \vec{G} berechnet werden. Mit diesem Winkel kann nun entsprechen der Abbildung 4.5 die Klasse bestimmt werden. Dabei ist zu beachten das \vec{G} immer orthogonal auf der eigentlichen Kante steht, deshalb ist die Klasse *Vertikal* auch auf der links-rechts Achse der Abbildung zu finden.




Abb. 4.5: Klassifizierung der Gradientenorientierung (nach [Hom21])

Die Klassifizierung wird in einer 8-Bit Variable abgespeichert, da so ein normales Graustufen-Bild als Datenstruktur verwendet werden kann. Jeder Klasse wird dabei ein Bit wie folgt zugeordnet:

Tab. 4.1: Zuordnung der Klassen zu Bits

Bit	Klasse
1	<i>Vertikal</i>
2	<i>Diagonal 1</i>
3	<i>Diagonal 2</i>
4	<i>Horizontal</i>
5	Vorzeichen-Bit

Um die Klassifizierung in Python durchzuführen, wird zuerst ein weiteres, leere 8-Bit Bild mit identischer Größe angelegt. Dann wird erneut über alle Pixel des Bildes iteriert. Da allerdings die meisten Pixel schwarz und damit uninteressant sind, können diese direkt verworfen werden. Für alle verbleibenden, weißen Pixel wird die Klassifizierung durchgeführt.

Code 4.2: Schleife über das vom Canny-Edge-Detektor gelieferte Bild

```

1 for (u, v), e in np.ndenumerate(canny[1:-1, 1:-1]):
2     if not e:
3         continue
4     u += 1
5     v += 1
    
```

$$\begin{aligned}
 d_x &= \begin{bmatrix} p_{-1-1} & p_{-10} & p_{-11} \\ p_{0-1} & p_{00} & p_{01} \\ p_{1-1} & p_{10} & p_{11} \end{bmatrix} \circ \begin{bmatrix} 0 & 0 & 0 \\ -1 & 0 & +1 \\ 0 & 0 & 0 \end{bmatrix} \\
 d_y &= \begin{bmatrix} p_{-1-1} & p_{-10} & p_{-11} \\ p_{0-1} & p_{00} & p_{01} \\ p_{1-1} & p_{10} & p_{11} \end{bmatrix} \circ \begin{bmatrix} 0 & -1 & 0 \\ 0 & 0 & 0 \\ 0 & +1 & 0 \end{bmatrix}
 \end{aligned} \tag{4.1}$$

Zuerst die Gradienten d_x und d_y ermittelt. Dazu wird die 3×3 Pixelnachbarschaft des aktuellen Pixels elementweise mit dem jeweiligen Sobel-Kernel multipliziert und die Summe der Ergebnismatrix gebildet (siehe Gleichung 4.1). Das Pythonpaket `numpy` stellt hierfür sehr hilfreiche Funktion zum Arbeiten mit Matrizen zu Verfügung. Dadurch lässt sich diese Operation in wenigen Zeilen durchführen, wie Code 4.3 gezeigt.

Code 4.3: Bestimmung der Gradienten d_x und d_y

```

1 nh = img[u-1:u+2, v-1:v+2]
2 dx = np.sum(nh * SOBEL_X)
3 dy = np.sum(nh * SOBEL_Y)
    
```

Mit diesen werden nun die `atan2(dy,dx)` Funktion aufgerufen. Diese gibt einen Winkel in rad zurück, welcher zur besseren Nachvollziehbarkeit in Grad umgerechnet wird.

Nun werden durch eine Folge von Bedingungen die Klasse des aktuellen Pixels bestimmt. Zuerst wird das Vorzeichen bestimmt und im 5. Bit abgespeichert. Dies vereinfacht die folgenden Abfragen, da für die *Vertikale* und *Horizontale* Klasse der Betrag des Winkels ausreicht.

Ist die Klasse bestimmt, wird das entsprechende Bit des Pixels gesetzt. Die Umsetzung in Python ist in Code 4.4 gezeigt.

Code 4.4: Durchführen der Klassifizierung mittel des bestimmten Winkels

```
1 arc = atan2(dy, dx) / pi * 180
2
3 if arc < 0:
4     pixel_info[u, v] |= 0x10
5 arc = abs(arc)
6 if arc >= 157.5 or 22.5 > arc:
7     pixel_info[u, v] |= V
8 elif 22.5 <= arc < 67.5:
9     pixel_info[u, v] |= D1 if not pixel_info[u, v] else D2
10 elif 67.5 <= arc < 112.5:
11     pixel_info[u, v] |= H
12 elif 112.5 <= arc < 157.5:
13     pixel_info[u, v] |= D2 if not pixel_info[u, v] else D1
```

Wurde jeder Kantenpixel klassifiziert, ist der Vorgang beendet. Zur Veranschaulichung wurde ein Bild erstellt, wo jeder Klasse und Vorzeichen eine eindeutige Farbe zugeordnet ist. So ist genau zu erkennen, welche Kanten derselben Klasse zugeordnet wurden. Diese Bild ist in Abbildung 4.6 gezeigt.





Abb. 4.6: Klassifizierte Kanten mit farblicher Markierung der unterschiedlichen Klassen (Farben sind nicht identisch mit Abbildung 4.5)

Genauigkeit der Klassifizierung

Die Klassifizierung erfolgt leider nicht immer völlig zuverlässig. Gut klassifizierte Kanten haben für die gesamte Länge der Linie dieselbe Klasse erhalten wie es im vergrößerten Bildausschnitt Abbildung 4.7(a) zu sehen ist. Im Gegensatz dazu haben unzuverlässig klassifizierte Kanten mehrere Klassen in einem engen Bereich und wechseln häufig sogar mehrfach zwischen mehreren Klassen, wie das Beispiel in Abbildung 4.7(b) zeigt.

Durch Störungen und generell schlechtere Bildqualität in weiter von der Kamera entfernten Bildbereichen weisen vor allem die äußeren Linien viele dieser Ungenauigkeiten auf. Das führt dazu, dass die nachfolgende Logik viele einzelne, kleine Linien anstatt der vollständigen, durchgängigen Linie, erkennt.

Die zentralen Linienmarkierungen der eigenen Spur werden aber zuverlässig genug klassifiziert.



(a) Beispiel guter Kantenklassifizierung (b) Beispiel schlechter Kantenklassifizierung

Abb. 4.7: Vergleich gut und schlecht klassifizierte Bildbereiche

4.1.3 Linienbildung

Mit den Informationen über die Kantenklasse kann nun der eigentliche Prozess der Linienerkennung erfolgen. Dieser gliedert sich in zwei Schritte, das Zusammenfassen von gleich klassifizierten Kantenpixeln zu durchgängigen Linien und das Zusammenfassen von Linien zu einer Fahrspurmarkierung.

Für den ersten Schritt ist es ein weiteres mal nötig über das gesamte Bild zu iterieren. Auch diesmal können wieder alle schwarzen Pixel übersprungen werden. Wird ein klassifiziertes Pixel gefunden, muss überprüft werden, ob es sich um ein Startpixel handelt. Startpixel sind Pixel, die keine Nachbarn in der ihrer Klasse entsprechenden Ursprungsrichtung haben. Zum Beispiel wäre ein Pixel der *Vertikal* Klasse ein Startpixel, wenn sich direkt oder diagonal über ihm keine weiteren Pixel derselben Klasse befinden.

Ist ein Startpixel gefunden, wird es für später abgespeichert. Nun wird der Linie zu ihrem Ende gefolgt. Dazu wird der nächste Nachbapixel gesucht. Da die grobe Richtung entsprechend der Klasse bekannt ist, müssen hier nicht alle Nachbapixel überprüft werden. Beim Beispiel mit der *Vertikal* Klasse müssten die Pixel direkt und diagonal unterhalb betrachtet werden. Existiert ein Nachbar wird dieser ausgewählt und der Prozess wiederholt. Dabei werden alle bereits besuchten Pixel aus dem Bild gelöscht, damit sich nicht noch einmal untersucht werden.

Code 4.5: Verfolgen einer Linie vom Start- zum Endpunkt

```
1 start = (u, v)
2 relevant_nh *= -1
3
4 while True:
5     pixel_info[u, v] = 0
6     for x, y in relevant_nh:
7         if e == pixel_info[u+x, v+y] & 0x0f:
8             u, v = u+x, v+y
9             break
10        else: # no more neighbours
11            break
12
13 l = Line(start, (u, v), info)
14 if l.length > 5:
15     lines.append(l)
```

Hat ein Pixel keine weiteren Nachbarn, ist er der Endpunkt dieser Linie. Start und Endpunkt werden in ein Linienobjekt zusammengefasst und abgespeichert. Zusätzlich wird ebenfalls die Orientierungsklasse mit abgespeichert.

Mittels Start- und Endpunkt kann außerdem die Länge der Linie bestimmt werden. Da durch die in Unterunterabschnitt 4.1.2 beschriebenen Störungen viele kurze Linien gefunden werden, deren Berücksichtigung zu viel Rechenzeit in Anspruch nehmen würde, werden Linien unter einer Minimallänge von 5 Pixeln vernachlässigt.

Akzeptierte Linien werden ihrer Orientierung entsprechen in einzelnen Listen abgespeichert, sodass am Ende eine Liste für jede Orientierungsklasse entstanden ist.

Da ein Linienmarker immer aus einer linken und einer rechten Kante besteht, können wir diese durch Bilden von Linienpaaren gleicher Orientierung, aber unterschiedlichem Vorzeichen, die in geringem Abstand zueinander liegen, identifizieren.

Dazu werden die Elemente der entsprechenden Listen nacheinander miteinander verglichen, bis ein passendes Paar gefunden wurde. Ein Beispiel ist in Code 4.6 für Linienmarkierungen der Orientierung *Digital 1* gezeigt. Es wird für jeden Kandidaten aus der ersten Liste ein Partner in der zweiten Liste gesucht. Ein solcher ist gefunden, wenn die Start- und Endpunkte beider Linien innerhalb bestimmter Bereiche liegen.

Code 4.6: Finden von Linienpaaren in Python

```
1 for a in left_D1_edges:
2     for b in right_D1_edges:
3         if (
4             (a.start[0] - 20) < b.start[0] < (a.start[0] + 20) and
5             a.start[1] < b.start[1] < (a.start[1] + 30) and
6             (a.end[0] - 20) < b.end[0] < (a.end[0] + 20) and
7             a.end[1] < b.end[1] < (a.end[1] + 20)
8         ):
9             markings_found.append(LineMarking(a,b, "left"))
10            right_D1_edges.remove(b)
11            break
```

Die gefundenen Linienpaare werden zu einem Linienmarker Objekt zusammengefasst. In diesem wird der Umriss bestehend aus den vier Linienpunkten abgespeichert. Außerdem wird der Mittelwert der beiden Start- und Endpunkte gebildet und somit die Mittellinie des Linienmarkers angenähert.

So gefundene Linienmarker lassen sich wieder im Beispielbild markieren, wodurch sich Abbildung 4.8 ergibt. Wie man dort sehen kann, wurden die Linienmarker der eigenen linken und rechten Fahrspurbegrenzung erfolgreich identifiziert. Weitere Markierungen anderer Spuren konnten aufgrund der unzuverlässigen Klassifizierung nicht erkannt werden.




Abb. 4.8: Umrisse und Mittellinien der gefundenen Fahrspurmarkierungen

Komplexere Szenen

Nicht jede Situation, auf die der Roboter treffen kann, führt zu so guten Ergebnissen wie das gezeigte Beispiel. Daher sind in Abbildung 4.9 einige weitere Beispiele und die darin detektierten Markierungen im direkten Vergleich gezeigt.

In 4.9(a) sind die Linienbegrenzungen nahe am Fahrzeug durchgezogen und werden erst in größerer Entfernung gestrichelt. Hier war die Erkennung der durchgezogenen Teile sehr gut möglich, jedoch kam es zu einer unpräzisen Identifizierung im oberen Teil der rechten Linie, da sich zwei Liniensegmente unterschiedlicher Linien zu nahe aneinander befanden.

Bei der Szene 4.9(b) handelt es sich um eine Kurve. Dies erschwert die Erkennung deutlich, da eine durchgängige Klassifizierung einer Kante nicht garantiert ist. Daher sind auch nicht alle Spurmarkierungen identifiziert.

Der letzte Vergleich 4.9(c) zeigt eine Szene mit vollständig durchgezogener Linie. Dies ist aus dem Grund schwierig, dass die Wahrscheinlichkeit einer Störung durch die hohe Pixelanzahl sehr groß ist. Daher wurde die rechte Kante der Linie auch nicht durchgängig erkannt und der gefundene Marker wirkt verzehrt.




Abb. 4.9: Ergebnisse bei komplexeren Szenen im Vergleich

4.2 Implementierung in eine ROS Node

Um den Spurmarkererkennungs-Algorithmus auf jedes Kamerabild anwenden zu können, wird er in einer Node umgesetzt. Da der Python-Code bereits auf einem leistungsfähigen Entwickler-PC Laufzeiten von $> 0,25$ s hat, wird diese im C++ implementiert. Dies wird die Performance deutlich verbessern.

Die Beziehung der neuen Node zu den bestehenden Nodes wurde bereits in Abbildung 4.1 skizziert. Dort sieht man, dass die Node mit dem Namen `lane_marker_detection` initialisiert wird. Außerdem wird das Topic `/img/gray` von der Entzerrer-Node abonniert, um jedes Schwarz-Weiß Bild zu bekommen. Das Bild mit den eingezeichneten, detektierten Spurmarkern wird nach Durchlauf des Algorithmus auf dem eigenen Topic `/img/lanemarkings` veröffentlichte.

Beim Abonnieren des `/img/gray` Topics wird die Callback-Funktion `callback_image()` angehängt, sodass diese von ROS für jedes Bild aufgerufen und das Bild an sie übergeben wird. Da dieses in einem ROS eigenen Bild-Datentyp übergeben wird, OpenCV diesen aber nicht verwenden kann, ist es nötig das Bild zuerst einmal in einen anderen Datentyp umzuwandeln. Hierzu wird wieder das ROS-Paket `cv_bridge` und dessen Funktion `toCvCopy()` verwendet.

Kantenerkennung und Klassifizierung

Das so konvertierte Bild kann nun an die Funktion `edgeDetectionClassification()` übergeben werden, welche die Erkennung und Klassifizierung der Kanten durchführt. Wie bereits in der Python-Version wird wieder der Canny-Edge-Detektor aus OpenCV verwendet. Dadurch können die Parameter einfach übernommen werden. Der Code 4.7 zeigt den Aufruf. Das Ergebnis mit den detektierten Kanten wird in der Variable `canny` abgespeichert.

Code 4.7: Aufruf des Canny-Edge-Detektor in C++

```
1 cv::Mat canny;  
2 cv::Canny(image, canny, 180, 50);
```

Die Implementierung der Kantenklassifizierung in C++ läuft im groben sehr ähnlich zur Python, die wichtigsten Unterschiede sind die For-Schleifen für beide Dimensionen des Bildes, welche explizit einzeln verwendet werden müssen, und die Beachtung von Datentypen. Die Erstellung des benötigten, leeren Bildes und die For-Schleifen sind in Code 4.8 zu sehen. Auch hier werden wieder alle leeren Pixel übersprungen.

Code 4.8: Initialisieren des leeren Bildes und iteriert über jenes.

```
1 cv::Mat classified_edges =  
    cv::Mat::zeros(cv::Size(image.cols, image.rows), CV_8U);  
2 for (int u=1; u < image.rows-1; u++) {  
3     for (int v=1; v < image.cols-1; v++) {  
4         if ( ! canny.at<uint8_t>(u,v) )  
5             continue;
```

Die Bestimmung der Gradienten mittels Sobel wirkt in C++ deutlich komplizierter, da hier vieles manuell gemacht werden muss, was in Python von `numpy` erledigt wurde. Mit zwei For-Schleifen wird über die 3×2 Pixelnachbarschaft iteriert, die Elemente mit dem Kernel multipliziert und aufsummiert, wie in Code 4.9 zu sehen.

Code 4.9: Bestimmung der Gradienten mittels Sobel

```
1 uint8_t e;  
2 int dx=0, dy=0;  
3 for (int y=0; y<3; y++) {  
4     for (int x=0; x<3; x++) {  
5         e = image.at<uint8_t>(u+y-1, v+x-1);  
6         dx += SOBEL_X[y*3+x] * e;  
7         dy += SOBEL_Y[y*3+x] * e;  
8     }  
9 }
```

Die eigentliche Klassifizierung ist praktisch identisch zur Python-Version. Lediglich die Überprüfung der Winkelbereiche ist etwas langwieriger, da nicht mehrere Vergleiche direkt nacheinander möglich sind. Die Codierung der Klassen erfolgt wieder über die einzelnen Bit des Bytes der einzelnen Pixel. Wie es implementiert ist, ist in Code 4.10 dargestellt.

Das Ergebnisbild mit den klassifizierten Pixeln wird von der Funktion zurückgegeben und dort weiterverarbeitet.

Code 4.10: Bestimmung der Gradienten mittels Sobel

```
1 double arc = atan2(dy,dx) / 3.1415 * 180.0;
2
3 uint8_t clsif = 0;
4 if (arc < 0)
5     clsif = 0x10;
6 arc = fabsf(arc);
7
8 if (arc<=22.5f || arc>157.5f ) {
9     clsif |= V;
10 } else if ( 67.5f<=arc && arc<112.5f ) {
11     clsif |= H;
12 } else if (( !clsif && arc<67.5f )||( clsif && 112.5f<=arc )) {
13     clsif |= D1;
14 } else if (( clsif && arc<67.5f )||( !clsif && 112.5f<=arc )) {
15     clsif |= D2;
16 }
17 classified_edges.at<uint8_t>(u,v) = clsif;
```

Linienbildung

Mit dem klassifizierten Bild kann nun dieselbe Methodik zur Identifizierung zusammenhängender Linien wie in Python angewendet werden. Allerdings ist in C++ das Definieren und Testen der relevanten Pixelnachbarschaft nicht so übersichtlich möglich wie in Python. Daher müssen viele lange if Bedingungen verwendet werden, welche in den folgenden Codebeispielen zur Übersichtlichkeit verkürzt sind.

Begonnen wird wieder mit einer doppelten For-Schleife über das gesamte Bild, wie in Code 4.11 zu sehen. Dabei werden wieder alle leeren Pixel vernachlässigt.

Code 4.11: For-Schleifen über alle Klassifizierten Pixel

```
1 for (int u=1; u < classified_edges.rows-1; u++) {
2     for (int v=1; v < classified_edges.cols-1; v++) {
3         uint8_t clsif_org = classified_edges.at<uint8_t>(u,v);
4         if ( ! clsif_org )
5             continue;
```

Für jeden Pixel wird wieder überprüft, ob er ein Startpixel ist. Genau wie in Python ist hierfür wieder der Klasse entsprechend eine Pixelnachbarschaft relevant. Ist dort ein Nachbar gleicher Klasse vorhanden, wird mit dem nächsten Pixel weitergemacht. Dies ist in Code 4.12 gezeigt. Ist ein Startpixel gefunden, wird er gespeichert und wieder so lange der nächste Nachbar ausgewählt, bis kein Nachbar mehr vorhanden ist. Dann ist die gesamte Linie nachverfolgt. Dabei werden alle besuchten Pixel aus dem Bild gelöscht. Siehe dazu Code 4.13.

Code 4.12: Überprüfen, ob ein Pixel ein Startpixel ist

```
1 // get only classification without direction:
2 uint8_t clsif = 0x0f & clsif_org;
3 bool has_neighbour = false;
4 switch (clsif) {
5     case V:
6         if ( /* any of the relevant neighbours */ )
7             has_neighbour = true;
8     case D1:
9         if ( /* any of the relevant neighbours */ )
10            has_neighbour = true;
11     case H:
12         if ( /* any of the relevant neighbours */ )
13            has_neighbour = true;
14     case D2:
15         if ( /* any of the relevant neighbours */ )
16            has_neighbour = true;
17 }
18 if ( has_neighbour )
19     continue;
```

Code 4.13: Line verfolgen, bis keine Nachbarn mehr existieren

```
1 pnt start(v,u);
2 // follow line to its end
3 do {
4     classified_edges.at<uint8_t>(u,v) = 0;
5     has_neighbour = false;
6     switch (clsif) {
7         case V:
8             if ( /* any neighbour existis */ )
9                 // u+-;v+-; change u,v to new coordinates
10                has_neighbour = true;
11         case D1:
12             if ( /* any neighbour existis */ )
13                 // u+-;v+-; change u,v to new coordinates
14                has_neighbour = true;
15         case D2:
16             if ( /* any neighbour existis */ )
17                 // u+-;v+-; change u,v to new coordinates
18                has_neighbour = true;
19         }
20         case H:
21             if ( /* any neighbour existis */ )
22                 // u+-;v+-; change u,v to new coordinates
23                has_neighbour = true;
24     }
25 } while ( has_neighbour );
```

Die so gefunden Linien werden wieder auf ihre Länge überprüft und als Objekte abgespeichert. Dabei werden einzelne Listen für jede Klasse angelegt, sodass diese Später verglichen werden können.

Besonders wichtig ist es, dass im Gegensatz zu Python die Schleifenvariablen u, v manuell wieder auf die Startkoordinaten zurückgesetzt werden müssen.

Paarbildung

Auch die Bildung von Linienpaaren aus einer rechten und linken Linie Erfolg analog zu Python. Hier gibt es auch keine großartigen Unterschiede in der Umsetzung, wie Code 4.14 zu sehen ist.

Code 4.14: Line verfolgen, bis keine Nachbarn mehr existieren

```
1 for(const Line& a : left_D1_edges) {
2     for(auto it = right_D1_edges.begin(); it !=
3         right_D1_edges.end(); it++) {
4         const Line b = *it;
5         if (
6             ( a.start.y - 10 < b.start.y && b.start.y < a.start.y
7               + 10 ) &&
8             ( a.start.x < b.start.x && b.start.x < a.start.x + 25
9               ) &&
10            ( a.end.y - 10 < b.end.y && b.end.y < a.end.y + 10 ) &&
11            ( a.end.x < b.end.x && b.end.x < a.end.x + 25 )
12        ) {
13            markings_found.push_back(LineMarking(a,b, D1));
14            left_D1_edges.erase(it);
15            break;
16        }
17    }
18 }
```

4.2.1 Performance Betrachtung

Mit dieser zusätzlichen Node ist es erneut interessant, wie sich diese auf die Performance auswirkt. Aus Abschnitt 3.1 ist ja bereits die Performance mit laufender Kamera- und Entzerrer-Node bekannt. Zum Vergleich wurde wieder die Systemauslastung, insbesondere die der CPU, mit dem Programm jtop aufgenommen. Dies ist in Abbildung 4.10 Abgebildet.

Abb. 4.10: CPU Auslastung des JetBots mit laufender Kamera, Entzerrung
und Markierungserkennung

Robo will nicht booten...

Die Performance der C++ implementiert ist wie erwartet deutlich besser als bei der Python-Version. Vom Erhalt des Bildes bis zur Veröffentlichung des Ergebnisses mit den gefundenen Linienmarkierungen dauert es

Tab. 4.2: Gemessene Laufzeit bei 10 Durchläufen der Callback-Funktion

Durchlauf Nr.	gemessene Laufzeit
1	3,885 ms
2	4,068 ms
3	3,969 ms
4	3,712 ms
5	3,970 ms
6	4,086 ms
7	4,025 ms
8	3,897 ms
9	3,753 ms
10	4,096 ms

ist die Tabelle überhaupt sinnvoll?

5 Fazit

Die Arbeit hatte zum Ziel, die auf dem JetBot existierende Bilderfassung zu verbessern und mit einer Erkennung von Fahrspurmarkierungen in Echtzeit auszustatten.

Durch eine intrinsische Kalibrierung der Kamera und das Erstellen einer Node, welche diese Kalibrierung anwendet, konnte das von der Kamera erhaltene Bild deutlich verbessert und vorhandenen Verzerrungen korrigiert werden. Insbesondere die radiale Verzerrung, die gerade Linien wie zum Beispiel Fahrspurmarkierungen im Bild gekrümmt erscheinen lässt, konnte annähernd vollständig entfernt werden. Dies verbesserte die Voraussetzungen für die nachfolgenden Schritte.

Außerdem wurde die Erkennung der Fahrspurmarkierungen erfolgreich implementiert. Der Algorithmus wurde in der Programmiersprache Python entwickelt und getestet, wobei insbesondere die einfache Syntax und gute Debuggmöglichkeiten das Vorgehen vereinfacht haben. Da Python aber nicht performant genug war, um die Echtzeitanforderung zu erfüllen, wurde die eigentliche Implementierung in C++ umgesetzt. Dadurch wurde die Laufzeit des Programms deutlich beschleunigt und die Echtzeitfähigkeit gewährleistet.

Die Erkennung von Fahrspurmarkierungen wurde mittels Kantenerkennung durch einen Canny-Edge-Detektor und Klassifizierung der einzelnen Kantenpixel entsprechend ihrer Orientierung umgesetzt. So ließen sich aus den Kanten erfolgreich zusammenhängende Linien einer Orientierung ableiten und deren Start- und Endpunkte abspeichern. Durch Paarbildung zwischen rechten und linken Linien konnten dann Rückschlüsse über einzelne Fahrspurmarkierungen gezogen werden. Die vier Punkte eines Linienpaares konnten dann als Kontur abgespeichert und die Mittellinie berechnet werden.

Zur Veranschaulichung wurden die Konturen in ein leeres Bild eingezeichnet und dieses ebenfalls veröffentlicht. Dadurch ist ein direkter Vergleich zwischen Originalbild und gefundenen Konturen in Echtzeit möglich.

6 Ausblick

Die grundsätzliche Erkennung von Linienmarkierungen im Bilddatenstrom konnte erfolgreich umgesetzt werden. Jedoch bestehen in mehreren Bereichen des Programmes noch Weiterentwicklungsmöglichkeiten. Dadurch könnte die Erfassungsgenauigkeit insbesondere in schwierigen Situationen erhöht und weitere Informationen gewonnen werden.

Mehr Orientierungsklassen

Derzeit wird bei der Klassifizierung der Kantenpixel lediglich in vier unterschiedliche Klassen eingeteilt. Das kann insbesondere bei Kurven zu dem Problem führen, dass die Klassifizierung innerhalb einer Kante plötzlich wechselt und so zwei unterschiedliche Linien auf derselben Kante erfasst werden.

Durch mehr Klassen und Berücksichtigung von benachbarten Klassen in der Linienverfolgung ließen sich potenziell auch gekrümmte Linien verfolgen.

Reduzierung von Falschklassifizierungen

Dies ist möglicherweise bereits teilweise durch den vorherigen Punkt mit abgedeckt, bedarf aber trotzdem einer weiteren Erklärung. Derzeit werden vor allem bei weiter von der Kamera entfernten Linien, also vor allem den Spurmarkierungen benachbarter Spuren, viele Fehlklassifizierungen durchgeführt. Wie in Abbildung 4.7(b) gezeigt wird eine Kante durch fehlerklassifizierte Pixel unterbrochen, sodass eine durchgängige Linienverfolgung nicht möglich ist.

Hier könnten zuerst einmal Ansätze zum Verbinden von sehr eng zusammen liegenden Linien Abhilfe schaffen. Aber eine Verbesserung der Genauigkeit bei der Klassifizierung wäre ebenfalls denkbar.

Datenübergabe an weitere Prozesse

Da diese Arbeit als Grundlage für weitere Prozesse, z.B. zum autonomen Einhalten der Spur beim Fahren, müsste die genaue Methode zur Datenübergabe festgelegt werden. Zurzeit wird ein weiteres Bild mit den eingezeichneten Fahrspurmarkierung veröffentlicht, weitere Prozesse benötigen aber die erzeugten Objekte mit den enthaltenen Informationen.

Diese liegen vor und können über die definierte Headerdatei genutzt werden, es findet aber noch keine Übertragung mittels ROS statt. Diese müsste bei Bedarf eingerichtet werden.

noch was?

Literatur

- [Can86] John Canny. „A Computational Approach to Edge Detection“. eng. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence* PAMI-8.6 (1986), S. 679–698. DOI: 10.1109/TPAMI.1986.4767851.
- [Fra+09] Barbara Frank u. a. *Robotics 2 - Camera Calibration*. eng. 2009. URL: <http://ais.informatik.uni-freiburg.de/teaching/ws09/robotics2/pdfs/rob2-08-camera-calibration.pdf> (besucht am 19.07.2022).
- [Han11] Tobias Hanning. *High Precision Camera Calibration*. eng. 1. Aufl. Vieweg+Teubner, 2011. 225 S. DOI: 10.1007/978-3-8348-9830-2.
- [Hom21] Prof. Dr.-Ing. Hanno Homann. *Script: Vorlesung Bildverarbeitung*. ger. Moodle, Open Source Lernplattform der Hochschule Hannover. Stand: WiSe 2021/22. 2021.
- [KK15] Gurveen Kaur und Dinesh Kumar. „Lane Detection Techniques: A Review“. eng. In: *International Journal of Computer Applications* 112.10 (2015), S. 4–8. URL: <https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.695.9070&rep=rep1&type=pdf> (besucht am 01.09.2022).
- [Lop+05] A. Lopez u. a. „Detection of lane markings based on ridgeness and RANSAC“. eng. In: *Proceedings. 2005 IEEE Intelligent Transportation Systems, 2005*. 2005, S. 254–259. DOI: 10.1109/ITSC.2005.1520139.
- [Lu+19] Jingyan Lu u. a. „A Lane Detection Method Based on a Ridge Detector and Regional G-RANSAC“. eng. In: *Sensors* 19 (Sep. 2019), S. 4028. DOI: 10.3390/s19184028.
- [Mat22] MathWorks. *What Is Camera Calibration? - MATLAB & Simulink - MathWorks Deutschland*. eng. 2022. URL: <https://de.mathworks.com/help/vision/ug/camera-calibration.html> (besucht am 19.07.2022).
- [Nis+12] Alfred Nischwitz u. a. *Computergrafik und Bildverarbeitung. Band I: Computergrafik*. ger. 3. Aufl. Studium. Wiesbaden: Vieweg+Teubner, 2012. 1 online resource. DOI: 10.1007/978-3-8348-8323-0.
- [Ope22a] OpenCV. *Homepage - Open Source Computer Vision Library*. eng. 27. Juli 2022. URL: <https://opencv.org/> (besucht am 12.08.2022).
- [Ope22b] OpenCV. *Python-Tutorials: Camera Calibration*. eng. 17. Juli 2022. URL: https://docs.opencv.org/4.6.0/dc/dbb/tutorial_py_calibration.html (besucht am 09.08.2022).
- [Rob18] Open Robotics. *ROS 2 Documentation - Introduction*. eng. 8. Aug. 2018. URL: <http://wiki.ros.org/ROS/Introduction> (besucht am 14.08.2022).
- [Rob22] Open Robotics. *Homepage - Robot Operating System*. eng. 2022. URL: <https://www.ros.org/> (besucht am 15.08.2022).
- [Spa22] Sparkfun. *Assembly Guide for SparkFun JetBot AI Kit V2.0*. eng. 2022. URL: <https://learn.sparkfun.com/tutorials/assembly-guide-for-sparkfun-jetbot-ai-kit-v20> (besucht am 15.07.2022).

- [WHF05] Chun-Che Wang, Shih-Shinh Huang und Li-Chen Fu. „Driver assistance system for lane detection and vehicle recognition with night vision“. In: *2005 IEEE/RSJ International Conference on Intelligent Robots and Systems*. 2005, S. 3530–3535. DOI: 10.1109/IR0S.2005.1545482.
- [Wik22] Wikipedia. *Verzeichnung* — *Wikipedia, die freie Enzyklopädie*. ger. 2022. URL: <https://de.wikipedia.org/w/index.php?title=Verzeichnung&oldid=223280815> (besucht am 12.07.2022).
- [Wil22a] Jan Wille. *VideoDriveWorkspace Wiki: example data sets - intrinsische kalibrierung down4*. 15. Juni 2022. URL: https://lab.it.hs-hannover.de/p9r-rxm-u1/videodrive_ws/-/wikis/uploads/6c853b3f41964eccd6671954a07ad5ed/intrinsicCalibration_down4.zip (besucht am 19.06.2022).
- [Wil22b] Jan Wille. *VideoDriveWorkspace Wiki: example data sets - straßen leer down4*. 15. Juni 2022. URL: https://lab.it.hs-hannover.de/p9r-rxm-u1/videodrive_ws/-/wikis/uploads/c8e09d2f28a2279b9b76cd899c383cc9/stra%C3%9Fen_leer_down4.zip (besucht am 19.06.2022).

Abbildungsverzeichnis

2.1	Generischer Ablauf von Fahrspurerkennung (nach [KK15])	2
2.2	SparkFun JetBot AI Kit V2.1 [Spa22]	4
2.3	CPU Auslastung des JetBots ohne ROS	5
2.4	CPU Auslastung mit laufender Kamera und ROS-Core	5
3.1	Unkalibriertes Kamerabild mit tonnenförmiger Verzeichnung	6
3.2	Darstellung der optischen Verzerrung (nach [Wik22])	7
3.3	Probleme in der Ausrichtung von Sensor und Linse (nach [Mat22])	7
3.4	Schachbrett Kalibrieremuster mit markierten inneren Kreuzungen	8
3.5	Schritte der intrinsischen Kalibrierung	10
3.6	Beziehungen der entzerrer Node zu bestehenden Nodes	11
3.7	CPU Auslastung des JetBots mit laufender Kamera und entzerrer Node	14
4.1	Zusammenhang der Fahrspurmarkierung-Erkennungs Node mit den bestehen- den Nodes	15
4.2	Ablauf des Algorithmus zur Erkennung von Fahrspurmarkierungen	16
4.3	Ein Beispiel Bild an dem der Ablauf demonstriert wird	17
4.4	Vom Canny-Edge-Detector gefundene Kanten	18
4.5	Klassifizierung der Gradientenorientierung (nach [Hom21])	18
4.6	Klassifizierte Kanten mit farblicher Markierung der unterschiedlichen Klassen (Farben sind nicht identisch mit Abbildung 4.5)	20
4.7	Vergleich gut und schlecht klassifizierte Bildbereiche	21
4.8	Umrisse und Mittellinien der gefundenen Fahrspurmarkierungen	22
4.9	Ergebnisse bei komplexeren Szenen im Vergleich	23
4.10	CPU Auslastung des JetBots mit laufender Kamera, Entzerrung und Markie- rungserkennung	27

Tabellenverzeichnis

3.1	Gemessene Laufzeit bei 10 Durchläufen der Callback-Funktion	14
4.1	Zuordnung der Klassen zu Bits	19
4.2	Gemessene Laufzeit bei 10 Durchläufen der Callback-Funktion	28

Codeverzeichnis

3.1	Definiteion der Größe des Kalibriermuster	8
3.2	Initialisierung von Variablen für die Kalibrierung	9
3.3	Finden und Verarbeiten der Kalibrierbilder	9
3.4	Abspeichern der Gefundenen Bildpunkte	9
3.5	Ermitteln der Kalibrierwerte mittels OpenCV	10
3.6	Berechnen des Reprojektions-Fehlers	11
3.7	Einlesen der Kalibrierungsergebnisse aus einer YAML-Datei	12
3.8	Bestimmen der Pixel-Mappings zu Entzerrung	13
3.9	Vereinfachte Version der Callback-Funktion zur Durchführung der Entzerrung	13
4.1	Laden, glätten eines Bildes und durchführen der Kantenerkennung mit OpenCV	17
4.2	Schleife über das vom Canny-Edge-Detektor gelieferte Bild	19
4.3	Bestimmung der Gradienten d_x und d_y	19
4.4	Durchführen der Klassifizierung mittel des bestimmten Winkels	20
4.5	Verfolgen einer Linie vom Start- zum Endpunkt	21
4.6	Finden von Linienpaaren in Python	22
4.7	Aufruf des Canny-Edge-Detektor in C++	24
4.8	Inizialisieren des leeren Bildes und iteriert über jenes.	24
4.9	Bestimmung der Gradienten mittels Sobel	24
4.10	Bestimmung der Gradienten mittels Sobel	25
4.11	For-Schleifen über alle Klassifizierten Pixel	25
4.12	Überprüfen, ob ein Pixel ein Startpixel ist	26
4.13	Line verfolgen, bis keine Nachbarn mehr existieren	26
4.14	Line verfolgen, bis keine Nachbarn mehr existieren	27