



Masterarbeit

Differenzanalyse von synthetischen und realen Wetterphänomenen in RGB-Bilddaten

Theresa Maienschein

theresa.maienschein@ovgu.de

1. Oktober 2025

Erstprüfer:

Prof. Dr. Bernhard Preim

Zweitprüfer:

Dr.-Ing. Stefan Krause

Betreuer:

Rebecca Schmidt

Kurzfassung

Eine korrekte Umweltwahrnehmung ist für autonome Fahrzeuge entscheidend. Wetterbedingungen wie Regen oder Nebel können die Leistungsfähigkeit von Sensoren in Umweltwahrnehmungssystemen jedoch erheblich beeinträchtigen. Damit diese Systeme dennoch unter allen Bedingungen zuverlässig arbeiten, werden zunehmend virtuelle Tests eingesetzt. Derzeit fehlt jedoch eine belastbare Möglichkeit, die Realitätstreue solcher Simulationen nachzuweisen. Daher wird in der vorliegenden Arbeit werden Simulationen von Licht- und Regeneffekten in der Unreal Engine 5 für eine Differenzanalyse zwischen realen und simulierten Bildern berücksichtigt. Hierzu wird ein Datensatz realer Wetterbedingungen erhoben und in der Simulationsumgebung nachgebildet; die resultierenden Datensätze werden anschließend anhand definierter Metriken verglichen. Die Ergebnisse verdeutlichen, dass reale Wettereffekte durch komplexe Abhängigkeiten – etwa Tageszeit, Bewölkung und kamerainduzierte Einflüsse – geprägt sind, die in Simulationen berücksichtigt werden müssen, um phänomenologische Korrektheit zu erreichen. Zudem zeigt sich, dass die durchgeführte Differenzanalyse geeignet ist, Defizite in der Wettersimulation zu identifizieren.

Inhaltsverzeichnis

Abbildungsverzeichnis	VI
Tabellenverzeichnis	IX
Quellcodeverzeichnis	X
Abkürzungsverzeichnis	XI
1. Einleitung	1
2. Verwandte Arbeiten	4
2.1. Datensätze zur Umweltwahrnehmung bei schwierigen Wetterlagen	4
2.2. Wettersimulationen	5
2.3. Differenzanalysemethoden für den Vergleich von Bildern	6
3. Auswahl der Differenzanalysemethoden	10
3.1. Kategorie 1: Strukturunabhängige Bildmerkmale	11
3.2. Kategorie 2: Low-Level Feature Analyse	12
3.3. Kategorie 3: Pixel- und Wahrnehmungsähnlichkeit	12
3.4. Kategorie 4: Verteilungsähnlichkeit	13
3.5. Kategorie 5: Klassifikator- und Anwendungsbasiert	13
4. Grundlagen	14
4.1. Wetter	14
4.1.1. Regen	14
4.1.2. Lichteffekte bei klarem Wetter	16
4.2. Wettersimulationen in der Unreal Engine	17
4.2.1. Unreal Engine 5.3	17
4.2.2. Regeneffekte	17
4.2.3. Lichteffekte	17
4.3. Ausgewählte Differenzanalysemethoden	18
4.3.1. Helligkeit	18
4.3.2. Kontrast	18
4.3.3. Bildschärfe	19
4.3.4. Canny-Algorithmus	20
4.3.5. Shi-Tomasi Eckendetektion	20
4.3.6. RMSE	21
4.3.7. PSNR	21
4.3.8. SSIM	22
4.3.9. Klassifizierer mit ResNet	23

5. Generierung der realen und synthetischen Datensätze	24
5.1. Versuchsaufbau und Simulation	24
5.1.1. Kalibriermuster	24
5.1.2. Wetteraufzeichnungen	26
5.1.3. Realer Datensatz	28
5.1.4. Synthetischer Datensatz	32
5.1.5. Experiment zur Entfernungsbestimmung	38
5.2. Charakterisierung der Datensätze	39
6. Differenzanalyse der realen und synthetischen Daten	42
6.1. Strukturunabhängige Bildmerkmale	42
6.1.1. Helligkeit	43
6.1.2. Kontrast	45
6.1.3. Bildschärfe	47
6.2. Low-Level Feature Analyse	50
6.2.1. Kantendetektion	51
6.2.2. Eckendetektion	56
6.3. Pixel- und Wahrnehmungsähnlichkeit	60
6.3.1. NRMSE	60
6.3.2. PSNR	61
6.3.3. SSIM	63
6.4. Klassifikator- und Anwendungsbasiert	64
6.4.1. Cross-Dataset Generalisierung	65
6.4.2. Real/Synthetisch Klassifizierer	68
7. Auswertung und Diskussion der Differenzanalyse	71
7.1. Strukturunabhängige Bildmerkmale	71
7.1.1. Helligkeit	71
7.1.2. Kontrast	74
7.1.3. Bildschärfe	77
7.1.4. Zusammenhang der Ergebnisse für Methoden der einfachen Statistik .	78
7.2. Low-Level Feature Analyse	78
7.2.1. Kantendetektion	78
7.2.2. Eckendetektion	81
7.2.3. Zusammenhang der Ergebnisse für Methoden der Low-Level Feature Analyse	82
7.3. Pixel- und Wahrnehmungsähnlichkeit	82
7.3.1. NRMSE	82
7.3.2. PSNR	83
7.3.3. SSIM	83
7.3.4. Zusammenhang der Ergebnisse für Methoden der Pixel- und Wahrneh- mungsähnlichkeit	84
7.4. Klassifikator- und Anwendungsbasiert	85
7.4.1. Cross-Dataset Generalisierung	85
7.4.2. Real/Synthetisch Klassifizierer	86
7.4.3. Zusammenhang der Ergebnisse für klassifikator- und anwendungsba- sierte Methoden	87
7.5. Limitationen der Differenzanalyse	87

8. Zusammenfassung & Ausblick	89
8.1. Beitrag der Arbeit	89
8.2. Ausblick	90
Literaturverzeichnis	92
A. Appendix	98
A.1. Abbildungen	98
A.2. Tabellen	107
A.3. Quellcodeausschnitte	115

Abbildungsverzeichnis

4.1.	Beispiele für die in dieser Arbeit berücksichtigten Effekte durch Regen.	16
5.1.	Kalibriermuster mit vier Bereichen (Schachbrettmuster, Farbskalen + TV-Linien, Hexagonmuster, Bereich mit zusätzlichen Mustern für weitere Testmöglichkeiten)	25
5.2.	Praktischer Versuchsaufbau zur Generierung des realen Datensatzes (1,5*1,5m große Aluplatte mit Kalibriermuster, GoPro HERO11 Black als Kamera)	28
5.3.	Kalibriermuster zu verschiedenen Tageszeiten mit ausgewählten, tageszeitabhängigen Effekten bei klarem Wetter.	29
5.4.	Kalibriermuster mit durch Sonnenschein bedingten Schattenwurf auf einem Bild mit Regeneffekten.	30
5.5.	Simulationsumgebung (Nachbildung des realen Versuchsaufbaus) zur Generierung des synthetischen Datensatzes	37
6.1.	Histogramme für die Helligkeit der Bilder der zugeschnittenen Varianten der Datensätze Real-Angabe für klares Wetter im METAR Format / englisch: Ceiling, Clouds and Visibility OK (CAVOK), Real-Regen, Sim-CAVOK und Sim-Regen-Datensatz 0.	43
6.2.	Helligkeit der Bilder in Abhängigkeit von der Uhrzeit (blau: CAVOK Bilder; orange: Regen Bilder).	44
6.3.	Histogramme für den Kontrast der Bilder der zugeschnittenen Varianten der Datensätze Real-CAVOK, Real-Regen, Sim-CAVOK und Sim-Regen-Datensatz 0.	45
6.4.	Kontrast der Bilder in Abhängigkeit von der Uhrzeit (blau: CAVOK Bilder; orange: Regen Bilder).	46
6.5.	Histogramme für die MLV Bildschärfe der Bilder der zugeschnittenen Varianten der Datensätze Real-CAVOK, Real-Regen, Sim-CAVOK und Sim-Regen-Datensatz 0.	47
6.6.	MLV Bildschärfe der Bilder in Abhängigkeit von der Uhrzeit (blau: CAVOK Bilder; orange: Regen Bilder).	49
6.7.	Gestapeltes Histogramm für die MLV Bildschärfe von Bildern unter den speziellen Wetterbedingungen: Schatten auf dem Kalibriermuster bei CAVOK, Schatten auf dem Kalibriermuster bei Regen und Regentropfen auf der Linse	49
6.8.	Laplace Bildschärfe Diagramme mit abweichenden Ergebnissen zu denen der MLV Bildschärfe. Linkes Diagramm: Bildschärfe in Abhängigkeit von der Uhrzeit (blau: CAVOK Bilder; orange: Regen Bilder); Rechtes Diagramm: Gestapeltes Histogramm von Bildern unter den speziellen Wetterbedingungen: Schatten auf dem Kalibriermuster bei CAVOK, Schatten auf dem Kalibriermuster bei Regen und Regentropfen auf der Linse.	50
6.9.	Reales Regenbild mit den meisten Kanten(pixel) von allen Bildern aus den gegebenen Datensätzen und die dazugehörige Darstellung der erkannten Kanten und Ecken.	51

6.10. Histogramme für die Kantenpixelanzahl der Bilder der zugeschnittenen Varianten der Datensätze Real-CAVOK, Real-Regen, Sim-CAVOK und Sim-Regen-Datensatz 0.	52
6.11. Kantenpixelanzahl der Bilder in Abhängigkeit von der Uhrzeit (blau: CAVOK Bilder; orange: Regen Bilder).	53
6.12. Gestapeltes Histogramm für die Kantenpixelanzahl von Bildern unter den speziellen Wetterbedingungen: Schatten auf dem Kalibriermuster bei CAVOK, Schatten auf dem Kalibriermuster bei Regen und Regentropfen auf der Linse	54
6.13. Histogramme für die Kantenanzahl der Bilder der zugeschnittenen Varianten der Datensätze Real-CAVOK, Real-Regen, Sim-CAVOK und Sim-Regen-Datensatz 0.	55
6.14. Kantenanzahl der Bilder in Abhängigkeit von der Uhrzeit (blau: CAVOK Bilder; orange: Regen Bilder).	56
6.15. Synthetisches CAVOK Bild mit auffällig vielen Ecken und die dazugehörige Darstellung der erkannten Ecken, sowie das korrespondierende reale CAVOK Bild.	57
6.16. Histogramme für die Eckenanzahl der Bilder der zugeschnittenen Varianten der Datensätze Real-CAVOK, Real-Regen, Sim-CAVOK und Sim-Regen-Datensatz 0.	58
6.17. Eckenanzahl der Bilder in Abhängigkeit von der Uhrzeit (blau: CAVOK Bilder; orange: Regen Bilder).	59
6.18. Gestapeltes Histogramm für die Eckenanzahl von Bildern unter den speziellen Wetterbedingungen: Schatten auf dem Kalibriermuster bei CAVOK, Schatten auf dem Kalibriermuster bei Regen und Regentropfen auf der Linse	59
6.19. Histogramme für NRMSE der realen und simulierten Bildpaare zwischen Regen und CAVOK Bilder.	61
6.20. NRMSE der Bildpaare in Abhängigkeit von der Uhrzeit (blau: reale Bildpaare; orange: simulierte Bildpaare).	61
6.21. Histogramme für PSNR der realen und simulierten Bildpaare zwischen Regen und CAVOK Bilder.	62
6.22. PSNR der Bildpaare in Abhängigkeit von der Uhrzeit (blau: reale Bildpaare; orange: simulierte Bildpaare).	62
6.23. Outlier Bildpaar mit SSIM von 0,254.	63
6.24. Histogramme für SSIM der realen und simulierten Bildpaare zwischen Regen und CAVOK Bilder.	63
6.25. SSIM der Bildpaare in Abhängigkeit von der Uhrzeit (blau: reale Bildpaare; orange: simulierte Bildpaare).	64
6.26. Vergleich der Ergebnisse aller Modelle für zugeschnittene Bilder auf dem realen Datensatz ausgewertet.	66
6.27. Vergleich der Ergebnisse aller Modelle für zugeschnittene Bilder auf dem synthetischen Datensatz ausgewertet.	67
6.28. Vergleich der Ergebnisse aller Modelle für originalen Bilder auf dem realen Datensatz ausgewertet.	68
6.29. Vergleich der Ergebnisse aller Modelle für originale Bilder auf dem synthetischen Datensatz ausgewertet.	69
6.30. Vergleich der Ergebnisse aller Modelle für den Real/Synthetisch Klassifizierer auf zugeschnittenen Bildern.	69
6.31. Vergleich der Ergebnisse aller Modelle für den Real/Synthetisch Klassifizierer auf originalen Bildern.	70

7.1.	Repräsentative Bilder für die Helligkeitsverteilung der vier Subdatensätze. . .	72
7.2.	Beispiele für die Variabilität realer Bilder und die Einheitlichkeit simulierter Bilder die zu ähnlicher Zeit aufgenommen werden.	75
7.3.	Weitere Beispiele von simulierten Bildern mit interessanten Kontrast Effekten. Links: ausgegraut wirkenden Bild, welches in einen Zeitraum mit niedrigen Kontrastwerten fällt; Rechts: simuliertes Regenbild mit dem höchsten Kontrast, aber ohne sichtbare Regeneffekte.	76
7.4.	Beispielbilder für die Auswirkung mechanischer Einflüsse auf die Ausrichtung der realen Bilder nach dem Zuschneiden.	79
7.5.	SSIM Differenzbilder für reale und simulierte Bildpaare. Bei den realen Bildpaaren ist ein deutlicher Einfluss der auftretenden Verschiebungen und Rotationen, sowie von Rauschen zu erkennen. Bei simulierten Bildpaaren sind hauptsächlich die Regeneffekte zu sehen.	84
A.1.	Ausschnitt der Logdatei für Regenbilder mit Aufnahmedatum und -Uhrzeit, sowie dem wichtigen Ausschnitt des zugeordneten METAR-Berichts und dem Bildnamen. Die Beschriftung der Daten in der obersten Zeile gehört nicht zur eigentlichen Logdatei und wird nur für das bessere Verständnis eingefügt. . .	98
A.2.	Grundlegende Version des BP_DropCollision Blueprints zur Erzeugung von Regentropfen auf Objekten in der Simulation.	99
A.3.	Erweiterte Version des BP_DropCollision Blueprints zur Erzeugung von Regentropfen auf ausgewählten Objekten in der Simulation.	100
A.4.	Vergleich der Farbveränderungen zwischen realen und synthetischen Bildern über den Tag.	101
A.5.	Vergleich der realen und simulierten CAVOK Bilder aus den frühen Morgenstunden.	102
A.6.	Gestapeltes Histogramm für die Helligkeit von Bildern unter den speziellen Wetterbedingungen: Schatten auf dem Kalibriermuster bei CAVOK, Schatten auf dem Kalibriermuster bei Regen und Regentropfen auf der Linse	102
A.7.	Gestapeltes Histogramm für den Kontrast von Bildern unter den speziellen Wetterbedingungen: Schatten auf dem Kalibriermuster bei CAVOK, Schatten auf dem Kalibriermuster bei Regen und Regentropfen auf der Linse	103
A.8.	Histogramme für die Laplace Bildschärfe der Bilder der vier Subdatensätze. . .	103
A.9.	Laplace Bildschärfe der Bilder in Abhängigkeit von der Uhrzeit (blau: CAVOK Bilder; orange: Regen Bilder).	104
A.10.	Gestapeltes Histogramm für die Kantenanzahl von Bildern unter den speziellen Wetterbedingungen: Schatten auf dem Kalibriermuster bei CAVOK, Schatten auf dem Kalibriermuster bei Regen und Regentropfen auf der Linse	104
A.11.	Beispielbilder für die Auswirkung des Hintergrundes auf die Erkennung weiterer Features zur Klassifizierung von CAVOK und Regenbildern. Die zugeschnittenen Varianten sind die Zuschnitte der gezeigten originalen Bilder. Das simulierte Bild ist das für die Daten des realen Bildes generierte Bild.	105
A.12.	Beispiele für die Auswirkung von Regentropfen auf der Linse auf die Eckenerkennung. In Bereichen mit erkennbaren Regentropfen nimmt die Anzahl der erkannten Ecken ab. Allerdings werden auf dem restlichen Bild viele andere Kanten erkannt.	106

Tabellenverzeichnis

3.1. Einteilung der Differenzanalysemethoden in fünf Kategorien. Die in dieser Arbeit genutzten Methoden sind fett gedruckt.	10
4.1. Einteilung von Regen entsprechend der Niederschlagsintensität entsprechend [1].	15
5.1. Benötigte Partikelanzahlen pro Quadratmeter entsprechend dem Regentyp und der Intensität.	34
5.2. Charakterisierung der erzeugten Datensätze.	39
A.1. Klassifikationsberichte für alle Modelle die auf realen zugeschnittenen Bildern trainiert wurden, ausgewertet auf realen Daten.	107
A.2. Klassifikationsberichte für alle Modelle die auf simulierten zugeschnittenen Bildern trainiert wurden, ausgewertet auf realen Daten.	107
A.3. Klassifikationsberichte für alle Modelle die auf realen zugeschnittenen Bildern trainiert wurden, ausgewertet auf simulierten Daten.	108
A.4. Klassifikationsberichte für alle Modelle die auf simulierten zugeschnittenen Bildern trainiert wurden, ausgewertet auf simulierten Daten.	108
A.5. Klassifikationsberichte für alle Modelle die auf realen originalen Bildern trainiert wurden, ausgewertet auf realen Daten.	109
A.6. Klassifikationsberichte für alle Modelle die auf simulierten originalen Bildern trainiert wurden, ausgewertet auf realen Daten.	109
A.7. Klassifikationsberichte für alle Modelle die auf realen originalen Bildern trainiert wurden, ausgewertet auf simulierten Daten.	110
A.8. Klassifikationsberichte für alle Modelle die auf simulierten originalen Bildern trainiert wurden, ausgewertet auf simulierten Daten.	110
A.9. Klassifikationsberichte für alle Sim vs. Real Modelle die auf zugeschnittenen Bildern trainiert wurden.	111
A.10. Klassifikationsberichte für alle Sim vs. Real Modelle die auf originalen Bildern trainiert wurden.	111
A.11. Zusammenfassung der Ergebnisse der Differenzanalyse für die Kategorie der strukturunabhängigen Bildmerkmale.	112
A.12. Zusammenfassung der Ergebnisse der Differenzanalyse für die Kategorie der Low-Level Feature Analyse.	113
A.13. Zusammenfassung der Ergebnisse der Differenzanalyse für die Kategorie der Pixel- und Wahrnehmungsähnlichkeit.	113
A.14. Zusammenfassung der Ergebnisse der Differenzanalyse für die Kategorie Klassifikator- und Anwendungs basiert.	114

Quellcodeverzeichnis

A.1. Implementierung der MLV Bildschärfe basierend auf der Originaldefinition . .	115
---	-----

Abkürzungsverzeichnis

CAVOK	Angabe für klares Wetter im METAR Format / englisch: Ceiling, Clouds and Visibility OK
CMYK	Cyan, Magenta, Gelb, Schwarz / englisch: Cyan, Magenta, Yellow, Key
CPU	Zentrale Verarbeitungseinheit / englisch: Central Processing Unit
DL	Tiefes Lernen / englisch: deep learning
DLR	Deutsches Zentrum für Luft- und Raumfahrt
EBU	Europäische Rundfunkunion / englisch: European Broadcasting Union
EIA	Electronic Industries Alliance
FID	Fréchet Inception Distanz
GAN	erzeugende gegnerische Netzwerke / englisch: Generative Adversarial Networks
GPU	Grafikprozessoren / englisch: Graphics Processing Unit
ICAO	Internationale Zivilluftfahrtorganisation / englisch: International Civil Aviation Organization)
MESZ	Mitteleuropäische Sommerzeit
METAR	Meteorologischer Flugplatzbericht / englisch: METeorological Aerodrome Report
ML	Maschinelles Lernen
MLV	Maximale lokale Variation / englisch: Maximum Local Variation
MSE	mittlere quadratische Abweichung / englisch: Mean Squared Error
NRMSE	Normalisierte Wurzel der mittleren quadratischen Abweichung / englisch: Normalized Root Mean Squared Error
PSNR	Signal-Rausch-Verhältnis / englisch: Peak Signal-to-Noise Ratio
RGB	Rot, Grün, Blau
RMS	Quadratisches Mittel / englisch: Root Mean Square
RMSE	Wurzel der mittleren quadratischen Abweichung / englisch: Root Mean Squared Error
SSIM	Index struktureller Ähnlichkeit / englisch: structural similarity index
UAV	Unbemanntes Luftfahrzeug / englisch: Unmanned Aerial Vehicle
UTC	Koordinierte Weltzeit / englisch: coordinated universal time
XAI	Erklärbare Künstliche Intelligenz / englisch: explainable Artificial Intelligence
yaml	YAML Ain't Markup Language

Danksagung

An dieser Stelle möchte ich mich bei allen bedanken, die mich bei meiner Arbeit unterstützt haben.

Ein besonderer Dank gilt Herrn Prof. Dr. Bernhard Preim, der mich seit Beginn meines Masterstudiums vielfältig unterstützt und gefördert hat und Herrn Dr.-Ing. Stefan Krause für die Bereitstellung des spannenden Themas. Ganz herzlich möchte ich mich auch bei Rebecca Schmidt für ihre hervorragende Betreuung bedanken.

Meiner Familie, die mich in besonders stressigen Phasen immer unterstützt und ermutigt hat, möchte ich ebenfalls herzlich danken.

Kapitel 1.

Einleitung

Die zuverlässige Umweltwahrnehmung durch den Einsatz unterschiedlicher Sensortechnologien stellt eine zentrale Voraussetzung für den sicheren Betrieb autonomer Systeme wie Roboter, selbstfahrenden Autos und unbemannten Luftfahrzeugen (Unbemanntes Luftfahrzeug / englisch: Unmanned Aerial Vehicle (UAV)s) dar. Sie bildet die Grundlage zahlreicher sicherheitskritischer Funktionen, etwa der frühzeitigen Erkennung anderer Verkehrsteilnehmer zur Kollisionsvermeidung oder im Fall von UAVs der Identifikation geeigneter Landeplätze. Wie in [2] aufgezeigt wird, können verschiedene Witterungsbedingungen, wie Regen, Schnee und Nebel, die Leistungsfähigkeit der Umweltwahrnehmung erheblich beeinträchtigen und somit ein sicherheitsrelevantes Risiko darstellen. So führt Regen – in Abhängigkeit von der Intensität – bei Rot, Grün, Blau (RGB)-Kameras zu Wahrnehmungsfehlern in bis zu 50% der Zeit. Starke Lichteinstrahlung kann darüber hinaus Einschränkungen bis hin zum vollständigen Ausfall der kamerabasierten Umweltwahrnehmung verursachen. Da derartige Umweltbedingungen nicht vermeidbar sind, ist die Entwicklung geeigneter Ansätze zur Erhöhung der Robustheit von Wahrnehmungssystemen erforderlich. Ergänzend dazu sind effiziente Testverfahren notwendig, um neue Systeme systematisch unter widrigen Wetterbedingungen evaluieren zu können.

Die Durchführung entsprechender Tests in realen Umgebungen, beispielsweise im Rahmen von Flugversuchen, ist mit erheblichen Herausforderungen verbunden. Bereits unter günstigen Wetterbedingungen erfordert ein Flugversuch eine aufwändige Planung und Vorbereitung, einschließlich der Organisation einer geeigneten und sicheren Testumgebung, der Einholung notwendiger Genehmigungen sowie des Einsatzes qualifizierten Personals. Die gezielte Einplanung von Witterungsbedingungen wie Regen, Nebel oder Schnee gestaltet sich aufgrund ihrer eingeschränkten Vorhersagbarkeit zusätzlich komplex. Darüber hinaus ist zu berücksichtigen, dass mit solchen Wetterbedingungen erhöhte Risiken verbunden sind, die bei der Planung und Durchführung von Flugversuchen in besonderem Maße berücksichtigt werden müssen.

Um die beschriebenen Herausforderungen in der Entwicklungsphase neuer Systeme zu umgehen, entwickelt das Deutsche Zentrum für Luft- und Raumfahrt (Deutsches Zentrum für Luft- und Raumfahrt (DLR)) einen Ansatz zur Virtualisierung von Flugversuchen. Ziel ist es, virtuelle Flugversuche unter variablen und gezielt einstellbaren Wetterbedingungen durchführen zu können. Die Ergebnisse solcher Tests sind jedoch nur dann aussagekräftig, wenn die zugrunde liegende Simulation hinreichend realistisch ist. In diesem Kontext bezieht sich Realismus nicht auf eine vollständig physikalisch korrekte Abbildung der Umgebung, sondern auf eine phänomenologisch korrekte Darstellung, die für die virtuellen Sensoren und Algorithmen relevante Eigenschaften der Umweltbedingungen abbildet. Darüber hinaus spielt die Echtzeitfähigkeit des entwickelten Systems eine zentrale Rolle, da so perspektivisch die Möglichkeit geschaffen werden soll, virtuelle Flugversuche in Kombination mit dem Personal eines realen Flugtests durchzuführen.

Für den Nachweis, ob eine Simulation beziehungsweise deren Output phänomenologisch korrekt ist, wird ein Datensatz mit realen Messdaten benötigt, anhand dessen die Simulation validiert werden kann. Damit eine Analyse aussagekräftig ist, ist es zudem erforderlich, nicht wetterbedingte Einflussfaktoren innerhalb dieses Datensatzes möglichst zu minimieren. In der Literatur zur Umweltwahrnehmung unter schwierigen Witterungsbedingungen wird mehrfach darauf hingewiesen, dass es insbesondere an Datensätzen mit expliziter Berücksichtigung von Wetterphänomenen mangelt [3][4][2]. Aus diesem Grund befassen sich zahlreiche Arbeiten mit der Generierung neuer, oder Erweiterung bestehender Datensätze [3][5][4]. Diese bestehen jedoch oftmals aus synthetisch erzeugten oder augmentierten Daten mit umfangreichen Szenen, die nicht ausschließlich auf Wetterphänomene fokussiert sind.

Weiterhin erfolgt die Bewertung neu erzeugter Datensätze in den meisten Arbeiten, unter anderem in [3] und [5], durch den Einsatz von Methoden des maschinellen Lernens (Maschinelles Lernen (ML)) beziehungsweise des tiefen Lernens (Tiefes Lernen / englisch: deep learning (DL)). Diese Verfahren ermöglichen zwar eine Einschätzung, inwieweit spezifische Modelle mit den Daten umgehen können, liefern jedoch keinen direkten Nachweis für die phänomenologische Korrektheit eines Datensatzes. In [4] wird ergänzend eine Nutzerstudie durchgeführt, die weitere Erkenntnisse zur Qualität liefert. Allerdings eignet sich auch dieser Ansatz nicht als alleinige Bewertungsmethode, da die menschliche Wahrnehmung von Bildern nicht mit der Verarbeitung durch rechnergestützte Systeme gleichgesetzt werden kann.

Das Ziel dieser Arbeit besteht darin eine Methode zur Differenzanalyse zwischen realen und synthetischen RGB-Bildern mit Wetterphänomenen zu entwickeln, mit der die phänomenologische Korrektheit der synthetischen Daten nachgewiesen werden kann. Als Wetterbedingungen werden klares Wetter und die dabei wechselnden Lichtverhältnisse, sowie Regen betrachtet. Da es keinen geeigneten Datensatz für diese Untersuchung gibt, wird ein eigener minimalistischer Datensatz erzeugt. Darüber hinaus wird eine Auswahl an Differenzanalysemethoden getroffen. Diese muss geeignet sein um ein breites Spektrum an Bildeigenschaften zu erkennen und Unterschiede zwischen den Datensätzen erklären zu können.

Diese Arbeit trägt folglich folgenden Beitrag zur Forschung an der Umweltwahrnehmung unter schlechten Wetterbedingungen, sowie der Forschung zur Virtualisierung von Flugversuchen bei:

- Es wird ein neuer realer Datensatz erstellt, der verschiedene Wetterphänomene aufzeichnet und andere Einflüsse minimiert. Für die im Rahmen dieser Arbeit betrachteten Wetterphänomene wird darüber hinaus ein passender simulierter Datensatz erzeugt.
- Es wird dargestellt wie ein echtzeitfähiges Regensystem, welches verschiedene Regeneffekte abbildet, in der Unreal Engine erstellt werden kann.
- Es wird eine Auswahl an Differenzanalysemethoden getroffen, mit denen die Datensätze ausgewertet werden. Darauf aufbauend wird der Unterschied zwischen Bildern klarer Wetterbedingungen und Bildern mit Regen diskutiert und die phänomenologische Korrektheit der Simulation geprüft.

Die Arbeit teilt sich in drei große Abschnitte auf. Kapitel 2, 3 und 4 bilden den ersten und theoretischen Abschnitt der Arbeit. In Kapitel 2 werden zuerst Arbeiten zu Datensätzen für die Umweltwahrnehmung bei schwierigen Wetterlagen genauer vorgestellt. Anschließend wird auf Wettersimulationen und Differenzanalysemethoden für den Vergleich von Bildern eingegangen und diese Arbeit und ihr Beitrag eingeordnet. In Kapitel 3 werden die für die spätere

Differenzanalyse benötigten Methoden ausgewählt und die Auswahl begründet. In Kapitel 4 werden anschließend alle weiteren benötigten Grundlagen für die Arbeit beschrieben.

Der zweite Abschnitt beschäftigt sich mit den neuen Datensätzen und besteht aus dem Kapitel 5. In Kapitel 5.1 wird darauf eingegangen, wie die Datensätze erzeugt werden. Es wird sowohl der praktische Aufbau für den realen Datensatz erklärt, als auch die Simulation für den synthetischen Datensatz. Für den synthetischen Datensatz wird die Regensimulation im Detail erläutert. In Kapitel 5.2 werden anschließend die erzeugten Datensätze vorgestellt. Es wird genauer darauf eingegangen wie viele Bilder von welchen Wetterphänomenen für die Differenzanalyse genutzt werden.

Der dritte und letzte große Abschnitt der Arbeit besteht aus der Differenzanalyse der Datensätze. Kapitel 6 zeigt alle relevanten Ergebnisse der Differenzanalyse. In Kapitel 7 werden die Ergebnisse ausgewertet und mögliche Erklärungen angegeben.

Für die leichtere Navigation durch die Arbeit, vor allem in Bezug auf die Auswertung mit bestimmten Differenzanalysemethoden, haben Kapitel 3, 4.3, 6 und 7 eine ähnliche Struktur.

Kapitel 2.

Verwandte Arbeiten

Das folgende Kapitel ist in drei Teile gegliedert. Der erste Abschnitt befasst sich mit bestehenden Arbeiten, die synthetische oder aufgezeichnete Datensätze zur Umweltwahrnehmung bei widrigen Wetterbedingungen bereitstellen. Dabei werden nicht nur die Datensätze selbst vorgestellt, sondern auch Methoden zu deren Auswertung diskutiert. Ziel ist es, die Relevanz und Grenzen bestehender Ansätze im Hinblick auf die Motivation für einen Minimal-Setup-Datensatz herauszuarbeiten.

Im zweiten Abschnitt werden unterschiedliche Methoden der Wettersimulation betrachtet. Der Vergleich verschiedener Ansätze verdeutlicht die Spannbreite zwischen Rechenaufwand, physikalischer Korrektheit und Anwendungsfokus.

Der dritte Abschnitt widmet sich Verfahren zur Differenzanalyse, die für den Vergleich von Bilddaten herangezogen werden können. Solche Methoden sind insbesondere für die objektive Bewertung von Simulationsergebnissen und deren Nutzen für Wahrnehmungsalgorithmen unter Schlechtwetterbedingungen relevant.

In allen drei Bereichen wird die Position der vorliegenden Arbeit aufgezeigt, indem deren Beitrag im Kontext bestehender Forschungsarbeiten eingeordnet wird.

2.1. Datensätze zur Umweltwahrnehmung bei schwierigen Wetterlagen

In [2] wird hervorgehoben, dass für die Forschung im Bereich der Umweltwahrnehmung unter Schlechtwetterbedingungen geeignete Datensätze erforderlich sind, in weit verbreiteten Datensätzen jedoch häufig entsprechende Wetterphänomene fehlen. Zahlreiche Arbeiten versuchen diese Lücke zu schließen, indem eigene Datensätze generiert werden. Dabei handelt es sich überwiegend um synthetisch erzeugte Daten, die durch Augmentierungen [6][4] oder Simulationen [3][5] erstellt werden. Einige Ansätze basieren auf physikalischen Eigenschaften der Wetterphänomene, beispielsweise Regentropfen [6][4], während andere auf dem optischen Erscheinungsbild beruhen [7][3]. Teilweise werden auch Methoden erzeugender gegnerischer Netzwerke erzeugende gegnerische Netzwerke / englisch: Generative Adversarial Networks (GAN)s eingesetzt [4]. Mit Ausnahme von [7] verfolgen alle genannten Arbeiten das Ziel, Datensätze zu erzeugen, die unmittelbar für das Training von Umweltwahrnehmungssystemen genutzt werden können. Daher enthalten die Datensätze vollständige Szenen, wodurch eine isolierte Analyse der Wettereinflüsse erschwert wird. Die Bewertung erfolgt überwiegend mithilfe von ML-Methoden [3][5], wobei häufig keine Erklärung gegeben wird, warum die

neuen Datensätze zu einer Leistungssteigerung der Modelle führen. Ergänzend werden in einigen Fällen Nutzerbefragungen eingesetzt [6][4]. Auch in physikalisch basierten Ansätzen fehlt jedoch eine umfassende und vielschichtige Validierung der phänomenologischen Korrektheit der erzeugten Wettereffekte [4][5].

Insgesamt zeigt sich, dass reale Datensätze, die synthetische Daten systematisch ergänzen, nur selten erstellt werden. Ein Datensatz, der sich ausschließlich auf Wetterphänomene konzentriert und andere Einflüsse komplexer Szenen ausschließt, konnte auch im Rahmen einer systematischen Recherche in einschlägigen Quellen (z. B. arXiv, IEEE, ACM und projektoffizielle Veröffentlichungen) nicht identifiziert werden. Verfügbare Datensätze integrieren, ähnlich wie die genannten Arbeiten, Wetterbedingungen stets in komplexe Szenen (z. B. Straßenverkehr) oder sind auf aufgabenorientierte Benchmarks wie Detektion oder Bildentstörung ausgerichtet. Beispiele hierfür sind Rainy WCity [8] und Seeing Through Fog [9].

Diese Befunde verdeutlichen eine bestehende Forschungslücke und motivieren die Entwicklung eines Minimal-Setup-Datensatzes, der eine phänomenologische Bewertung von Wettereffekten erlaubt. Ziel dieser Arbeit ist es, diese Lücke zu adressieren, indem ein entsprechender Datensatz erstellt wird. Damit wird ein Wechsel ermöglicht von der Fragestellung, ob ein Datensatz bestimmte Anwendungen verbessert, hin zur Analyse, warum ein Datensatz bzw. eine Simulation geeignet ist und welche Effekte optimiert werden müssen.

2.2. Wettersimulationen

Die Simulation von Wetterphänomenen wird in unterschiedlichen Disziplinen mit sehr verschiedenen Zielen verfolgt. Die Wahl der Methode hängt wesentlich vom Anwendungsfeld ab. In interaktiven Medien wie Computerspielen liegt der Fokus auf der visuellen Plausibilität und der Echtzeitfähigkeit der Darstellung. Eine strikte physikalische Korrektheit ist in diesem Kontext von nachgeordneter Bedeutung. Arbeiten wie [10] oder [11] präsentieren Verfahren zur Echtzeitsimulation von Regen. Während [10] primär partikelbasierte Effekte ohne physikalische Modellierung nutzt, integriert [11] vereinfachte physikalische Effekte, um den Realismus zu erhöhen, ohne jedoch eine vollständige physikalische Konsistenz zu erreichen.

In der Filmproduktion wird eine höhere visuelle Genauigkeit gefordert, was häufig den Einsatz physikalisch fundierter Verfahren erfordert. Diese zeichnen sich durch erheblich größere Rechenzeiten aus, da komplexe Wechselwirkungen wie Tropfendynamik, Oberflächenbenetzung und volumetrische Effekte berücksichtigt werden. Ein Beispiel ist die Simulation von Regen in Blade Runner 2049, die in Fachinterviews als eine der aufwendigsten Aufgaben der visuellen Effekte beschrieben wurde [12].

Für meteorologische Anwendungen und numerische Wettervorhersagemodelle steht hingegen die physikalische Korrektheit im Vordergrund, während die grafische Darstellung keine Rolle spielt. Hier werden hochaufgelöste Strömungs- und Atmosphärenmodelle eingesetzt, deren Rechenaufwand nur mit Hochleistungsrechnern bewältigt werden kann [13].

Arbeiten zur Generierung synthetischer Datensätze für die Erforschung der Umweltwahrnehmung unter Schlechtwetterbedingungen [3][5] bewegen sich zwischen diesen beiden Extremen. Sie verbinden Elemente physikalisch motivierter Modellierung mit der Notwendigkeit kurzer Renderzeiten bis hin zur Echtzeitfähigkeit, um robuste Trainings- und Testumgebungen für Wahrnehmungsalgorithmen bereitzustellen.

Auch in der Simulation unbemannter Luftfahrzeuge (UAVs) werden spezielle Simulationsumgebungen genutzt, die in Echtzeit laufen müssen. Vergleichsstudien [14] zeigen, dass gängige Simulatoren wie AirSim [15] oder X-Plane [16] Wettersimulationen beinhalten. Während X-Plane als kommerzielles Produkt verfügbar ist, wurde AirSim für die Unreal Engine [17] entwickelt und steht als Open-Source-Software zur Verfügung.

Aufbauend auf diesen Erkenntnissen hat sich die Unreal Engine als geeignete Plattform für UAV-Simulationen etabliert, da sie eine moderne Echtzeitrendering-Pipeline bereitstellt und damit sowohl technische Flugtests als auch visuelle Wettersimulationen unterstützt. In der vorliegenden Arbeit wird die Unreal Engine eingesetzt, um synthetische Bilder für die Differenzanalyse unter Verwendung einer Wettersimulationen zu erstellen. Dabei werden physikalisch motivierte Ansätze berücksichtigt, soweit sie mit den Anforderungen an Echtzeitfähigkeit vereinbar sind.

2.3. Differenzanalysemethoden für den Vergleich von Bildern

Wie der Begriff Differenzanalyse bereits nahelegt, befasst sich dieses Forschungsfeld mit der Bestimmung von Unterschieden beziehungsweise Ähnlichkeiten zwischen Bildern. Bei synthetischen Bildern ist eine solche Analyse häufig in einem an die jeweilige Anwendung angepassten Umfang erforderlich. In [18] wird hervorgehoben, dass eine physikalisch korrekte Simulation nicht zwangsläufig sicherstellt, dass die erzeugten oder dargestellten Bilder auch ein authentisches Erscheinungsbild aufweisen. Eine Differenzanalyse ist daher notwendig, um mögliche Abweichungen zu identifizieren. Entsprechend der Relevanz dieses Themenfeldes wird die Bestimmung der Ähnlichkeit zwischen synthetischen und realen Bildern bereits seit längerer Zeit erforscht. So wird in [19] beschrieben, dass geeignete Methoden der Differenzanalyse erfassen sollen, wie ähnlich Bilder erscheinen. Dabei wird betont, dass ein synthetisches Bild einem realen Bild nicht exakt entsprechen muss, um dennoch als realistisch wahrgenommen zu werden. Unklar bleibt jedoch, wie sich der Begriff „ähnlich erscheinen“ präzise definieren lässt. In [19] liegt der Fokus auf der menschlichen Wahrnehmung, und es werden Metriken vorgeschlagen, die eine Bewertung von Bildähnlichkeiten aus der Perspektive von Menschen unterstützen. Auch [18] befasst sich überwiegend mit der menschlichen Wahrnehmung. Im Unterschied zu [19] erfolgt die Beurteilung der Ähnlichkeit dort nicht ausschließlich über computergestützte Metriken, sondern unter Einbeziehung menschlicher Einschätzungen. Solche Verfahren sind insbesondere dann relevant, wenn synthetische Bilder in ihrer Anwendung für Menschen realistisch wirken sollen. Für die vorliegende Arbeit haben diese Ansätze jedoch nur eine untergeordnete Bedeutung. Zwar ist auch hier langfristig eine realistische Darstellung für Menschen von Interesse, vorrangig wird jedoch die Wahrnehmung durch computergestützte Algorithmen berücksichtigt.

Zur Zeit der Veröffentlichung der genannten Arbeiten war die menschliche Wahrnehmung der zentrale Maßstab zur Bewertung der Ähnlichkeit zwischen synthetischen und realen Bildern [18]. Inzwischen gibt es jedoch zahlreiche Anwendungsfelder, in denen die menschliche Wahrnehmung keine zentrale Rolle mehr spielt. Werden synthetische Bilder beispielsweise als Trainingsdatensätze für Algorithmen des maschinellen Lernens (ML) oder des tiefen Lernens (DL) eingesetzt, ist es unerheblich, ob diese für Menschen realistisch wirken, solange sie von den trainierten Modellen in ähnlicher Weise wie reale Bilder verarbeitet werden. Für derartige

Anwendungen sind Methoden, die sich primär an der menschlichen Wahrnehmung orientieren, daher nicht geeignet.

Die Auswahl geeigneter Bewertungsmethoden hängt von verschiedenen Faktoren ab, darunter dem Ziel der Differenzanalyse, der geplanten Anwendung der Bilder sowie der Art ihrer Erzeugung. In einigen Forschungsgebieten haben sich bestimmte Metriken als Standard etabliert. Ein Beispiel hierfür ist der Fréchet Inception Distance (Fréchet Inception Distanz (FID)) [20], der als Benchmark für die Evaluation von GANs verwendet wird.

Werden synthetische Bilder ausschließlich als Trainingsdaten für ML- oder DL-Modelle erzeugt, erfolgt häufig kein direkter Vergleich mit realen Bildern. Stattdessen ist es üblich, Modelle mit unterschiedlichen Kombinationen aus realen und synthetischen Daten zu trainieren und deren Leistung zu evaluieren. Wenn ein Modell, das auf synthetischen Daten trainiert wurde, erfolgreich auf reale Daten generalisiert, wird angenommen, dass die synthetischen Daten für die jeweilige Anwendung hinreichend realistisch sind. Ein entsprechender Ansatz zur Untersuchung der Eignung verschiedener Methoden der Datenerzeugung – wie Augmentierung, Bildbearbeitung oder Simulation – zur Ergänzung realer Datensätze wird in [21] vorgestellt. Ein verwandtes Konzept ist die Cross-Dataset Generalization, bei der zwei Modelle auf unterschiedlichen Datensätzen trainiert und anschließend auf dem jeweils anderen Datensatz evaluiert werden. Ähnliche oder repräsentative Datensätze führen in diesem Ansatz zu vergleichbar guten Ergebnissen auf beiden Seiten [22]. Ein weiterer Ansatz im Bereich ML, bzw. DL ist der Einsatz von Klassifikatoren, die darauf trainiert werden, reale von synthetischen Daten zu unterscheiden. Je schlechter ein solcher Klassifikator abschneidet, das heißt je mehr Fehler er bei der Klassifizierung macht, desto eher wird angenommen, dass die synthetischen Daten die relevanten Eigenschaften realer Daten hinreichend imitieren. Unter anderem in [23] wird ein derartiger Ansatz genutzt. Eine Einschränkung dieser ML, bzw. DL-basierten Verfahren ist das sogenannte Blackbox-Problem: Die Entscheidungen von ML- und DL-Modellen sind für Menschen nur schwer nachvollziehbar. Forschungsarbeiten im Bereich erklärebare künstliche Intelligenz (Erklärebare Künstliche Intelligenz / englisch: explainable Artificial Intelligence (XAI)) befassen sich mit dieser Herausforderung. XAI-Methoden werden bereits eingesetzt, um zu untersuchen, anhand welcher Merkmale ML- und DL-Modelle zwischen realen und synthetischen Daten unterscheiden. Eine Methode zur Visualisierung der Bildbereiche, die für die Klassifizierung zwischen real und synthetisch relevant sind, wurde beispielsweise 2023 in [24] vorgestellt. Dennoch sind diese Ansätze häufig auf spezifische Anwendungen zugeschnitten und liefern keine umfassende Erklärung darüber, welche Eigenschaften von Bildern entscheidend sind, damit sie als ähnlich zu realen Bildern wahrgenommen werden.

Neben den zuvor beschriebenen, im Bereich des ML und des DL häufig angewendeten Verfahren existieren weitere, stärker anwendungsspezifische Methoden. Ein Beispiel hierfür sind Tests, mit denen die Leistungsfähigkeit virtueller Kameras im Vergleich zu realen Kameras bewertet wird. In [25] werden solche Ansätze genutzt, um Parameter wie Linsenverzerrung, Brennweite, Vignettierung und Sensorlinearität zwischen realen und virtuellen Kameras gegenüberzustellen. Der Nachteil dieser Methoden besteht darin, dass sie sich nicht zur Bestimmung einer anwendungsunabhängigen Ähnlichkeit zwischen Bildern eignen. Im Rahmen der vorliegenden Arbeit werden jedoch Verfahren benötigt, die für allgemeine Aussagen eingesetzt werden können, da derzeit noch nicht absehbar ist, welche spezifischen Anwendungen zu einem späteren Zeitpunkt untersucht werden. Aus diesem Grund sind vor allem Methoden relevant, die ein breites Spektrum möglicher Anwendungen abdecken – wie etwa der Einsatz von Klassifikatoren – und die durch noch allgemeinere Ansätze ergänzt werden können.

Zu den allgemeinen Methoden zählt die direkte Auswertung einzelner Bildeigenschaften wie Helligkeit, Kontrast oder Unschärfe. Mit diesen Verfahren lassen sich reale und synthetische Bilder unmittelbar vergleichen. Dieser Ansatz ähnelt dem in [18] beschriebenen Vorgehen, unterscheidet sich jedoch insofern, als dass bei der computergestützten Analyse der Helligkeit nicht die menschliche Wahrnehmung berücksichtigt wird, sondern lediglich die Pixelwerte. Zur Bestimmung von Kontrast und Unschärfe existieren unterschiedliche Verfahren [26][27]. Ein Nachteil dieser Methoden besteht darin, dass sie in der Regel nur globale Ergebnisse liefern und keine Informationen über lokale Strukturen bereitstellen, sofern sie nicht entsprechend angepasst werden. Dennoch können auf einzelne Bildeigenschaften fokussierte Verfahren hilfreich sein, um Unterschiede zwischen Bildern zu identifizieren. Ein Anwendungsbeispiel findet sich in [28], wo untersucht wird, wie sich Helligkeit und Kontrast von Outdoor-Aufnahmen in Abhängigkeit von Tageszeit und Himmelsrichtung verändern. Auch in [29] werden derartige Methoden eingesetzt, um aus Basismerkmalen wie Helligkeit und Kontrast übergeordnete Parameter – beispielsweise die Anwesenheit von Nebel – abzuleiten.

Neben der Analyse einzelner Bildeigenschaften können auch Verfahren wie Kanten- und Eckenerkennung eingesetzt werden, um Informationen über die Bildinhalte zu gewinnen. Im Vergleich zu den zuvor genannten Ansätzen liefern diese Methoden Hinweise auf Unterschiede in den Strukturen von Bildern. Die Ergebnisse bestehen typischerweise aus statistischen Größen wie der Anzahl oder Gesamtlänge von Kanten und sind dadurch vergleichsweise leicht interpretierbar. Zu den gängigen Verfahren zur Kantendetektion zählen der Canny-Algorithmus [30], der Sobel-Operator [31] sowie der Laplace-Filter [32]. Für die Erkennung von Eckpunkten sind insbesondere der Harris-Corner-Detector [33] und der Features from Accelerated Segment Test (FAST) [34] weit verbreitet. Darüber hinaus können auch Verfahren zur Analyse von Texturmerkmalen, wie etwa die Anwendung von Gabor-Filtern [35], dieser Kategorie zugeordnet werden. Ein Beispiel für die Anwendung solcher Methoden zum Vergleich zweier Bilddatensätze findet sich in [36]. In dieser Arbeit wird ein Datensatz mit neuartigen Objekten einem Datensatz mit vertrauten Objekten gegenübergestellt. Zur Charakterisierung der Unterschiede zwischen beiden Datensätzen werden klassische Bildmerkmale ausgewertet, darunter die Kantendichte. Die Analyse dieser statistischen Größen zeigt, dass sich die beiden Datensätze in ihren strukturellen Eigenschaften systematisch unterscheiden lassen.

Während die Analyse von Bildeigenschaften auf einzelnen Bildern basiert, eignen sich sogenannte Similarity Measures (Ähnlichkeitsmaße), um zwei oder mehr Bilder direkt miteinander zu vergleichen. Solche Verfahren können pixelbasiert sein, wie beispielsweise das Mean Squared Error (MSE) [37], oder mehrere Bildeigenschaften kombinieren, wie im Fall des Structural Similarity Index (SSIM) [38]. Einige Methoden verknüpfen lokale Bildstrukturen mit Modellen der menschlichen Wahrnehmung, um die visuelle Ähnlichkeit zwischen Bildern zu quantifizieren. In der Praxis werden derartige Verfahren heute häufig eingesetzt, etwa zur Identifikation redundanter Bilder innerhalb eines Datensatzes, wie in [39] demonstriert, oder zur Bewertung der Bildqualität durch den Vergleich von Original- und rekonstruierten Bildern mittels MSE und SSIM [40].

In der Literatur finden sich zahlreiche Methoden, die ein breites Spektrum von niedrig- bis hochstufigen Bildeigenschaften abdecken. Diese Verfahren unterscheiden sich hinsichtlich ihrer Interpretierbarkeit und sind zum Teil nur für spezifische Anwendungen geeignet. In den bisherigen Arbeiten zeigt sich häufig, dass die Auswahl der Methoden auf die jeweilige Anwendung zugeschnitten ist. Im Gegensatz dazu verfolgt die vorliegende Arbeit das Ziel, die Ähnlichkeit zwischen simulierten und realen Bildern für Anwendungen der Umweltwahrnehmung jeder Art zu bewerten, sodass die Ergebnisse sowohl für klassischen Verfahren als auch

auf DL Methoden nutzbar sind. Daher wird im Folgenden eine Auswahl verschiedener Ansätze vorgestellt, die sowohl niedrig- als auch hochstufige Bildeigenschaften berücksichtigen und dadurch einen umfassenden Einblick in die Daten ermöglichen. Die Auswahl dieser Methoden wird in Kapitel 3 beschrieben.

Kapitel 3.

Auswahl der Differenzanalysemethoden

Tabelle 3.1.: Einteilung der Differenzanalysemethoden in fünf Kategorien. Die in dieser Arbeit genutzten Methoden sind fett gedruckt.

Kategorie	Methoden (Beispiele)	Eigenschaften
Strukturunabhängige Bildmerkmale	- Helligkeit - Kontrast - Bildschärfe	- globale Merkmale
Low-Level Feature Analyse	- Kanten - Ecken - Texturmerkmale	- objektive Unterschiede in Strukturen - leicht interpretierbar
Pixel- und Wahrnehmungsähnlichkeit	- MSE - PSNR - SSIM	- basieren auf lokalen Strukturen und Wahrnehmung - vergleichen zwei Bilder direkt
Verteilungsähnlichkeit	- FID - KID [41]	- Vergleich von Feature-Verteilungen ganzer Datensätze
Klassifikator- und Anwendungs-basiert	- Datensatz Generalisierung - Klassifizierer - Nutzerstudien	- starke Aussagekraft für speziellen Anwendungsfall

Die Differenzanalyse zwischen realen und synthetisch erzeugten Bildern kann mit einer Vielzahl von Verfahren durchgeführt werden (vgl. Kapitel 2.3). Diese Verfahren lassen sich in fünf Kategorien einteilen, die sich hinsichtlich der zugrunde liegenden Merkmale und Abstraktionsebenen unterscheiden.

Die erste Kategorie umfasst Methoden zur Bestimmung globaler Bildmerkmale wie Helligkeit, Kontrast oder Histogramme in verschiedenen Farbräumen. Diese Verfahren liefern Informationen über statistische Eigenschaften der Intensitätsverteilung, ohne Bildstrukturen explizit abzubilden. Da sie auf Einzelbilder angewendet werden, ist ein anschließender Vergleich der Ergebnisse über mehrere Bilder hinweg erforderlich. Im Folgenden wird diese Gruppe als „Strukturunabhängige Bildmerkmale“ bezeichnet.

Die zweite Kategorie beinhaltet Verfahren zur Erkennung von Kanten, Ecken oder Texturen. Solche Methoden dienen der Untersuchung struktureller Unterschiede zwischen Bildern und werden daher im Folgenden als „Low-Level Feature Analyse“ bezeichnet. Auch diese Verfahren werden auf Einzelbilder angewendet.

Die dritte Kategorie umfasst Methoden zur Bestimmung der „Pixel- und Wahrnehmungsähnlichkeit“. Hierzu gehören klassische Metriken wie die mittlere quadratische Abweichung (MSE) [37], das Signal-Rausch-Verhältnis (PSNR) [42] sowie der Index struktureller Ähnlichkeit (SSIM) [38]. Diese Verfahren vergleichen jeweils zwei Bilder direkt miteinander und berücksichtigen sowohl lokale Strukturen als auch Aspekte der menschlichen Wahrnehmung.

Die vierte Kategorie bilden Verfahren der „Verteilungsähnlichkeit“. Ein Beispiel hierfür ist die FID [20]. Methoden dieser Kategorie vergleichen Merkmalen über ganze Datensätze hinweg.

Die fünfte Kategorie umfasst „Klassifikator- und Anwendungsbasierte“ Methoden. Dazu gehören Verfahren, bei denen Klassifikatoren auf Unterschiede zwischen realen und synthetischen Bildern trainiert werden, ebenso wie Studien mit menschlichen Probanden oder andere anwendungsspezifische Bewertungsansätze. Diese Methoden bieten eine besonders hohe Aussagekraft in Bezug auf die Eignung eines Datensatzes für eine bestimmte Anwendung, sind jedoch nur eingeschränkt übertragbar auf andere Einsatzkontexte oder auf die Entwicklung von Simulationsumgebungen.

Eine Übersicht über die genannten Kategorien ist in Tabelle 3.1 dargestellt.

Die im Rahmen dieser Arbeit durchgeführte Differenzanalyse soll allgemeingültige Aussagen über die Ähnlichkeit von synthetisch erzeugten Bildern mit Wettereffekten und realen Referenzbildern ermöglichen. Da keine einzelne Methode alle relevanten Aspekte erfassen kann, ist die Kombination mehrerer Ansätze erforderlich. Aus diesem Grund wird eine Auswahl von Verfahren aus vier der fünf beschriebenen Kategorien zusammengestellt; Methoden der vierten Kategorie (Verteilungsähnlichkeit) werden hierbei nicht berücksichtigt. Die ausgewählten Verfahren sollen als Grundlage für eine zukünftig einfache und systematische Bewertung neu erzeugter synthetischer Daten dienen. Im Folgenden wird die Auswahl pro Kategorie näher erläutert.

3.1. Kategorie 1: Strukturunabhängige Bildmerkmale

Da die hier betrachteten Methoden globale Bildmerkmale erfassen, ist zunächst zu bestimmen, welche dieser Merkmale durch Wettereffekte beeinflusst werden können. Mit der Einschränkung auf Lichteffekte und Regen ergeben sich folgende relevante Einflussgrößen. Lichteffekte wirken unmittelbar auf die Helligkeit eines Bildes. Auch fallende Regentropfen können die Intensität einzelner Pixel erhöhen [43] und sich dadurch auf die Gesamthelligkeit sowie auf Histogramme der Helligkeitsverteilung auswirken. Da Regen in der Regel mit Wolken einhergeht, die das Umgebungslicht reduzieren, ist außerdem anzunehmen, dass eine allgemeine Abdunkelung in betroffenen Bildern sichtbar wird.

Neben der Helligkeit stellt auch der Bildkontrast eine relevante Größe dar. Da dieser den Unterschied zwischen den hellsten und dunkelsten Bildbereichen quantifiziert, können insbesondere Lichteffekte wie Lens-Flare oder Schatten den Kontrast beeinflussen. Ebenso ist es plausibel, dass Regenwolken die Kontrastwerte verändern. Zusätzlich zu den fallenden Tropfen sind auch Effekte durch auf Oberflächen haftende Wassertropfen relevant. Diese können sowohl auf Objekten innerhalb der Szene als auch auf der Kameralinse oder vorgelagerten Schutzscheiben auftreten. Durch Brechung des einfallenden Lichts verursachen sie Bildverzerrungen [44], die sich in Form von Unschärfe manifestieren können. Im Rahmen dieser Arbeit wird untersucht, inwieweit sich solche Verzerrungen mithilfe von Schärfemaßen erfassen lassen.

Zusammenfassend werden in dieser Kategorie Methoden zur Bestimmung von Helligkeit, Kontrast und Bildschärfe eingesetzt. Alle Verfahren werden auf Einzelbilder angewendet, deren Ergebnisse anschließend vergleichend ausgewertet werden. Da diese Methoden ausschließlich globale Merkmale liefern, werden die resultierenden Messwerte nicht nur auf Einzelbildern zu vergleichen, sondern Gruppen von Bildern – beispielsweise reale versus synthetisch erzeugte Daten – gegenüberzustellen.

3.2. Kategorie 2: Low-Level Feature Analyse

Methoden dieser Kategorie sind geeignet, strukturelle Eigenschaften von Bildern zu erfassen. Insbesondere bei Regen wird vermutet, dass zusätzliche Strukturen entstehen, die sich in den erkannten Merkmalen widerspiegeln. Sowohl fallende Regentropfen als auch auf Oberflächen haftende Tropfen erzeugen neue Konturen und Muster, die mit entsprechenden Verfahren detektiert werden können. Auch Lichteffekte können die Bildstruktur beeinflussen, beispielsweise wenn Reflexionen oder Lens-Flare-Effekte vorhandene Strukturen überlagern oder verdecken. In [2] wird gezeigt, dass starkes einfallendes Licht die Bildaufnahme so stark beeinträchtigen kann, dass kaum noch Strukturen erkennbar sind.

Zur Untersuchung dieser Effekte werden Kantenerkennungs- und Eckendetektionsverfahren eingesetzt. Konkret kommen der Canny-Algorithmus [30] sowie die Shi-Tomasi-Eckendetektion [45] zum Einsatz. Analog zur ersten Kategorie werden diese Methoden auf Einzelbilder angewendet, wobei die erzielten Ergebnisse anschließend vergleichend gegenübergestellt werden.

3.3. Kategorie 3: Pixel- und Wahrnehmungsähnlichkeit

Im Gegensatz zu den ersten beiden Kategorien basieren die Methoden dieser Gruppe stets auf dem Vergleich zweier Bilder. Pixelbasierte Verfahren operieren dabei direkt auf den Intensitätswerten einzelner Pixel, während wahrnehmungsbasierte Verfahren komplexere Merkmale berücksichtigen und diese zwischen den Bildern vergleichen. Da immer Bildpaare benötigt werden, ist eine abweichende Gruppierung des Datensatzes erforderlich.

Für die pixelbasierten Methoden ist ein Vergleich von Regenbildern untereinander nicht zweckmäßig, da die Position einzelner Regentropfen zwischen verschiedenen Aufnahmen stark variiert. Daher werden diese Verfahren genutzt, um Bilder ohne Regen mit Bildern mit Regeneffekten zu vergleichen, die jeweils zu ähnlichen Tageszeiten aufgenommen wurden. Der Vergleich erfolgt getrennt für reale und synthetische Bildpaare; die Ergebnisse beider Gruppen werden anschließend gegenübergestellt. Als Metriken kommen die Wurzel der mittleren quadratischen Abweichung / englisch: Root Mean Squared Error (RMSE) und PSNR zum Einsatz, da beide Ansätze in der Bildverarbeitung weit verbreitet sind.

Auch bei wahrnehmungsbasierten Methoden bestehen Einschränkungen im Umgang mit Regenbildern. SSIM etwa misst die strukturelle Ähnlichkeit zwischen zwei Bildern auf Basis von Luminanz, Kontrast und Struktur. Da Strukturen jedoch direkt durch Regentropfen beeinflusst werden, ist die Interpretation der Ergebnisse beim direkten Vergleich zweier Regenbilder erschwert. Aus diesem Grund wird auch hier die gleiche Gruppierungsstrategie wie bei den

pixelbasierten Verfahren angewendet. Die Auswahl passender Bildpaare wird in Kapitel 6.3 näher beschrieben.

3.4. Kategorie 4: Verteilungsähnlichkeit

Wie bereits dargestellt, messen Verfahren dieser Kategorie die Verteilungen von Merkmalen ganzer Datensätze. Dazu werden in der Regel vortrainierte Modelle eingesetzt, um die Abstände zwischen den Datensätzen im Merkmalsraum zu bestimmen. Diese Methoden wurden primär für die Bewertung synthetischer Datensätze entwickelt, die mit GANs erzeugt wurden, und sind stark von den Eigenschaften des zugrunde liegenden vortrainierten Modells abhängig. Aus diesem Grund werden Ansätze dieser Kategorie im Rahmen der vorliegenden Arbeit nicht weiter berücksichtigt.

3.5. Kategorie 5: Klassifikator- und Anwendungsbasiert

Da zu erwarten ist, dass ein Teil der späteren Anwendungen auf ML-Methoden basiert, werden auch klassifikatorbasierte Verfahren berücksichtigt. In der Literatur wird gezeigt, dass Klassifikatoren ein geeignetes Mittel zum Vergleich von realen und synthetischen Bilddaten darstellen und zudem Aufschluss über die Reaktion von Deep-Learning-Netzen auf solche Daten geben können [23]. In diesem Zusammenhang werden zwei Ansätze verfolgt.

Im ersten Ansatz wird ein Klassifikator trainiert, der vier Klassen unterscheidet: real + klares Wetter, real + Regen, synthetisch + klares Wetter sowie synthetisch + Regen. Ziel ist es, die Unterscheidbarkeit zwischen realen und synthetischen Daten zu quantifizieren. Geringere Klassifikationsleistungen deuten dabei auf eine größere Ähnlichkeit der Daten hin [23].

Der zweite Ansatz orientiert sich an der Cross-Dataset-Generalization-Methode [22]. Hierbei werden zwei Modelle mit identischer Netzwerkarchitektur verwendet. Das erste Modell wird auf realen Daten trainiert, das zweite auf synthetischen. Beide Modelle lernen, zwischen klarem Wetter und Regen zu unterscheiden, und werden anschließend jeweils auf dem jeweils anderen Datensatz evaluiert. Auf diese Weise lässt sich untersuchen, inwieweit sich auf synthetischen Daten trainierte Modelle auf reale Daten übertragen lassen und umgekehrt.

Kapitel 4.

Grundlagen

Zur Einordnung der in dieser Arbeit eingesetzten Methoden und Verfahren werden in diesem Kapitel die erforderlichen theoretischen und technischen Grundlagen dargestellt. Zunächst werden die für die Arbeit relevanten Wetterphänomene erläutert. Anschließend erfolgt eine Beschreibung der Unreal Engine mit ihren Möglichkeiten zur Simulation von Wetterbedingungen. Abschließend werden die in Kapitel 3 ausgewählten Methoden sowie die ihnen zugrunde liegenden mathematischen Konzepte vorgestellt.

4.1. Wetter

Wie zuvor dargestellt, können verschiedene Wetterphänomene die mit Kameras erfassten Bilder maßgeblich beeinflussen. Um eine realitätsnahe Simulation solcher Phänomene zu ermöglichen, ist zunächst ein Verständnis ihrer Eigenschaften und Wirkungen erforderlich. Da für diese Arbeit lediglich ein begrenzter Erhebungszeitraum im Frühjahr und Sommer zur Verfügung steht, wird angenommen, dass kein realer Datensatz zu Nebel, Schnee, Hagel oder vergleichbaren Wetterbedingungen erstellt werden kann. Daher konzentriert sich die Betrachtung auf Regeneffekte sowie auf Lichteffekte, die durch den Sonnenstand bei klarem Wetter verursacht werden. Diese beiden Phänomene werden im Folgenden näher erläutert.

4.1.1. Regen

Niederschlag in flüssiger Form wird allgemein als Regen bezeichnet [46]. Regen kann jedoch anhand verschiedener Merkmale, wie der Tropfengröße oder der Niederschlagsintensität, differenziert werden. Im Folgenden werden zunächst die Fallgeschwindigkeit von Regentropfen, die gängigen Kategorisierungen sowie die Auswirkungen auf mit Kameras aufgenommene Bilder erläutert.

Fallgeschwindigkeit von Regentropfen

Regen entsteht, wenn die Wassertröpfchen in einer Wolke so groß werden, dass sie nicht länger durch Luftreibung oder Aufwinde in der Schwebelage gehalten werden können. Die Geschwindigkeit, mit der ein Tropfen anschließend zu Boden fällt, hängt maßgeblich von seinem Durchmesser ab [47]. Kleine Tropfen erreichen dabei geringere Endgeschwindigkeiten als große Tropfen. Allerdings besitzen auch große Tropfen eine maximale Fallgeschwindigkeit, da sich ihre Form während des Falls verändert [48]. Während kleine Tropfen nahezu kugelförmig

bleiben, werden größere Tropfen durch den Luftwiderstand abgeflacht, wodurch der Strömungswiderstand zunimmt. Bei Tropfendurchmessern von etwa fünf Millimetern oder mehr kommt es zudem häufig zu Instabilitäten, die zum Zerfall in kleinere Tropfen führen [49]. Dabei bildet sich zunächst eine Einbuchtung an der Unterseite, die schließlich zum Aufbrechen des Tropfens führt. Da Tropfen mit einem Durchmesser über fünf Millimetern in der Natur nur selten auftreten [46], sind sie für die Betrachtung der Endgeschwindigkeit von geringerer Relevanz. Typischerweise erreichen Tropfen mit weniger als 0,5 mm Durchmesser Endgeschwindigkeiten von etwa 2 m/s, während größere Tropfen bis 5 mm Durchmesser Geschwindigkeiten von bis zu 9 m/s erreichen können [47]. Für die weitere Arbeit wird ein Durchschnittswert von etwa 6 m/s für Tropfen mit mehr als 0,5 mm Durchmesser angenommen, da sehr große Tropfen vergleichsweise selten vorkommen.

Kategorisierungen

Die Einteilung von Regen kann zunächst anhand der Tropfengröße erfolgen. Tropfen mit einem Durchmesser kleiner als 0,5 mm werden als Sprühregen beziehungsweise Nieselregen bezeichnet. Für größere Tropfen mit einem Durchmesser über 0,5 mm wird allgemein die Bezeichnung Regen verwendet [46].

Darüber hinaus erfolgt eine Klassifikation nach der Niederschlagsintensität. Diese beschreibt die gefallene Wassermenge in Form einer Niederschlagshöhe pro Zeiteinheit, typischerweise angegeben in Millimetern. Der Wert bezieht sich darauf, wie hoch die Wassersäule auf einer horizontalen Fläche stünde, wenn kein Wasser abfließen, versickern oder verdunsten würde [50]. Die Angabe lässt sich unmittelbar in Liter pro Quadratmeter umrechnen, wobei 1 mm Niederschlagshöhe dem Äquivalent von 1 l/m^2 entspricht.


Tabelle 4.1.: Einteilung von Regen entsprechend der Niederschlagsintensität entsprechend [1].

Regentyp/-intensität	Niederschlagshöhe pro Stunde (mm/h)
leichter Sprühregen	<0,1
mäßiger Sprühregen	0,1 - 0,5
starker Sprühregen	>0,5
leichter Regen	<2,5
mäßiger Regen	2,5 - 10
starker Regen	10 - 50
sehr starker Regen	>50


Sowohl Sprühregen als auch Regen werden anhand der Intensität in die Kategorien leicht, mäßig und stark unterteilt. Für Regen existiert zusätzlich die Kategorie sehr stark [1]. Die entsprechenden Einteilungen sind in Tabelle 4.1 zusammengefasst.

Auswirkungen auf Kamerabilder

Regen kann sich auf unterschiedliche Weise in Bildern bemerkbar machen. Wie in [43] beschrieben, erscheinen fallende Tropfen bis zu einer bestimmten, von den Kameraeigenschaften abhängigen Entfernung als helle Strukturen im Bild (vgl. Abbildung 4.1a). Ab größerer Entfernung wirkt der Niederschlag ähnlich wie Nebel. Da Nebel im Rahmen dieser Arbeit nicht berücksichtigt wird, wird dieser Effekt nicht weiter vertieft. Eine weitere Auswirkung ergibt sich, wenn Tropfen auf Oberflächen auftreffen und dort haften bleiben, bis sie entweder abfließen oder verdunsten. Solche Tropfen können das Erscheinungsbild der betroffenen Oberflächen



(a) Fallenden Regentropfen (weiße Streifen).



(b) Regentropfen auf einem Objekt.



(c) Regentropfen auf der Kameralinse.

Abbildung 4.1.: Beispiele für die in dieser Arbeit berücksichtigten Effekte durch Regen.

deutlich verändern, wie in Abbildung 4.1b dargestellt. Eine besondere Form dieser Beeinflussung tritt auf, wenn Tropfen direkt auf die Kameralinse oder – sofern eine Scheibe vorgeschaltet ist – auf die Scheibenoberfläche treffen. In diesem Fall können sie einen erheblichen Teil des Bildes einnehmen, Farbveränderungen hervorrufen oder Bildverzerrungen verursachen (vgl. Abbildung 4.1c) [44]. Zusätzlich können auch durch Regen entstandene Pfützen zu relevanten Bildartefakten führen. Aus der Luft betrachtet erzeugen sie störende Reflexionen [51], während sie am Boden durch Spritzwasser erhebliche Bildbeeinträchtigungen hervorrufen können [52]. Da diese Effekte durch Pfützen jedoch über den Rahmen einer einfachen Regensimulation hinausgehen und auch in realen Datensätzen nur schwer kontrollierbar sind, werden sie in dieser Arbeit nicht weiter untersucht.

4.1.2. Lichteffekte bei klarem Wetter

Lichteffekte bei klarem Wetter entstehen durch das Zusammenspiel von Sonnenstand und Umgebungsbedingungen. Im einfachsten Fall ergibt sich der Einfluss allein aus der Position der Sonne. Beispiele für tageszeitabhängige Effekte sind farbliche Veränderungen von Objekten über den Tag [53]. Auch die Dämmerung zählt hierzu, da das verringerte Umgebungslicht zu dunkleren Bildern und einer reduzierten Erkennbarkeit von Strukturen führt. Tagsüber stellt der Schattenwurf einen der prägnantesten Effekte dar. Dieser ist ebenfalls von der Tageszeit abhängig und sollte in einer Simulation realitätsnah nachgebildet werden. Schatten beeinflussen Bilder auf vielfältige Weise und führen unter anderem zu Unterschieden in Helligkeit und Farbwahrnehmung zwischen beschatteten und unbeschatteten Regionen [54]. Weitere relevante Lichteffekte sind beispielsweise Lens Flare, der auftritt, wenn eine Kamera direkt auf eine starke Lichtquelle ausgerichtet ist und dadurch helle Flecken im Bild entstehen [55], sowie Reflexionen. Letztere können sowohl durch spiegelnde Oberflächen in der Umgebung hervorgerufen werden als auch durch reflektiertes Licht, das sich in Form von Punkten, Streifen oder Flächen auf anderen Objekten abbildet [37]. Alle genannten Effekte beeinflussen Bildeigenschaften wie Helligkeit, Farbwirkung und Kontraste in aufgenommenen Bildern und sind daher auch für die Bildauswertung von Bedeutung.

4.2. Wettersimulationen in der Unreal Engine

Für die in dieser Arbeit durchgeführten Untersuchungen bildet die Unreal Engine eine technische Basis. In diesem Kapitel werden zunächst die wesentlichen Eigenschaften der Engine vorgestellt, die für die Simulation von Umwelteinflüssen und deren Auswertung relevant sind. Anschließend wird erläutert, wie in der Unreal Engine Lichteffekte und Regen simuliert werden können.

4.2.1. Unreal Engine 5.3

In dieser Arbeit wird die Unreal Engine 5.3 eingesetzt [56]. Die Unreal Engine wird von Epic Games entwickelt und wurde ursprünglich als Spiele-Engine konzipiert. Mittlerweile findet sie auch in zahlreichen anderen Bereichen Anwendung, darunter Film- und Fernsehen, Live-Events, Architektur, Automobilindustrie und Simulationen [57]. Die Kombination aus Echtzeitfähigkeit und einer Bildqualität auf dem Stand der Technik macht die Engine für viele Anwendungsfelder attraktiv. Ein weiterer Vorteil besteht in der Flexibilität der Programmierung: Neben nativer C++-Entwicklung können auch mit dem Blueprint-System, einer visuellen Skriptsprache, eigene Funktionen implementiert werden [58]. Darüber hinaus bietet die Unreal Engine eine Vielzahl integrierter Funktionen, beispielsweise zur Generierung von Materialien, Partikeleffekten oder komplexen Animationen. Über den integrierten Marketplace kann zusätzlich auf eine breite Palette von Assets und Erweiterungen aus der Community zugegriffen werden [59].

4.2.2. Regeneffekte

Wie in Kapitel 2.2 beschrieben, existieren verschiedene Ansätze zur synthetischen Nachbildung von Regen. In der Unreal Engine wird Regen typischerweise als Partikeleffekt dargestellt, wofür das Niagara-System verwendet wird [60]. Regentropfen werden dabei meistens als längliche Partikel eingestellt und das Niagara-System wird in einer bestimmten Region des Raums platziert, sodass der Eindruck fallender Tropfen entsteht [61]. Das Niagara-System erlaubt eine Vielzahl an Konfigurationen und kann durch Blueprints oder Skripte flexibel erweitert werden, um gewünschte Effekte individuell anzupassen. Zwar lässt sich ein vollständig physikalisch korrekter Regen damit nicht realisieren, jedoch ermöglichen die umfangreichen Einstellungsmöglichkeiten eine visuell überzeugende und anwendungsorientierte Simulation.

4.2.3. Lichteffekte

Für die Unreal Engine existieren Plugins, die den Sonnenstand in Abhängigkeit von den geografischen Koordinaten sowie der Tageszeit berechnen können [62]. Darüber hinaus lassen sich Umgebungslicht und weitere Beleuchtungsparameter direkt in der Engine konfigurieren. Auch der Schattenwurf ist standardmäßig implementiert und erfordert keine zusätzlichen Anpassungen. Der Effekt des Lens Flares kann in den Kameraeinstellungen aktiviert werden [63], wird jedoch im Rahmen dieser Arbeit nicht weiter berücksichtigt. Reflexionen stellen eine größere Herausforderung dar, da hierfür reflektierende Materialien an den relevanten Objekten definiert werden müssen und die Berechnung selbst mit hohem Rechenaufwand verbunden

ist. Geeignet für Reflexionen ist das Lumen-System der Unreal Engine [64] Aufgrund dieser Komplexität werden Reflexionen in dieser Arbeit nicht weiter betrachtet.

4.3. Ausgewählte Differenzanalysemethoden

Im Folgenden werden die zuvor ausgewählten Differenzanalysemethoden näher erläutert, um ein grundlegendes Verständnis ihrer Funktionsweise zu schaffen. Dazu werden die jeweiligen mathematischen Grundlagen dargestellt und, soweit erforderlich, durch Gleichungen veranschaulicht. Die Erklärungen sind bewusst auf eine konzeptionelle Ebene beschränkt und sollen keine vollständige technische Implementierung wiedergeben, sondern die für das Verständnis der späteren Anwendung wesentlichen Aspekte vermitteln.

4.3.1. Helligkeit

Die Helligkeit eines Bildes beschreibt dessen Gesamthelligkeit und bestimmt, wie hell oder dunkel ein Bild wahrgenommen wird. Sie beeinflusst unmittelbar die Erkennbarkeit von Strukturen und die subjektive Klarheit des Bildes. In digitalen Bildern wird die Helligkeit durch die Pixelwerte repräsentiert, wobei ein vollständig weißes Bild den höchsten und ein vollständig schwarzes Bild den niedrigsten Wert aufweist.

Eine standardisierte Methode zur Berechnung der Bildhelligkeit existiert nicht [65][66]. Insbesondere bei Farbbildern werden die Kanäle unterschiedlich behandelt: Entweder wird die Helligkeit für jeden Kanal separat bestimmt und anschließend kombiniert, oder das Bild wird zunächst in ein Graustufenbild mit nur einem Kanal umgewandelt. Auch die Berechnungsansätze variieren. Neben der Summation und Normalisierung der Pixelwerte werden häufig das arithmetische Mittel oder das quadratische Mittel verwendet.

Im Rahmen dieser Arbeit wird die Helligkeit über das quadratische Mittel (Quadratisches Mittel / englisch: Root Mean Square (RMS)) bestimmt. Die Berechnung erfolgt nach Gleichung 4.1 [66]:

$$Helligkeit_{RMS} = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2} \quad (4.1)$$

Hierbei bezeichnet x_i den Wert des i -ten Pixels und n die Gesamtzahl aller Pixel.

Die resultierenden Helligkeitswerte werden üblicherweise entweder auf einer Skala von 0,0 bis 1,0 oder von 0 bis 255 angegeben. In dieser Arbeit wird eine Skala von 0 bis 255 verwendet.

4.3.2. Kontrast

Der Kontrast eines Bildes wird – ähnlich wie die Helligkeit – auf Grundlage der Pixelwerte bestimmt. Er beschreibt den Unterschied zwischen hellen und dunklen Bereichen eines Bildes und beeinflusst damit maßgeblich die Sichtbarkeit von Details. Für die Bestimmung des Kontrasts existieren verschiedene Ansätze, die je nach Anwendungsfall eingesetzt werden [26]. In

dieser Arbeit wird der RMS-Kontrast verwendet. Ein Vorteil dieser Definition besteht darin, dass sie unabhängig von der räumlichen Verteilung der Kontraste im Bild ist und somit eine globale Kennzahl liefert [67].

Der RMS-Kontrast entspricht der Standardabweichung der Pixelwerte eines Bildes. Er berechnet sich nach Gleichung 4.2:

$$Kontrast_{RMS} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (4.2)$$

Hierbei bezeichnet n die Gesamtzahl der Pixel, x_i den Wert des i -ten Pixels und $\bar{x}$ den Mittelwert aller Pixelwerte.

4.3.3. Bildschärfe

Die Bildschärfe beschreibt den Grad, mit dem feine Details in einem Bild erkennbar sind. Allgemein gilt: starke Intensitätsschwankungen zwischen benachbarten Pixeln deuten auf eine hohe Detailgenauigkeit hin, während geringe Unterschiede auf Unschärfe hinweisen. Zur Berechnung der Bildschärfe existieren verschiedene Methoden [68]. Im Folgenden werden zwei Ansätze näher erläutert.

MLV Bildschärfe

Die Methode der Maximalen lokalen Variation (Maximale lokale Variation / englisch: Maximum Local Variation (MLV)) [68] bestimmt die Schärfe durch einen direkten Vergleich jedes Pixels mit seinen Nachbarpixeln. Für jeden Pixel wird dabei die größte Abweichung zum lokalen Umfeld berechnet:

$$MLV(I_{i,j}) = \{max|I_{i,j} - I_{x,y}| | x = i - 1, i, i + 1; y = j - 1, j, j + 1\} \quad (4.3)$$

Hierbei bezeichnet $I_{i,j}$ den Pixelwert an der Position (i, j) und $I_{x,y}$ die Werte der acht benachbarten Pixel. Anschließend wird die Standardabweichung der so bestimmten Maximalwerte berechnet. Je schärfer ein Bild ist, desto größer ist diese Standardabweichung, da deutliche Intensitätsunterschiede zwischen einzelnen Pixeln und deren Nachbarschaft auftreten. Unscharfe Bilder hingegen weisen geringere Unterschiede auf.

Laplace Bildschärfe

Ein weiter verbreiteter Ansatz ist es die Messung der Bildschärfe auf dem Laplace-Operator zu basieren [69]. Der Laplace-Operator wird in der Bildanalyse häufig zur Kantenerkennung eingesetzt, da er Bildbereiche mit starken Intensitätsänderungen hervorhebt. Diese Eigenschaft lässt sich nutzen, indem die Schärfe eines Bildes über die Standardabweichung der durch den Laplace-Operator berechneten Werte bestimmt wird. Eine hohe Standardabweichung weist dabei auf ein hohes Maß an Schärfe hin, da viele deutliche Kanten vorhanden sind.

4.3.4. Canny-Algorithmus

Für Kantendetektionsverfahren werden in der Literatur drei wesentliche Kriterien hervorgehoben [30]. Zum einen sollte die Fehlerrate möglichst gering sein, sodass weder Kanten übersehen noch fälschlicherweise Kanten detektiert werden. Zweitens ist eine präzise Lokalisierung erforderlich, das heißt der Abstand zwischen den detektierten und den tatsächlichen Kanten sollte minimal sein. Das letzte Kriterium sagt aus, dass das Verfahren eine eindeutige Antwort liefern sollte, d. h. jede Kante sollte höchstens einmal erkannt werden.

Ein weit verbreitetes und robustes Verfahren, das diese Anforderungen berücksichtigt, ist der Canny-Algorithmus [30]. Zuerst werden für jedes Pixel der horizontale und vertikale Intensitätsgradient berechnet, aus denen sich sowohl die Gradientenstärke als auch die Gradientenrichtung bestimmt wird. Anschließend erfolgt der Schritt der Nicht-Maximum-Unterdrückung, bei dem lokale Maxima entlang der Gradientenrichtung beibehalten und alle anderen Pixel unterdrückt werden. Im letzten Schritt wird ein Verfahren mit zwei Schwellwerten (Hysterese-Schwellen) angewendet: Pixel mit einer Gradientenstärke oberhalb des höheren Schwellwertes werden als Kantenpixel klassifiziert. Pixel mit einer Gradientenstärke zwischen den beiden Schwellwerten werden nur dann als Kantenpixel berücksichtigt, wenn sie mit bereits als sicher eingestuften Kanten verbunden sind. Alle übrigen Pixel werden verworfen.

Da der Canny-Algorithmus lediglich einzelne Pixel markiert, die auf Kanten liegen, jedoch keine vollständigen geometrischen Strukturen liefert, sind weitere Verfahren notwendig, um die erkannten Kanten als Linien zu beschreiben. Hierfür eignet sich z.B. die Hough-Transformation [70], ein globales Verfahren zur Erkennung verschiedener geometrischer Figuren in einem binären Gradientenbild. Dabei wird ein Dualraum definiert, in den für jedes als Kantenpixel erkannte Bildpixel alle Parameterkombinationen der gesuchten Figuren eingetragen werden. Zur Erkennung von Geraden kann beispielsweise die hessische Normalform (Gleichung 4.4) genutzt werden. Der Winkel α und der euklidische Abstand d bilden in diesem Fall die Parameter.

$$d = x \cdot \cos(\alpha) + y \cdot \sin(\alpha) \quad (4.4)$$

Für jedes Kantenpixel werden alle Parameterkombinationen in den Dualraum eingetragen, die die Gleichung erfüllen. Der so entstehende Dualraum fungiert als „Voting-Matrix“: Für jede gültige Parameterkombination wird der Zähler um eins erhöht. Nach Abschluss des Verfahrens werden die Parameter mit den höchsten Werten als erkannte geometrische Figuren ausgegeben, im Fall der Geradenerkennung also als Linien.

4.3.5. Shi-Tomasi Eckendetektion

Obwohl Verfahren wie die Shi-Tomasi-Eckendetektion häufig als reine Eckendetektionsalgorithmen bezeichnet werden, detektieren sie in Wirklichkeit allgemein interessante Punkte, die durch eine eindeutige Position charakterisiert sind und wiederholt zuverlässig erkannt werden können [45]. Diese Punkte sind oft Ecken, können aber ebenso isolierte Punkte oder andere markante Bildstellen sein. Charakteristisch ist, dass an solchen Punkten Intensitätsänderungen in mehreren Richtungen auftreten, während Kanten lediglich eine signifikante Intensitätsänderung in einer Richtung aufweisen.

Zur Bestimmung interessanter Punkte wird bei der Shi–Tomasi-Methode ein Fenster vorgegebener Größe (z. B. 3×3 , 5×5 oder 7×7 Pixel) über das Bild verschoben. Innerhalb dieses Fensters werden die Gradienten in x- und y-Richtung berechnet. Auf dieser Grundlage wird die Strukturmatrix M gebildet:

$$M = \begin{bmatrix} \sum \omega(x, y) I_x^2 & \sum \omega(x, y) I_x I_y \\ \sum \omega(x, y) I_x I_y & \sum \omega(x, y) I_y^2 \end{bmatrix} \quad (4.5)$$

Dabei bezeichnet $\omega(x, y)$ eine mögliche Gewichtungsfunktion, beispielsweise eine Gauß-Gewichtung, die eine Glättung innerhalb des Fensters bewirkt. Ein Pixel im Zentrum des Fensters wird als Ecke klassifiziert, wenn der kleinere Eigenwert der Matrix M einen vorgegebenen Schwellenwert überschreitet [45]. Durch diese Definition können auch gezielt die besten N Punkte ausgewählt werden.

4.3.6. RMSE

Die RMSE-Methode ist ein weit verbreitetes Maß zur Quantifizierung der Unterschiede zwischen zwei Bildern [37]. Trotz ihrer Popularität weist die RMSE-Methode einige Einschränkungen auf. Da die Berechnung ausschließlich auf einem Pixel-zu-Pixel-Vergleich beruht, werden strukturelle Informationen nicht berücksichtigt. Zudem zeigt sich eine nur geringe Übereinstimmung zwischen RMSE-Werten und der menschlichen Wahrnehmung von Bildähnlichkeit. Grundsätzlich gilt: je niedriger der RMSE-Wert, desto ähnlicher sind sich die verglichenen Bilder. Die Berechnung erfolgt nach Gleichung 4.6:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2} \quad (4.6)$$

Hierbei bezeichnet n die Anzahl aller Pixel im Bild, x_i den Wert des i-ten Pixels des ersten Bildes und y_i den entsprechenden Wert des zweiten Bildes.

In dieser Arbeit wird die Normalisierte Wurzel der mittleren quadratischen Abweichung (Normalisierte Wurzel der mittleren quadratischen Abweichung / englisch: Normalized Root Mean Squared Error (NRMSE)) als Methode verwendet. Für die Normalisierung existiert keine einheitliche Definition; je nach Anwendung werden unterschiedliche Varianten eingesetzt. In dieser Arbeit erfolgt die Normalisierung über die gemittelte euklidische Norm des Originalbildes, entsprechend der Implementierung in der Python-Bibliothek scikit-image [71].

4.3.7. PSNR

Die PSNR-Methode ist eine klassische Metrik, die insbesondere zur Bewertung der Signalqualität bei Übertragungen eingesetzt wird [72]. Sie beschreibt das Verhältnis zwischen der maximal möglichen Signalstärke und der Stärke des Störsignals, wobei letzteres durch den MSE berechnet wird. Da es sich erneut um einen Pixel-zu-Pixel-Vergleich handelt, ist die Metrik nicht in der Lage, strukturelle Unterschiede zwischen Bildern zu erfassen. Zudem zeigt sie eine geringe Übereinstimmung mit der menschlichen Wahrnehmung von Bildqualität [38]. Die Berechnung erfolgt nach Gleichung 4.7:

$$PSNR = 20 \cdot \log_{10}(MAX) - 10 \cdot \log_{10}(MSE) \quad (4.7)$$

Hierbei steht MAX für den maximal möglichen Pixelwert des Bildes. Die Berechnung des MSE entspricht dem Ausdruck unter der Wurzel in Gleichung 4.6. Die Ergebnisse von PSNR werden in Dezibel (dB) angegeben. Ein höherer PSNR-Wert weist dabei auf eine größere Ähnlichkeit der verglichenen Bilder hin.

4.3.8. SSIM

Der Index struktureller Ähnlichkeit (SSIM) ist ein wahrnehmungsbasiertes Modell zur Bewertung der Ähnlichkeit zweier Bilder [38]. Ziel dieser Metrik ist es, die Bildqualität so zu quantifizieren, dass sie besser mit der menschlichen Wahrnehmung übereinstimmt als klassische Pixel-differenzbasierte Maße wie MSE oder PSNR. Dabei werden auch wahrnehmungspsychologische Effekte berücksichtigt, etwa die Helligkeitsmaskierung (Bildstörungen erscheinen in hellen Bildbereichen weniger auffällig) und die Kontrastmaskierung (Bildstörungen sind in kontrastreichen Regionen schwerer wahrzunehmen).

Die Berechnung von SSIM erfolgt lokal auf sogenannten Fenstern, also Bildausschnitten fester Größe. Für jedes Fenster werden drei Komponenten bestimmt: Leuchtdichte, Kontrast und Struktur. Jede dieser Komponenten wird durch eine Vergleichsfunktion beschrieben:

$$\text{Leuchtdichte: } l(x, y) = \frac{2\mu_x\mu_y + c_1}{\mu_x^2 + \mu_y^2 + c_1} \quad (4.8)$$

$$\text{Kontrast: } c(x, y) = \frac{2\sigma_x\sigma_y + c_2}{\sigma_x^2 + \sigma_y^2 + c_2} \quad (4.9)$$

$$\text{Struktur: } s(x, y) = \frac{\sigma_{xy} + c_3}{\sigma_x\sigma_y + c_3} \quad (4.10)$$

Die drei Komponenten werden anschließend zu einem Gesamtwert kombiniert:

$$SSIM(x, y) = [l(x, y)]^\alpha \cdot [c(x, y)]^\beta \cdot [s(x, y)]^\gamma \quad (4.11)$$

Hierbei bezeichnen x und y zwei gleich große Bildausschnitte aus den zu vergleichenden Bildern. μ_x und μ_y sind die Mittelwerte der Pixelwerte, σ_x und σ_y die Standardabweichungen, und σ_{xy} die Kovarianz zwischen beiden Fenstern. Die Konstanten c_1 , c_2 und c_3 dienen der Stabilisierung, um Divisionen durch kleine Nenner zu vermeiden. Mit den Exponenten α , β und γ wird die relative Gewichtung der drei Komponenten gesteuert.

Das Ergebnis von SSIM liegt im Wertebereich von 0 bis 1, wobei der Wert 1 nur bei vollständig identischen Bildern erreicht wird. In der Praxis wird SSIM üblicherweise auf Graustufenbildern angewendet, Erweiterungen für Farb- und Multi-Skalen-Analysen sind jedoch ebenfalls verfügbar [38][72].

4.3.9. Klassifizierer mit ResNet

ResNet ist eine auf Convolutional Neural Networks (CNNs) basierende Architektur [20]. Bei tiefen CNN-Architekturen kann das sogenannte Problem des Verschwindens der Gradienten auftreten. Dabei werden die Gradienten während der Backpropagation in den frühen Schichten des Netzwerks so stark abgeschwächt, dass die Gewichte kaum noch angepasst werden können und das Training dadurch erheblich erschwert wird [73]. Zur Lösung dieses Problems wurde in ResNet-Architekturen ein neuer Baustein eingeführt: der Residual Block. Dieser enthält sogenannte Shortcut-Verbindungen, die nicht aufeinanderfolgende Schichten direkt miteinander verbinden. Auf diese Weise können Schichten, die die Modelleistung verschlechtern, effektiv umgangen werden und ein Verschwinden der Gradienten verhindert werden [20].

In dieser Arbeit wird ResNet-18 verwendet, eine Variante mit insgesamt 18 Schichten, die sowohl Faltungsschichten (Convolutional Layers) als auch Residual-Blöcke umfasst.

Kapitel 5.

Generierung der realen und synthetischen Datensätze

Für eine valide Differenzanalyse ist ein Datensatz erforderlich, bei dem nicht wetterbedingte Einflussfaktoren minimiert sind. Nur unter dieser Voraussetzung kann angenommen werden, dass beobachtete Unterschiede in der Auswertung auf das Wetter und die Simulation dessen zurückzuführen sind. Die Nichtexistenz eines solchen Datensatzes in der Literatur wird in Kapitel 2 erläutert. Im vorliegenden Kapitel wird zunächst der Prozess zur Erzeugung geeigneter realer und synthetischer Datensätze beschrieben. Anschließend werden die generierten Datensätze charakterisiert.

5.1. Versuchsaufbau und Simulation

Zur Minimierung nicht wetterbedingter Einflüsse und zur Erzielung einer realistischen Nachbildung des Versuchsaufbaus in der Simulation werden Bilder eines statischen Motivs erstellt. Zudem wird die Kamera in einer festen Position fixiert, um Bewegungseinflüsse auszuschließen. Neben der Reduzierung unerwünschter Einflüsse sind genaue Wetteraufzeichnungen von wesentlicher Bedeutung, um reale und synthetische Datensätze sinnvoll zu vergleichen. Im Folgenden wird zunächst das neu entwickelte Kalibriermuster, welches als Motiv dient, vorgestellt. Anschließend werden die verwendeten Wetterdaten detailliert beschrieben, gefolgt von der Beschreibung des realen Aufbaus und der Simulation.

5.1.1. Kalibriermuster

Kalibriermuster können eine breite Palette an statischen Mustern umfassen. In bestimmten Anwendungsbereichen, wie der Kamerakalibrierung, im Film und der Fernsehtechnik, haben sich jedoch spezifische Muster bewährt. Diese Muster dienen zur Bestimmung wichtiger Parameter wie der Auflösung, der Unschärfe an den Ecken und der Farbeinstellungen.

Ein Beispiel für solche Muster ist das PM5544-Testmuster von Philips, das eine Vielzahl von Einstellungen ermöglicht [74]. Dazu gehören unter anderem die Auflösung und Farbeinstellungen, die mithilfe des von der Europäischen Rundfunkunion (Europäische Rundfunkunion / englisch: European Broadcasting Union (EBU)) vorgestellten EBU-Farbbalkensignals [75] vorgenommen werden können. Ein weiteres Beispiel ist das Electronic Industries Alliance (EIA)-Resolution-Chart der Electronic Industries Alliance, das sowohl in der Fernsehtechnik als auch in der




Abbildung 5.1.: Kalibriermuster mit vier Bereichen (Schachbrettmuster, Farbskalen + TV-Linien, Hexagonmuster, Bereich mit zusätzlichen Mustern für weitere Testmöglichkeiten)

Kameratechnik Anwendung findet [76]. Das Muster beinhaltet unter anderem TV-Linien, die aus abwechselnd schwarzen und weißen Balken mit fester Breite bestehen [77]. Durch die Messung der minimalen Breite dieser Balken, bei der sie noch als separate Linien erkennbar sind, kann die Auflösung einer Kamera bestimmt werden. Historisch wurden TV-Linien verwendet, um die Auflösung von Analogkameras zu spezifizieren.

Der volle Umfang solcher Standard-Testkarten ist im Rahmen dieses Projekts mit dem Fokus auf die Untersuchung von Wettereffekten in Bildern nicht von Interesse. Daher wird ein eigenes Muster entwickelt. Dieses umfasst eine Vielzahl von Testbereichen mit unterschiedlichen Mustern und Farben. Ziel ist es, ein Kalibriermuster zu schaffen, das eine umfassende Bewertung verschiedener Methoden ermöglicht, die über die Grenzen dieses Projekts hinausgehen. Das quadratische Kalibriermuster wird, wie in Abbildung 5.1 dargestellt, in vier separate Bereiche unterteilt, die im Folgenden detailliert beschrieben werden.

Bereich oben links

In diesem Bereich ist ein Schachbrettmuster abgebildet, das sich ideal für die Messung von Kontrasten zwischen schwarz und weiß eignet. Dies kann besonders interessant für die Untersuchung von Regen sein, da Regentropfen in Bildern eine Aufhellung einzelner Pixel verursachen können, wie in der [43] erwähnt wird. Darüber hinaus weist ein Schachbrettmuster klar definierte Kanten und Ecken auf, die durch Regentropfen verzerrt oder gestört werden können.

Bereich oben rechts

Dieser Bereich des Kalibriermusters ist in verschiedene Muster aufgeteilt. Es gibt eine Skala verschiedener Grautöne und einen Bereich mit den Farben gelb, cyan, grün, magenta, rot und blau. Diese Skalen sind angelehnt an die Farbbalkensignale, die beim PM5544 Testmuster verwendet wurden. Damit die Farben korrekt gedruckt werden, werden diese im Cyan, Magenta, Gelb, Schwarz / englisch: Cyan, Magenta, Yellow, Key (CMYK)-Format (Cyan, Magenta, Gelb Schwarz) angegeben. Für die Simulation werden sie anschließend ins RGB-Format umgewandelt. Die Farbskalen können genutzt werden, um Veränderungen der Farben durch verschiedene Lichtverhältnisse sowie Regen oder andere Witterungsbedingungen zu untersuchen. Zwischen

den Farbskalen sind horizontale und vertikale TV-Linien eingefügt. Für das entworfene Kalibriermuster dienen die TV-Linien dazu, die Auflösung zwischen realen und synthetischen Bildern zu vergleichen, sowie auch hier um Effekte verschiedener Lichtverhältnisse oder von Regen zu erkennen.

Bereich unten links

Im unteren linken Bereich des Kalibriermusters sind Hexagone zu erkennen, die dazu dienen, die Auswirkung von z.B. Regen auch auf nicht horizontal oder vertikal verlaufende Kanten zu überprüfen. Dieses Muster ist dazu gedacht, das darüber liegende Schachbrettmuster zu ergänzen.

Bereich unten rechts

In diesem Bereich sind diverse Formen angeordnet. Neben Kreisen, die als Ergänzung zu den Schachbrett- und Wabenmustern dienen, sind zwei gestrichelte Linien zu sehen, die ähnlich wie die TV-Linien zur Auflösungsbestimmung verwendet werden können. Darüber hinaus sind Buchstaben und Zahlen in diesem Bereich enthalten. Dieser Bereich ist dazu bestimmt, die anderen drei Bereiche zu ergänzen und ermöglicht weitere Tests, wie beispielsweise die Erkennung von Buchstaben durch ML-Methoden, die im Kontext dieser Arbeit jedoch nicht berücksichtigt werden.

5.1.2. Wetteraufzeichnungen

Zur korrekten Zuordnung der realen Bilder zu den entsprechenden Wetterphänomenen und zur Bestimmung ihrer Relevanz für das Projekt sind Wetteraufzeichnungen erforderlich.

Auswahl der genutzten Wetterdaten

Da keine eigene Wetterstation mit Logfunktion vorhanden ist, müssen externe Wetterdaten verwendet werden. Diese müssen bestimmte Anforderungen erfüllen: Die Meldungen sollten in kurzen Zeitintervallen erfolgen, um die genaue Wetterlage für die aufgenommenen Bilder bestimmen zu können. Zudem sollte die Messstation in der Nähe des DLR-Geländes in Braunschweig liegen, wo der praktische Versuchsaufbau eingerichtet wird. Der Wetterbericht muss Informationen über die Bewölkung, die Art des Regens (Sprühregen oder Regen), die Niederschlagsmenge und die Windrichtung enthalten.

Die Wetterstation des Deutschen Wetterdienstes in Braunschweig befindet sich in Lehdorf-Watenbüttel, mehrere Kilometer vom DLR-Gelände entfernt. Die Wetterstation der Technischen Universität Braunschweig [78] ist ebenfalls zu weit entfernt. Die einzige Wetterstation in unmittelbarer Nähe ist die des Braunschweiger Flughafens, die direkt an das DLR-Gelände angrenzt. Daher können die Messdaten dieser Station als repräsentativ für die Wetterbedingungen am Versuchsaufbau betrachtet werden.

Beschreibung der Wetterdaten

Die Wetterstation des Flughafens Braunschweig übermittelt alle 30 Minuten automatisch Wetteraufzeichnungen im Format Meteorologischer Flugplatzberichte (Meteorologischer Flugplatzbericht / englisch: METeorological Aerodrome Report (METAR)). Historische Wetterdaten sind über verschiedene Webseiten verfügbar, was den Zugriff auf umfangreiche Datensätze über einen längeren Zeitraum ermöglicht. Für diese Arbeit werden die Wetteraufzeichnungen von OGIMET [79] bezogen und anschließend für die weitere Analyse aufbereitet.

METAR steht für METeorological Aerodrome Report und ist ein standardisiertes Format für Wetterberichte, das in der Luftfahrt zur Beschreibung der Wetterbedingungen an einem einzelnen Flughafen verwendet wird. Ein METAR-Bericht enthält den Code der Internationalen Zivilluftfahrtorganisation (Internationale Zivilluftfahrtorganisation / englisch: International Civil Aviation Organization) (ICAO) für den entsprechenden Flughafen, das Datum und die Uhrzeit der Aufzeichnung, sowie Informationen über den Wind, einschließlich der durchschnittlichen Windrichtung und -geschwindigkeit (in Knoten) über einen Zeitraum von 10 Minuten, sowie gegebenenfalls Höchstgeschwindigkeiten und Schwankungen in der Windrichtung [80]. Darüber hinaus werden die Sichtweite am Boden, die Temperatur und der Luftdruck angegeben. Bei Bedarf können auch Angaben zu bestimmten Wetterphänomenen, wie Niederschlag oder Nebel, sowie zur Bewölkung gemacht werden. Der Begriff CAVOK (Ceiling and Visibility OK) wird verwendet, um klare Wetterbedingungen zu beschreiben, die durch eine Sichtweite von mindestens 10 km, keine Wolken unter 5000 ft und keine Wettererscheinungen gekennzeichnet sind. Die Intensität von Regen und Sprühregen wird entsprechend der Definition vom Deutschen Wetterdienst anhand der Tropfengröße unterschieden, wobei die Kategorien leicht, mäßig und stark verwendet werden.

Es ist zu beachten, dass es keine offizielle Definition für die Niederschlagsintensität im METAR-Format gibt. Da die tatsächliche Niederschlagsmenge nur von wenigen Stationen gemessen wird, wird für die Zwecke dieser Arbeit die Definition des Deutschen Wetterdienstes als Referenz verwendet. Diese Definition wird als Grundlage für die Interpretation der Niederschlagsintensität im METAR-Format dienen.

Verwendung der Wetterdaten

Die gesammelten Wetterdaten werden auf zwei Arten weiter verwendet. Zum einen wird eine Metadatei für den gesamten realen Datensatz erzeugt, der im Rahmen dieser Arbeit erstellt wird. Hierfür wird jedem Bild der zeitlich nächste Wetterbericht zugeordnet. Mehr zu dem realen Datensatz und der Generierung der Metadatei wird im Abschnitt 5.1.3 erklärt.

Da für die Differenzanalyse ausschließlich Bilder berücksichtigt werden sollen, die bei klarem Wetter oder bei Regen aufgenommen wurden, ist eine Vorsortierung des realen Datensatzes vor der Differenzanalyse erforderlich. Hierzu werden zunächst die aufgezeichneten Wetterdaten sortiert, indem alle Wetterdaten nach den für diese Arbeit relevanten Wetterphänomenen durchsucht werden. Bei den relevanten Wetterphänomenen handelt es sich ausschließlich um klares Wetter (CAVOK) und Regen, sowie Sprühregen jeder Intensität. Bewölkung jeder Art wird ausgeschlossen, da die Simulation dieser zu komplex ist für die Arbeit. Weitere Wetterphänomene wie Nebel, Schnee, Hagel etc. werden ebenfalls nicht berücksichtigt, da es unwahrscheinlich ist, dass diese oft genug während des verfügbaren Zeitraums auftreten, um eine ausreichende Anzahl an Bildern zu sammeln.

Gemäß der Definition der Wetterschlüssel im METAR-Format werden in einem Python-Skript die Wetterberichte anhand folgender Schlüssel überprüft: „CAVOK“, „-RA“, „RA“, „+RA“, „-SHRA“, „SHRA“, „+SHRA“, „-DZ“, „DZ“, „+DZ“, „-SHDZ“, „SHDZ“ und „+SHDZ“. Dabei wird sichergestellt, dass diese Schlüsselwörter alleine stehen und nicht mit anderen Wetterphänomenen kombiniert auftreten. Alle Wetterberichte, die diese Schlüssel enthalten, werden in Logdateien festgehalten, um auf dieser Grundlage später die Bilder sortieren zu können.

5.1.3. Realer Datensatz



Abbildung 5.2.: Praktischer Versuchsaufbau zur Generierung des realen Datensatzes (1,5*1,5m große Aluplate mit Kalibrierungsmuster, GoPro HERO11 Black als Kamera)

Versuchsaufbau


Für die Generierung des realen Datensatzes wird ein Versuchsaufbau auf dem DLR-Gelände in Braunschweig eingerichtet (siehe Abbildung 5.2). Das Kalibrierungsmuster wird auf eine 1,5*1,5m große Aluminiumplatte gedruckt und in einer Höhe von 3,45m (Oberkante) an einer Gebäudefassade angebracht. Zur Aufnahme der Bilder wird eine GoPro HERO11 Black-Kamera [81] verwendet, die auf einem Stativ 2,5m vom Kalibrierungsmuster entfernt und auf einer Höhe von 2,7m (Linsenmitte) positioniert wird. Die Kamera wird durch visuelle Kontrolle und mithilfe der aufgenommenen Bilder so ausgerichtet, dass sie zentriert vor dem Kalibrierungsmuster angebracht und direkt auf dieses ausgerichtet ist.

Die Entfernung zwischen Kamera und Kalibrierungsmuster spielt eine wichtige Rolle bei der Datengenerierung. Mit zunehmendem Abstand zwischen Kamera und Kalibrierungsmuster nehmen die negativen Effekte auf die Auswertung zu, da die relevanten Muster einen immer kleineren Bereich des Bildes einnehmen. Gleichzeitig ist zu erwarten, dass ein größerer Abstand, insbesondere bei Regen, relevant ist, um die Wettereffekte adäquat zu erfassen. Aufgrund der baulichen Gegebenheiten kann die Kamera bis zu 3,5m vom Kalibrierungsmuster entfernt positioniert werden. Um die optimale Entfernung zu bestimmen, wird ein Experiment mit sowohl realen als auch synthetischen Bildern durchgeführt. Dazu wird das Stativ an einem klaren Tag in verschiedenen Abständen zum Kalibrierungsmuster aufgestellt und jeweils ein Bild aufgenommen. Anschließend werden diese Bilder auf ihre Qualität hin überprüft. Das Experiment wird in Kapitel 5.1.5 detailliert beschrieben.

Die Kamera wird nach ihrer Ausrichtung auf Serienbildaufnahme eingestellt, wobei alle fünf Minuten ein Bild mit einer Auflösung von 5k (5568 x 4872 Pixel) aufgenommen wird. Die Belichtungszeit passt sich automatisch an die vorherrschenden Lichtverhältnisse an. Ebenso

wird der Fokus automatisch eingestellt. Zudem wird der lineare Modus der GoPro-Kamera genutzt. Dieser Modus reduziert Verzerrungen, die durch die Fischaugenlinse entstehen [82], und bietet ca. einen 90°-Blickwinkel (Field of View).

Effekte bei klaren Wetterbedingungen




(a) Lens Flare Effekt am Vormittag.




(b) Reflexionen durch Fenster am Vormittag.




(c) Schattenwurf am Nachmittag.



(d) Schattenwurf später am Nachmittag.



(e) Reflexionen durch die Akku Box.



(f) Beleuchtete Fenster in der Nacht.

Abbildung 5.3.: Kalibriermuster zu verschiedenen Tageszeiten mit ausgewählten, tageszeitabhängigen Effekten bei klarem Wetter.

Durch die Positionierung der Kamera und die Umgebung treten bei klaren Wetterbedingungen verschiedene zeitlich begrenzte Effekte auf. Die Kamera ist nach Osten ausgerichtet, was morgens zu Lens-Flare-Effekten führen kann (Abbildung 5.3a). Zusätzlich befindet sich hinter der Kamera und gegenüber vom Kalibriermuster ein Gebäudeteil mit Fenstern, durch die es morgens zu Reflexionen kommen kann, die zu hellen Stellen auf dem Kalibriermuster führen (Abbildung 5.3b). Am Nachmittag entstehen Schatten durch den Gebäudeteil hinter der Kamera (Abbildungen 5.3c, 5.3d). Ein weiterer Reflexionseffekt tritt bei einem bestimmten Sonnenstand durch die Box auf, in der der Akku für die Kamera untergebracht ist. Obwohl ein Handtuch als Schutz vor starken Reflexionen auf die Box gelegt wurde, kann es noch immer zu Reflexionen kommen, die jedoch nicht bis zum Kalibriermuster reichen (Abbildung 5.3e). Der letzte beobachtete Effekt entsteht durch die Fenster rechts und links vom Kalibriermuster. In einigen Nächten ist der Raum beleuchtet, wodurch die Fenster hell hervortreten (Abbildung 5.3f). Dies kann die automatische Beleuchtungszeit negativ beeinflussen und es erschwert die automatische Erkennung, ab wann die Aufnahme vom Kalibriermuster zu dunkel für eine sinnvolle Auswertung ist. Die Bestimmung, ab wann ein Bild als zu dunkel gilt, wird im Absatz *Auswahl der relevanten Bilder für die Differenzanalyse* erläutert.




Abbildung 5.4.: Kalibriermuster mit durch Sonnenschein bedingten Schattenwurf auf einem Bild mit Regeneffekten.

Effekte bei Regen

Regen bewirkt hauptsächlich die in Abbildung 4.1 dargestellten Effekte. Auf einigen Bildern ist Schatten sichtbar, der auf Sonnenschein zurückzuführen ist (siehe Abbildung 5.4). Es wird außerdem beobachtet, dass die Sichtbarkeit der Tropfen auf dem Kalibriermuster je nach Belichtung stark variiert.

Erzeugung der Metadatei

Im Zeitraum vom 18. Juni 2025 bis zum 6. August 2025 werden mit dem beschriebenen Aufbau erzeugt insgesamt 9793 Bilder. Eine Metadatei wird für diesen gesamten Datensatz erstellt. Jeder Eintrag für ein Bild in dieser Metadatei enthält den Dateinamen des Bildes, das Datum der Aufnahme, die Aufnahmezeit und den ursprünglich zugeordneten METAR-Bericht. Da die Wetterberichte in einem 30-Minuten-Abstand erstellt werden, können die zeitlichen Abweichungen zwischen dem Aufnahmezeitpunkt des Bildes und dem Zeitpunkt des Wetterberichts bis zu 15 Minuten betragen. Deshalb werden sowohl der Aufnahmezeitpunkt des Bildes als auch die im METAR-Bericht angegebene Uhrzeit gespeichert. Es ist zu beachten, dass die METAR-Wetterdaten immer in koordinierter Weltzeit (Koordinierte Weltzeit / englisch: coordinated universal time (UTC)) angegeben werden, während der Aufnahmezeitpunkt des Bildes in mitteleuropäischer Sommerzeit (Mittleuropäische Sommerzeit (MESZ)) angegeben wird.

Auswahl der relevanten Bilder für die Differenzanalyse

Viele der aufgezeichneten realen Bilder sind aufgrund ihrer Eigenschaften für die Differenzanalyse nicht geeignet. Dazu gehören alle während der Nacht aufgenommenen Bilder, die zu dunkel sind, sowie Bilder, die unter Wetterbedingungen aufgenommen wurden, die im Rahmen dieser Arbeit nicht betrachtet werden sollen. Die Selektion der relevanten Bilder erfolgt in zwei Schritten. Zuerst filtert ein Python-Skript alle potenziell geeigneten Bilder heraus. Im zweiten Schritt werden diese Bilder manuell sortiert und bewertet, um sicherzustellen, dass nur geeignete Bilder für die weitere Analyse verwendet werden.

Im ersten Schritt nutzt das Python-Skript die vorsortierten Wetterberichte, indem es nach Bildern sucht, die innerhalb eines zeitlichen Abstands von maximal 10 Minuten vor oder nach einem relevanten Wetterbericht aufgenommen wurden. Dieser Zeitraum von 10 Minuten wird gewählt, um die Wahrscheinlichkeit stark veränderter Wetterbedingungen zwischen der Bildaufnahme und dem Wetterbericht zu minimieren. Wenn ein Bild gefunden wird, das dieses Kriterium erfüllt, wird die Helligkeit des Bildes ermittelt. Wenn die Helligkeit unter einem Schwellenwert von 25 liegt, wird das Bild als zu dunkel angesehen und nicht weiter betrachtet.

Ein Helligkeitskriterium ist erforderlich, um Bilder, die bei Nacht aufgenommen wurden, herauszufiltern. Da die Verwendung von RGB-Kameras in der Dunkelheit nicht sinnvoll ist, kann ein solches Kriterium eingeführt werden, ohne die Aussagekraft der Differenzanalyse in diesem Zusammenhang zu beeinträchtigen. Zunächst könnte der Zeitpunkt des Sonnenauf- und -untergangs als Alternative zum Helligkeitskriterium dienen. Da dieser Zeitpunkt jedoch täglich variiert und über die siebenwöchige Aufnahmezeit erheblichen Schwankungen unterliegt, wird entschieden, ihn nicht als Entscheidungskriterium heranzuziehen. Stattdessen ermöglicht das Helligkeitskriterium zusätzlich die Nutzung von Bildern aus der Dämmerung, die noch als hell genug eingestuft werden.

Die Auswahl des Schwellwertes von 25 erfolgt in Kombination mit dem Canny-Algorithmus, einem weit verbreiteten Verfahren zur Bestimmung einfacher Features. Dieser Algorithmus ist repräsentativ für eine Vielzahl von Verfahren zur Feature-Bestimmung, die in Umweltwahrnehmungssystemen eingesetzt werden. Die Ergebnisse werden als Anhaltspunkte für die Verwendbarkeit eines Bildes in der Umweltwahrnehmung betrachtet, wobei ein Bild mit sehr wenigen Features aufgrund von Dunkelheit als nicht verwendbar gilt. Für eine große Anzahl an Bildern wird sowohl die Helligkeit als auch die Anzahl von Pixeln bestimmt, die vom Canny-Algorithmus als Kanten wahrgenommen werden. Die Analyse zeigt, dass bei den meisten Bildern mit einer Helligkeit zwischen 60 und 150 zwischen 100.000 und 190.000 Kantenpixel gefunden werden. Bei Bildern mit einer Helligkeit zwischen 25 und 60 liegen die Kantenpixel hauptsächlich zwischen 30.000 und 100.000. Bei Bildern mit einer Helligkeit unterhalb von 25 können - mit Ausnahme von lediglich vier Bildern - nur noch maximal 25.000 Kantenpixel gefunden werden. Da dies weniger als ein Viertel der Kanten sind, die bei hellen Bildern gefunden werden, ist davon auszugehen, dass in diesen Bildern viele wichtige Features fehlen. Daher wird 25 als Helligkeitsschwellwert festgelegt.

Die wichtigsten Informationen zu den Bildern, die das Helligkeitskriterium erfüllen, werden in Logdateien gespeichert. Für jedes betrachtete Wetter gibt es eine eigene Logdatei. Jeder Eintrag für ein Bild enthält das Datum und die Uhrzeit der Bildaufnahme, die wichtigen Informationen aus dem zugehörigen METAR-Bericht sowie den Bildnamen. Ein Beispiel für einen solchen Logdateieintrag für Regenbilder befindet sich in Anhang Abbildung A.1.

Neben dem Eintrag in die passende Logdatei werden die Bilder in Ordner sortiert, um anschließend manuell überprüft zu werden. Bei CAVOK-Bildern werden Bilder mit Lens Flare und Reflexionen aussortiert, da diese vorerst nicht in der Simulation nachgebildet werden sollen. Außerdem gibt es Bilder, die durch beleuchtete Fenster zwar das Helligkeitskriterium erfüllen, aber dennoch das Kalibriermuster für eine sinnvolle Auswertung zu dunkel ist. Diese Bilder werden ebenfalls manuell aussortiert. Regen- und Sprühregenbilder aller Intensitäten werden auf Anzeichen von Regen untersucht. In dieser Arbeit werden fallende Regentropfen, Tropfen auf dem Kalibriermuster und Tropfen auf der Linse (siehe Abbildung 4.1) gezählt.

Nach dem Sortieren der Bilder werden diese auf das Kalibriermuster zugeschnitten, um die Differenzanalyse ausschließlich auf dem Kalibriermuster durchführen zu können und Einflüsse durch den Hintergrund auszuschließen. Zum Zuschneiden der Bilder wird die OpenCV [83] Funktion `warpPerspective` verwendet. Beim Zuschneiden wird berücksichtigt, dass das Stativ am 07.07.2025 getauscht wurde, was zu einer leichten Veränderung der Kameraposition geführt hat. Allerdings können minimale Veränderungen in der Kameraposition durch mechanische Einflüsse wie Wind, Handhabung der Kamera oder Spiel im Stativ nicht berücksichtigt werden.

Kritische Würdigung des Vorgehens

Die Vorgehensweise zur Erzeugung des realen Datensatzes besitzt einige Einschränkungen. Aufgrund der zeitlichen Inkonsistenz zwischen der Bildaufnahme im Fünf-Minuten-Rhythmus und der Übertragung von Wetterdaten alle halbe Stunde besteht eine Unsicherheit hinsichtlich der Korrektheit der Wetterdaten für die Bilder. Dies macht ein manuelles Sortieren der Bilder erforderlich. Mit zunehmender Größe des Datensatzes wird dieser Schritt immer arbeitsintensiver. Für zukünftige Bildaufnahmen wäre es vorteilhaft, eine eigene Wetterstation mit Logfunktion in der Nähe des Versuchsaufbaus zu installieren. Dies hätte auch den Vorteil, die Windrichtung genauer zu bestimmen. Da der Versuchsaufbau in der Mitte einer U-förmigen Gebäudestruktur aufgebaut ist, müssen die Windverhältnisse vor Ort nicht mit den gemessenen Windverhältnissen auf freier Fläche übereinstimmen. Des Weiteren ist zu beachten, dass der Aufbau während der gesamten sieben Wochen nach Osten ausgerichtet war. Eine künftige Ausrichtung des Aufbaus in andere Himmelsrichtungen könnte interessante Ergebnisse liefern und zeigen, ob sich dadurch Unterschiede in den Bildern ergeben.

Bei der Auswahl von Bilddaten für die Differenzanalyse wird ein Helligkeitskriterium angewendet, das auf den ursprünglichen, unbeschnittenen Bilddaten basiert. Nach der Festlegung des Kriteriums werden die Bilder beschnitten. Dies führt dazu, dass Bilder mit beleuchteten Fenstern, aber kaum sichtbarem Kalibriermuster, das Helligkeitskriterium erfüllen und daher manuell ausgesondert werden müssen. Es wäre sinnvoll, den gewünschten Bildausschnitt vor der Sortierung zu beschränken und anschließend zu sortieren bzw. geeignete Kriterien festzulegen.

Weiterhin gibt es einige ungelöste Probleme mit dem Setup der Kamera. Um die Kamera vor Regen zu schützen, wird eine wasserfeste Hülle verwendet. Trotzdem sammelt sich nach einigen Tagen Wasser in der Hülle. Die Kamera muss dann aus der Hülle genommen und getrocknet werden. Darüber hinaus ist die Kamera nicht vor direkter Sonneneinstrahlung geschützt und kann bei hohen Temperaturen überhitzen. Die Kamera schaltet sich bei Außentemperaturen über 30°C automatisch aus und muss manuell wieder eingeschaltet werden.

5.1.4. Synthetischer Datensatz

Verwendete Plugins

Der synthetische Datensatz wird mit Unreal Engine und einem DLR internen Plugin für Wetereffekte erzeugt. Um aussagekräftige Ergebnisse für die spätere Anwendung von simulierten Flugversuchen zu erzeugen, wird bei der Erzeugung der synthetischen Daten bereits auf die Echtzeitfähigkeit der Lösung geachtet.

Das DLR-interne Plugin SenSim2 wird für die Sensorsimulation von Flugzeugen und unbemannten Luftfahrzeugen in der Unreal Engine 5 eingesetzt. Ziel des Plugins sind Echtzeitanwendungen mit kontinuierlichem Datenaustausch. Es verfügt über mehrere Module, wodurch es flexibel in verschiedene Projekte integriert werden kann. Ein Modul für Kameras vereinfacht die Nutzung, Einstellung und das Generieren von Kameradaten. Dieses Modul greift auf die Postprocessing-Einstellungen der Unreal Engine zu [63]. Ein weiteres Modul ermöglicht die Änderung von Einstellungen während der laufenden Simulation durch Python-Skripte sowie das Auslesen von Daten. Dies kann beispielsweise genutzt werden, um Kameradaten auszulesen und zu speichern. Neben der virtuellen Abbildung einer Vielzahl von Sensoren und der Möglichkeit, deren Daten auszulesen, bietet SenSim2 zudem ein Modul zur Wettersimulation. Dieses umfasst eine grundlegende, nicht physikalisch basierte Darstellung von Nebel, Regen und Schnee sowie den Einfluss von Wind auf diese Effekte. Die Simulation von Regen wird dabei mithilfe eines Partikelsystems erzeugt. SenSim2 nutzt Georeferencing, wodurch es möglich ist, den geografisch korrekten Standort der Simulation einzustellen und darüber hinaus den Sonnenstand zu berechnen. Der Sonnenstand selbst wird intern von der Unreal Engine im SunSky Actor berechnet [62]. Die Georeferenz wird zuvor in einer Konfigurationsdatei im YAML Ain't Markup Language (yaml)-Format (YAML Ain't Markup Language) definiert und zu Beginn der Simulation eingelesen.

Erweiterung: Berechnung von Regentyp und Regenintensität nach dem METAR Format

Die bisherige Implementierung für Regen ermöglicht ausschließlich die Einstellung der Partikelanzahl. Dieser Ansatz hat zwei Nachteile: Er ist nicht intuitiv für die Einstellung der Regenintensität und er berücksichtigt nicht die Unterscheidung zwischen Sprühregen und Regen, die unterschiedliche Tröpfchengrößen erfordert. Zur Erreichung einer realistischeren Darstellung von Regen wird das Plugin erweitert. Die Erweiterung umfasst Einstellungsmöglichkeiten für den Regentyp (Sprühregen/Regen), die Regenintensität (schwach, mäßig, stark) und die Belichtungszeit der Kamera in der Konfigurationsdatei. Diese Einstellungen ermöglichen die Berechnung der erforderlichen Parameter für den Regen-Partikeleffekt.

Die Regentropfengröße wird durch den Typ des Regens bestimmt, wobei nicht eine feste Größe, sondern eine Spanne angegeben wird. Die Tröpfchengröße von Sprühregen reicht von 0,1 bis 0,5mm, während die Spanne für Regen von 0,5 bis 5mm reicht. Tropfen mit einem größeren Durchmesser als 5mm brechen, wie in Kapitel 4.1.1 beschrieben, und werden daher nicht weiter berücksichtigt. Um die Partikelgröße in der Simulation zu bestimmen, wird im Niagara-System unter *InitializeParticle* der *Sprite Size Mode* auf *Random Non-Uniform* eingestellt. Dies ermöglicht es, die Größe jedes Partikels zufällig aus der angegebenen Spanne auszuwählen. Als Parameter werden zwei benutzerdefinierte Variablen übergeben, die die möglichen Partikelgrößen für die x- und y-Richtung speichern. Diese Variablen werden von einem Python Skript entsprechend des eingestellten Regentyps angepasst. Die x-Richtung (Breite der Partikel) gibt die Tröpfchengröße an, während die y-Richtung (Länge der Partikel) auf einen anderen Wert eingestellt werden muss, um den Effekt von Regentropfen als Streifen auf Bildern zu simulieren. Obwohl Regentropfen vereinfacht als Kugel angenommen werden können, erscheinen sie auf Bildern aufgrund der Belichtungszeit als Streifen. In der Unreal Engine werden Bilder sofort aufgenommen, daher muss dieser Effekt simuliert und in den Einstellungen des Partikeleffektes berücksichtigt werden. Die künstliche Verzerrung der simulierten Tropfen in die Fallrichtung wird als Länge der Partikel bezeichnet. Diese Partikellänge berücksichtigt die normale Höhe von realen Regentropfen, die durchschnittliche Geschwindigkeit der Regentropfen und die

Tabelle 5.1.: Benötigte Partikelanzahlen pro Quadratmeter entsprechend dem Regentyp und der Intensität.

Regentyp/-intensität	Niederschlagshöhe pro Stunde (mm/h)	Partikelanzahl pro m ²
leichter Sprühregen	0,01 - 0,1	196 - 1965
mäßiger Sprühregen	0,1 - 0,5	1965 - 9824
starker Sprühregen	0,5 - 5	9824 - 98244
leichter Regen	0,1 - 2,5	3 - 63
mäßiger Regen	2,5 - 10	63 - 255
starker Regen	10 - 50	255 - 1275

Belichtungszeit der Kamera. Die Formel zur Berechnung der Länge der Partikelgröße lautet wie folgt:

$$Partikellänge = Größe + Geschwindigkeit * Belichtungszeit \quad (5.1)$$

Für Sprühregen wird eine Geschwindigkeit von 2 m/s angenommen. Diese Annahme basiert auf der Maximalgeschwindigkeit, die Regentropfen dieser Größe erreichen können, wie in Kapitel 4.1.1 erläutert. Da die Aufnahmen in Bodennähe sind, kann angenommen werden, dass die Regentropfen ihre maximale Fallgeschwindigkeit bereits erreicht haben. Für Regen wird eine Geschwindigkeit von 6 m/s angenommen.

$$V_{Kugel} = \frac{4}{3} * \pi * r^3 \quad (5.2)$$

$$Partikelanzahl_l = \frac{1.000.000}{V_{Kugel}} [Partikelanzahl/l] V_{Kugel}[mm^3] \quad (5.3)$$

Die Intensität des Regens kann entsprechend den Angaben im METAR-Format als leicht, mäßig oder stark eingestellt werden. Diese Einstellung wird in Kombination mit dem Regentyp verwendet, um die Anzahl der Partikel zu berechnen. Aus dem Regentyp kann die durchschnittliche Größe eines Regentropfens und das entsprechende Wasservolumen berechnet werden, indem angenommen wird, dass die Wassertropfen eine Kugelform haben. Die Formel für das Volumen (V) einer Kugel mit Radius r kann daher verwendet werden (siehe Gleichung 5.2). Daraus ergibt sich die Anzahl durchschnittlicher Tropfen, die zusammen ein Liter, also 1.000.000 mm³ Wasser, ergeben (siehe Gleichung 5.3). Die Niederschlagsintensität wird als Niederschlagshöhe pro Zeiteinheit angegeben (siehe Kapitel 4.1.1). Ein Liter Wasser pro Quadratmeter entspricht dabei einer Niederschlagshöhe von 1 mm. Mit diesen Angaben und den Gleichungen 5.2 und 5.3 kann eine Gleichung zur Berechnung der Anzahl durchschnittlicher Tropfen pro Sekunde und Quadratmeter hergeleitet werden. Unter der Annahme, dass die betrachtete Zeiteinheit einer Stunde entspricht, ergibt sich folgende Gleichung:

$$Partikelanzahl = \frac{1.000.000}{Volumen_{Kugel}} * \frac{Niederschlagsintensität}{3.600} \left[\frac{Partikelanzahl}{mm^2 * s} \right] \quad (5.4)$$

, $V_{Kugel}[mm^3]$, $Niederschlagsintensität[\frac{mm}{h}]$

Daraus ergeben sich für die Regentypen und Intensitäten die in Tabelle 5.1 angegebenen Partikelmengen. Um die offenen Intervalle für schwache und starke Intensität zu definieren, werden zusätzliche Grenzen festgelegt. Beim Sprühregen wird eine untere Grenze von 0,01 mm/h gewählt, da dieser Wert als niedrig genug angesehen wird. Für schwachen Regen wird eine untere Grenze von 0,1 mm/h definiert, da erst ab diesem Wert mehr als 1 Partikel pro Quadratmeter generiert wird. Als obere Grenze für starken Sprühregen werden 5 mm/h festgelegt, da die daraus resultierenden nahezu 100.000 Partikel pro simuliertem Quadratmeter bei wenigen Quadratmetern Simulationsfläche zu Warnungen der Unreal Engine führen können. Für starken Regen wird eine obere Grenze von 50 mm/h gewählt, die der Definition des Deutschen Wetterdienstes für sehr starken Regen entspricht. Da die Niederschlagsintensität immer eine Spanne angibt und keine genauen, gemessenen Werte im METAR-Bericht angegeben werden, wird während der Laufzeit ein zufälliger Wert aus dem korrekten Bereich ausgewählt. Hierfür wird die Funktion `FRandomStream` aus dem Unreal Engine Ökosystem verwendet, wobei die aktuelle Uhrzeit als Seed genutzt wird.

Erweiterung: Regentropfen auf Objekten und der Kameralinse

Zusätzlich zu der Erweiterung des Partikel Systems für die fallenden Regentropfen, wird das bestehende Plugin erweitert, um Regentropfen auf Oberflächen zu simulieren. Anstatt auf Texturen zurückzugreifen, die in ihrer Variabilität eingeschränkt sind, wird ein System entwickelt, das die reale Entstehung dieser Regentropfen nachbildet. Dies ermöglicht nicht nur eine Vielzahl verschiedener Muster, sondern auch die korrekte Positionierung der Regentropfen entsprechend den Wetterbedingungen, insbesondere dem Wind.

Die aktuelle Version des Wetterplugins verwendet das Regen-Niagara-System, um Kollisionen zwischen Regenpartikeln und anderen Objekten in der Szene zu berechnen. Die Unreal Engine ermöglicht die Nutzung von Kollisionsdaten für verschiedene Zwecke. Wenn die Partikel auf der Zentrale Verarbeitungseinheit / englisch: Central Processing Unit (CPU) berechnet werden, können die Kollisionskoordinaten direkt an andere Emitter übermittelt werden. Allerdings wird das Regen-Niagara-System aufgrund der großen Anzahl an möglichen Partikeln auf der Grafikprozessoren / englisch: Graphics Processing Unit (GPU) berechnet. In diesem Fall ist eine direkte Übertragung der Daten an andere Emitter im gleichen Niagara-System nicht möglich. Stattdessen kann das Modul *Export Particle Data to Blueprint* verwendet werden, um die Daten an einen Blueprint zu übermitteln. Dazu muss eine neue Objektvariable im Niagara-System erstellt werden, die den gewünschten Blueprint referenziert. Diese Möglichkeit der Datenübermittlung wird genutzt, indem ein Blueprint namens BP_DropCollision erstellt wird. Der Blueprint ist in Abbildung A.2 im Anhang dargestellt. Im ersten Schritt wird das Regen-Niagara-System als Komponente in den Blueprint integriert, wodurch das Niagara-System an den Blueprint gekoppelt wird und automatisch eine Instanz des Niagara-Systems erstellt wird, wenn der Blueprint in einem Level existiert.

Um die Kollisionen im Blueprint zu nutzen, muss zunächst eine Referenz zum Blueprint innerhalb des Niagara-Systems erstellt werden. Dies geschieht mithilfe der *Set Niagara Variable By String (Object)*-Node. Anschließend kann die *Event Receive Particle Data*-Node genutzt werden, um die gesammelten Daten von Regenpartikeln, die kollidiert sind, zu erhalten. Diese Daten werden pro Tick (Aktualisierungsaufwurf pro Frame) zurückgegeben. Im nächsten Schritt werden die Daten einzeln betrachtet und mit der *Break BasicParticleData*-Node werden die relevanten Daten, in diesem Fall die Position der Kollision, gefiltert. Die Position wird dann an die *Spawn System at Location*-Node weitergegeben, die direkt an der Position der Kollision ein weiteres

Niagara-System namens NS_Drop spawnt, das einen einzelnen Partikel in der Form einer Kugel enthält.

Das beschriebene Basissetup weist den Nachteil auf, dass jeder fallende Regentropfen auf einem Objekt einen Regentropfen erzeugt, unabhängig von der Relevanz des Kollisionsbereichs. Insbesondere bei Sprühregen mit bis zu 98244 Partikeln pro Quadratmeter und Sekunde führt dies zu einer schnellen Anhäufung unnötiger Partikel, die Rechenressourcen beanspruchen. Um dies zu vermeiden, soll die Erzeugung von Regentropfen nur auf relevanten Objekten erfolgen. Dazu wird der Blueprint entsprechend erweitert. Alle zu berücksichtigenden Objekte müssen mit dem Actor-Tag „Target“ versehen werden. Im Blueprint werden diese Objekte zu Beginn gefiltert. Anschließend werden für jeden Tick die gesammelten Kollisionsdaten und die Positionen der Objekte verglichen. Bisher werden nur Kollisionen akzeptiert, die weniger als 1,5 m vom Zentrum des Objekts entfernt sind. Für das Kalibrieremuster reicht diese Definition aus, jedoch muss sie möglicherweise in Zukunft angepasst werden, um auch größere Objekte zu berücksichtigen. Die erweiterte Version des BP_DropCollision-Blueprints ist in Abbildung A.3 im Anhang dargestellt.

Erweiterung: Regenmaterialien

Neben der Erweiterung des Niagara Systems und der Einführung des Blueprints zur Regentropfenerzeugung auf Objekten, werden die Materialien für fallende Regentropfen angepasst und ein neues Material für Regentropfen auf Objekten eingeführt. Beide Materialien werden in mehreren Iterationen an das Erscheinungsbild von Regentropfen auf realen Bilddaten angepasst. Die Anpassung beschränkt sich auf Farbe und Transparenz. Physische Eigenschaften wie Lichtbrechung und Reflexion finden keine Berücksichtigung.

Erweiterung: Windberechnung entsprechend dem METAR Format

Wie bereits erwähnt, berücksichtigt das SenSim-Plugin den Wind, der die Fallrichtung der Regentropfen beeinflusst. Dabei werden die x- und y-Komponenten des Windes getrennt an die Simulation übermittelt, um die Stärke und Richtung des Windes zu beschreiben. Im METAR-Format werden die Windstärke und -richtung angegeben, wobei die Windrichtung als die Richtung angegeben wird, aus der der Wind kommt, und in Grad ausgedrückt wird (0° entspricht einem Wind aus Norden). In der Unreal Engine hingegen werden die x- und y-Koordinaten des Windes verwendet, um die Stärke des Windes nach Osten bzw. Süden anzugeben. Darüber hinaus wird die Windstärke in der Unreal Engine in cm/s angegeben, während im METAR-Format Knoten verwendet werden. Um das METAR-Format in das für die Unreal Engine erforderliche Format umzurechnen, müssen daher die Windstärke und -richtung entsprechend umgerechnet werden. Mit der Umrechnungsfaktor von $1kt = 51,444cm/s$ ergeben sich folgende Formeln für die Konvertierung:

$$x = -\sin(\alpha) * v * 51,444 \quad (5.5)$$

$$y = \cos(\alpha) * v * 51,444 \quad (5.6)$$

Dabei stellt α den im METAR-Bericht angegebenen Winkel dar, und v repräsentiert die Windgeschwindigkeit in Knoten. Die Umrechnung muss derzeit außerhalb der Unreal Engine durchgeführt werden und die korrigierten Werte müssen bereits in der YAML-Konfigurationsdatei eingetragen sein.




Abbildung 5.5.: Simulationsumgebung (Nachbildung des realen Versuchsaufbaus) zur Generierung des synthetischen Datensatzes

Erzeugung der simulierten Bilder

Das erweiterte SenSim Plugin ermöglicht die Simulation aller in dieser Arbeit betrachteten Wetterphänomene, einschließlich der Einstellung des Sonnenstands. Um synthetische Bilder realistisch zu erstellen, wird ein Python Skript eingesetzt, das relevante METAR-Daten direkt in die Simulation übermittelt und somit den Schritt der manuellen Erstellung einer yaml-Konfigurationsdatei für jedes Bild überflüssig macht. Um die simulierten Daten den realen möglichst weit anzupassen, nutzt dieses Skript die zuvor beschriebenen Logdateien für reale Bilder, um die simulierten Daten den realen möglichst weit anzupassen. Die Simulation erfolgt für alle Bilder einer Wetterlage am Stück, sodass die Wettereinstellungen (klares Wetter, Regen oder Nieselregen und die jeweiligen Intensitäten) nur einmal vorgenommen werden müssen. Anschließend werden für jedes Bild lediglich Datum, Uhrzeit und Wind angepasst. Das Skript, welches diese Daten an die Unreal Engine sendet, liest auch die Daten der virtuellen Kamera aus und speichert die Bilder ab. Um die korrekte Einstellung der Wetterphänomene - insbesondere des Sonnenstands, welcher über mehrere Frames angepasst wird - in der Simulation sicherzustellen, wird zwischen dem Senden der neuen Daten und dem Abruf aktueller Kameradaten jeweils eine Wartezeit von einigen Sekunden eingehalten. Zudem ermöglicht das Skript die Einstellung der Anzahl simulierter Bilder pro realem Bild, was besonders bei Wetterbedingungen mit variablen Einflüssen auf das Bild, wie z.B. Regen, nützlich ist.

Simulationsumgebung

Die Simulationsumgebung wird anhand des realen Versuchsaufbaus modelliert (siehe Abbildung 5.5). Hierfür werden die Koordinaten des Versuchsaufbaus für das Georeferencing-System der Unreal Engine ermittelt und entsprechend konfiguriert. Mithilfe von Cesium [84] erfolgt die Bestimmung der Positionen und Umrisse der Gebäude, die anschließend in 3D-Modelle umgewandelt werden. Die korrekte Höhe der Gebäude wird durch Aufzeichnungen des Gebäudemaneagements des DLR bestimmt. Sowohl das Kalibriermuster als auch die Kamera werden in der Simulation gemäß den ausgemessenen Positionen im realen Versuchsaufbau platziert, wobei auch die Ergebnisse des Versuchs zur Bestimmung der Entfernung zwischen Kalibriermuster und Kamera (siehe Kapitel 5.1.5) berücksichtigt werden.

Im Unterschied zum realen Versuchsaufbau werden die Gebäude in der Simulation ohne Fenster modelliert. Dieser Ansatz vermeidet Reflexionen, die am Vormittag durch die Fenster auftreten könnten. Ebenso wird die Kiste, die den Akku für die Kamera enthält, nicht simuliert, wodurch die durch die Kiste verursachten Effekte in der Simulation nicht nachgebildet werden. Infolgedessen werden diese Effekte aus den realen Daten herausgerechnet, um eine Vergleichbarkeit zwischen simulierten und realen Daten zu gewährleisten.

Kritische Würdigung der simulierten Bilddaten

Im Zuge der Erzeugung der ersten Bildergebnisse wird ein manueller Vergleich dieser mit dem realen Datensatz durchgeführt. Bei diesem Vergleich werden verschiedene Effekte beobachtet. Insbesondere stechen zwei Effekte hervor, die sowohl CAVOK- als auch Regenbilder betreffen und in direktem Zusammenhang mit der Simulation der Sonne stehen. Einerseits wird beobachtet, dass die Farben in der Simulation stark überspitzt dargestellt werden. Im Gegensatz dazu zeigen die realen Bilder nur eine geringe Variationsbreite an Farbveränderungen über den Verlauf des Tages. In den synthetischen Bildern hingegen erstreckt sich die Farbpalette von sehr klarem Weiß über einen Braunstich, welcher in realen Bildern auch beobachtet wird, bis hin zu einem Lilafarbtönen (siehe Abbildung A.4 im Anhang). Diese starken Farbänderungen können in der Simulation nicht ohne eine Modifikation des Pakets, das zur Berechnung des Sonnenstands verwendet wird, direkt korrigiert werden.

Der zweite Effekt zeigt, dass nicht nur die Farben bei der Berechnung des Sonnenstandes fehlerhaft sind, sondern auch die allgemeine Position der Sonne. Ein paar reale Bilder liegen über der vorgegebenen Helligkeitsgrenze, während ihre simulierten Gegenstücke vollkommen schwarz erscheinen. Ein Beispiel ist in Abbildung A.5 im Anhang dargestellt. In der Simulation gibt es zudem keinen Zeitpunkt am Tag, an dem der Schatten vom gegenüberliegenden Gebäudeteil auf das Kalibriermuster trifft. Dies deutet darauf hin, dass die Höhe der Sonne in der Simulation nicht korrekt berechnet wird, obwohl die Georeferenz und das Datum korrekt übertragen werden. Diese Fehler können nur durch einen Wechsel der Pakete oder die Entwicklung eines eigenen Tools für die Berechnung der Sonnenposition behoben werden. Folglich werden sie in der restlichen Arbeit nicht weiter betrachtet, stellen jedoch erste Fehlerquellen dar.

Das dritte identifizierte Problem betrifft ausschließlich Regenbilder. Obwohl die vorgestellte Lösung für Regentropfen auf Objekten effektiv für das Kalibriermuster ist, liegen keine synthetischen Bilder mit Tropfen auf der Linse vor. Die Gründe dafür können vielfältig sein. Aufgrund der begrenzten Anzahl relevanter realer Bilder mit Tropfen auf der Linse wird entschieden, diesen Effekt in der Simulation nicht zu berücksichtigen.

Weiterhin zeigen die simulierten Regentropfen eine von den Erwartungen abweichende Form. Obwohl die Tropfengröße an realen Werten ausgerichtet ist, erscheinen die simulierten Regentropfen in der Breite überdimensioniert im Vergleich zu realen Bildern. Eine Anpassung der Regentropfen für die aktuelle Arbeit unterbleibt. Für zukünftige Arbeiten wird eine eingehende Untersuchung der Ursachen für diese Diskrepanz vorgeschlagen.

Außerdem werden in der Simulation Reflexionen und Bewölkungen jeglicher Art vernachlässigt. Dies sollte in Zukunft ebenfalls angepasst werden.

5.1.5. Experiment zur Entfernungsbestimmung

Das Experiment wird durchgeführt, um den maximalen Abstand zu bestimmen, bei dem keine negativen Effekte durch die Entfernung zwischen Kamera und Kalibriermuster auftreten, die durch die geringere Auflösung bedingt sind. Die Ermittlung des maximalen Abstands ist relevant, da eine größere Entfernung zwischen Kamera und Kalibriermuster die Effekte durch Wetterbedingungen wie Regen verstärken kann [43]. Um den maximalen Abstand zu bestimmen, werden Bilder in verschiedenen Entfernungen (2 m, 2,5 m, 3 m und 3,5 m) sowohl im realen Versuchsaufbau als auch in der Simulation aufgenommen. Anschließend werden alle Bilder mithilfe eines Canny-Edge-Detektors analysiert. Die Ergebnisse zeigen,

dass die Kantenerkennung in den synthetischen Bildern ab einer Entfernung von 3 m deutlich schlechter ist als bei geringeren Abständen. Insbesondere die Linien im unteren rechten Bereich des Kalibriermusters werden nicht mehr korrekt dargestellt. Einige Punkte, die die Linie bilden, verschmelzen zu größeren Punkten, sobald der Abstand 2,5 m übersteigt. Bei den realen Daten ist der Unterschied zwischen den Bildern weniger ausgeprägt, jedoch kann eine leichte Abnahme der Genauigkeit mit zunehmender Entfernung beobachtet werden. Da eine präzise Auswertung der synthetischen Bilder wichtig ist, wurde ein Abstand von 2,5 m gewählt.

5.2. Charakterisierung der Datensätze

Tabelle 5.2.: Charakterisierung der erzeugten Datensätze.

Name	Anzahl Bilder	Erzeugungsart	Wetterphänomene	Varianten
Real-Gesamt	9793	real	- CAVOK - Regen - verschiedene Bewölkungen - Sprühregen, - Hagel - Gewitter - Nebel	- original
Real-CAVOK	429	real	- CAVOK	- original - zugeschnitten
Real-Regen	166	real	- Regen aller Intensitäten	- original - zugeschnitten
Sim-CAVOK	429	simuliert	- CAVOK	- original - zugeschnitten
Sim-Regen	166	simuliert	- Regen aller Intensitäten	- Datensätze 0, 1 und 3 jeweils in: - original - zugeschnitten
Schatten-CAVOK	17	real	- CAVOK (nur Schattenbilder)	- zugeschnitten
Schatten-Regen	5	real	- Regen (nur Schattenbilder)	- zugeschnitten
Tropfen-Regen	6	real	- Regen (nur Bilder mit Tropfen auf der Linse)	- zugeschnitten

Aus den 9793 realen Bilddaten und den erzeugten synthetischen Bildern werden mehrere Datensätze generiert, die in Tabelle 5.2 zusammengefasst sind und im Folgenden näher charakterisiert werden. Dabei wird die Anzahl an Bildern, die Erzeugungsart, die abgebildeten Wetterphänomene, die Versionen des Datensatzes und die vorgesehene Verwendung näher betrachtet.

Datensatz: Real-Gesamt

Dieser Datensatz umfasst alle 9793 aufgenommenen realen Bilder. Er bleibt unsortiert, sodass auch sehr dunkle Bilder aus den Nächten enthalten sind. Die Bilder werden nicht zugeschnitten. Die aufgezeichneten Wetterphänomene sind vielfältig, wobei Bilder bei klarem Wetter, Regen oder verschiedenen Bewölkungen dominieren. Andere Wetterphänomene sind nur mit wenigen Bildern vertreten. Der Datensatz dient als Grundlage für die sortierten Datensätze. Er steht zudem für weitere Projekte innerhalb des DLR zur Verfügung.

Datensatz: Real-CAVOK

Der Real-Gesamt-Datensatz wird unter Verwendung der in Abschnitt 5.1.3 erläuterten Kriterien auf CAVOK-Bilder untersucht, woraus 429 Bilder hervorgehen, die für die Differenzanalyse genutzt werden können. Der Datensatz besteht aus CAVOK-Bildern, die über den gesamten Tag (mit Ausnahme der Nachtstunden) verteilt sind. Die Bilder werden sowohl im Originalformat als auch zugeschnitten für die Differenzanalyse verwendet. In Kapitel 6 wird erläutert, wann welche Variante des Datensatzes genutzt wird. Um zwischen den Varianten zu unterscheiden, wird die Bezeichnung der Variante, wenn nötig, an den Namen des Datensatzes angehängt.

Datensatz: Real-Regen

Der Real-Gesamt-Datensatz enthält Bilder von Sprühregen, aber das Sortierskript kann nur 10 Bilder identifizieren, von denen nur vier Bilder für Menschen erkennbare Anzeichen für Regen zeigen. Da vier Bilder für eine aussagekräftige Differenzanalyse nicht ausreichen, wird beschlossen, Sprühregen im weiteren Rahmen dieser Arbeit nicht mehr zu berücksichtigen.

Der Real-Regen-Datensatz besteht somit ausschließlich aus Bildern, die zu Zeiten mit Regen aller betrachteter Intensitäten aufgenommen wurden. Nach beiden Sortierungsschritten (Skript und manuelle Kontrolle) bleiben 62 Bilder von leichtem Regen, 81 Bilder von mäßigem Regen und 23 Bilder von starkem Regen übrig. Da diese Datensätze einzeln für eine aussagekräftige Differenzanalyse zu klein sind, werden alle geeigneten Regenbilder als Real-Regen-Datensatz zusammengefasst. Dieser Datensatz besteht aus 166 Regenbildern aller Intensitäten. Es werden zwei Varianten dieses Datensatzes erstellt: eine mit den originalen Bildern und eine mit zugeschnittenen Bildern. Im Rahmen dieser Arbeit wird der Datensatz für die Differenzanalyse verwendet. Im Vergleich zum Real-CAVOK-Datensatz fehlen Regenbilder aus den frühen Morgenstunden.

Datensatz: Sim-CAVOK

Dieser Datensatz enthält synthetische Bilder, die den Bildern im Real-CAVOK Datensatz nachempfunden sind. Da die Windverhältnisse für CAVOK-Bilder keine Rolle spielen, hängt die Darstellung lediglich vom Sonnenstand ab, der mit Datum und Uhrzeit variiert. Der Datensatz besteht somit ebenfalls aus 429 Bildern, die ausschließlich CAVOK-Bilder darstellen und sowohl in den Varianten „original“ als auch „zugeschnitten“ für die Differenzanalyse verwendet werden.

Datensatz: Sim-Regen

Der Sim-Regen-Datensatz wird durch Simulationen erstellt, die die Regenintensität, den Wind, das Datum und die Aufnahmeuhrzeit berücksichtigen. Für jedes reale Regenbild werden drei simulierte Regenbilder generiert. Diese Vorgehensweise zielt darauf ab, zufällige Fehler durch die

Anordnung der sichtbaren Regentropfen zu minimieren bzw. zu identifizieren. Der Sim-Regen-Datensatz besteht insgesamt aus 498 Bildern und wird in drei Subdatensätze, bzw. Varianten mit jeweils 166 Bildern unterteilt, die den Bildern des Real-Regen-Datensatzes entsprechen. Diese drei Varianten werden als Sim-Regen-Datensatz 0, 1 und 2 bezeichnet und stehen sowohl in Originalgröße als auch zugeschnitten zur Verfügung.

Datensatz zu speziellen Wetterbedingungen

Die Datensätze Schatten-CAVOK, Schatten-Regen und Tropfen-Regen werden als Sonderdatensätze zu speziellen Wetterbedingungen erstellt. Diese Datensätze erfassen Wetterbedingungen, die nicht in der Simulation nachgebildet werden können, aber als potenziell einflussreich angesehen werden. Der Datensatz Schatten-CAVOK enthält alle realen Bilder, auf denen Schatten auf dem Kalibriermuster sichtbar ist. Von den 429 realen CAVOK-Bildern erfüllen lediglich 17 Bilder diese Bedingung. Der Datensatz Schatten-Regen umfasst Bilder, die sowohl Schatten auf dem Kalibriermuster als auch Regeneffekte zeigen. Es können insgesamt 5 solcher Bilder identifiziert werden. Der Datensatz Tropfen-Regen betrachtet Regenbilder mit Tropfen auf der Kamera-Linse, die sich auf den Bereich des Kalibriermusters auswirken. Nur 6 Bilder erfüllen diese Bedingung. Aufgrund der geringen Anzahl an Bildern pro Datensatz ist eine zuverlässige Differenzanalyse nicht möglich. Trotzdem werden diese Bilder mit ausgewählten Methoden gesondert untersucht, um einen ersten Eindruck davon zu erhalten, ob diese Wetterbedingungen einen nennenswerten Einfluss haben können.

Kapitel 6.

Differenzanalyse der realen und synthetischen Daten

In diesem Kapitel werden die Ergebnisse der Differenzanalyse entsprechend der zuvor getroffenen Auswahl an Methoden und Daten dargestellt. Die Auswertung und Diskussion der Ergebnisse mit der Erklärung möglicher Ursachen erfolgt im nächsten Kapitel. Dieses und das nächste Kapitel gliedern sich jeweils in die zuvor vorgestellten Kategorien von Differenzanalysemethoden und anschließend in die einzelnen Methoden.

Für die einzelnen Kategorien wird dargelegt, welche Varianten der vorgestellten Datensätze verwendet werden. Obwohl für alle Kategorien alle drei Datensatzvarianten (0, 1, 2) des Sim-Regen-Datensatzes ausgewertet werden, stammen die präsentierten Daten alle vom Sim-Regen-Datensatz 0, da keine signifikanten Unterschiede bei der Auswertung der Varianten bestehen. Dies gilt für alle Kategorien und Methoden der Differenzanalyse.

Jede Methode in diesem Kapitel wird durch die Darstellung ihrer Implementierung eingeführt. Die Implementierung erfolgt in der Programmiersprache Python. Es folgt die Präsentation der Ergebnisse.

6.1. Strukturunabhängige Bildmerkmale

Methoden dieser Kategorie werden auf einzelnen Bildern angewendet. Daher werden diese Methoden auf allen Bildern ausgewertet und anschließend für die Differenzanalyse in Gruppen eingeteilt. Es werden ausschließlich die zugeschnittenen Varianten der Bilder verwendet, da die Methoden dieser Kategorie globale Werte liefern und der Einfluss vom Hintergrund zu komplex ist, um eine sinnvolle Auswertung zu ermöglichen. Folgende Diagramme werden für alle Methoden erstellt: Histogramme der Verteilungen realer CAVOK-Bilder, realer Regenbilder, simulierter CAVOK-Bilder und simulierter Regenbilder bezüglich der entsprechenden Metrik. Darüber hinaus werden Boxplots für den Verlauf der Daten in Abhängigkeit von der Tageszeit für sowohl die realen als auch simulierten Bilder erstellt. Zudem wird jeweils ein Histogramm für die Datensätze spezieller Wetterphänomene erstellt.

6.1.1. Helligkeit

Implementierung

Um die Helligkeit mithilfe des quadratischen Mittels der Pixelwerte zu berechnen, wird das `ImageStat`-Modul aus dem Paket `Pillow` verwendet [85]. Der Rückgabewert des Moduls sind globale Statistiken des Bildes, unter anderem auch das Ergebnis des quadratischen Mittels der Pixelwerte pro Kanal. Um nur einen Wert für die Helligkeit zu erhalten, werden die Bilder in Graustufenbilder umgewandelt und dann ausgewertet.




Abbildung 6.1.: Histogramme für die Helligkeit der Bilder der zugeschnittenen Varianten der Datensätze Real-CAVOK, Real-Regen, Sim-CAVOK und Sim-Regen-Datensatz 0.

Histogramme realer Bilder

Die Spanne der Bilder aus dem Real-CAVOK Datensatz erstreckt sich von 52,45 bis 208,25 (siehe Abbildung 6.1a). Der Durchschnitt aller Helligkeitswerte liegt bei 169,72 und der Median bei 178,21. Die Standardabweichung beträgt 28,63.


Der Minimalwert der Bilder aus dem Real-Regen Datensatz ist mit 107,01 deutlich höher als bei den realen CAVOK Bildern (siehe Abbildung 6.1b). Der Maximalwert beträgt 200,33. Der Durchschnitt liegt bei 178,41, der Median bei 180,60. Wie deutlich auf in dem Diagramm zu erkennen, sind die Helligkeitswerte bei realen Regen Bildern stark um diese Werte zentriert, was die Standardabweichung von 11,47 untermauert.

Histogramme simulierter Bilder

Das Diagramm für simulierte CAVOK-Bilder (Abbildung 6.1c) zeigt als einziges Diagramm deutliche Outlier. Diese Outlier entsprechen den in Kapitel 5.1.4 beschriebenen und in Abbildung A.5 dargestellten schwarzen Bildern, welche mit realen CAVOK-Bildern aus den frühen Morgenstunden korrespondieren. Der niedrigste Wert für diese Bilder beträgt 0,26, was darauf hindeutet, dass die Bilder trotz ihrer Erscheinung nicht vollständig schwarz sind. Der höchste gemessene Helligkeitswert für die simulierten CAVOK-Bilder beträgt 196,08. Der Durchschnittswert liegt bei 181,27 und der Median bei 187,46. Aufgrund der Outlier ist die Standardabweichung mit 32,85 sehr hoch. Aus dem Diagramm geht gleichzeitig hervor, dass die Helligkeit, mit Ausnahme der Outlier und einiger weniger anderer Ausnahmen, um den Median zentriert ist und die meisten gemessenen Helligkeiten zwischen 175 und 195 liegen.

Abbildung 6.1d zeigt die Ergebnisse für den Sim-Regen Datensatz 0. Die Standardabweichung von 2,11 zeigt, dass dieser Datensatz die geringste Variabilität in den Helligkeitsdaten hat. Alle Werte liegen zwischen 185,77 und 195,17. Auch der Durchschnittswert mit 191,73 liegt nahe beim Median mit 192,50.

Tageszeitabhängige Diagramme



(a) Helligkeit realer Bilder über den Tag in 3 Stunden Intervallen. (b) Helligkeit simulierter Bilder über den Tag in 3 Stunden Intervallen.

Abbildung 6.2.: Helligkeit der Bilder in Abhängigkeit von der Uhrzeit (blau: CAVOK Bilder; orange: Regen Bilder).

Die Korrelation zwischen Helligkeit und Tageszeit wird in Abbildung 6.2 dargestellt. Im linken Diagramm ist die Beziehung zwischen der Helligkeit realer Bilder und der Tageszeit abgebildet. Eine deutliche Abhängigkeit ist erkennbar. Insbesondere morgens (zwischen drei und fünf Uhr) und abends (zwischen 21 und 23 Uhr) nimmt die Helligkeit der Bilder ab. Zwischen null und zwei Uhr fehlen Einträge, was darauf hindeutet, dass Bilder aus dieser Zeit unterhalb der eingestellten Helligkeitsgrenze liegen. Darüber hinaus ist auffällig, dass Regenbilder (orange) tendenziell dunkler sind als CAVOK-Bilder (blau) zur gleichen Zeit.

Auch im Diagramm für die simulierten Bilder (Abbildung 6.2) ist eine Tageszeitabhängigkeit erkennbar. Im Gegensatz zu den realen Bildern ist diese jedoch schwach ausgeprägt. Im Unterschied zu den realen Daten zeigt dieses Diagramm, dass Regenbilder gleich hell oder sogar etwas heller sind als CAVOK-Bilder.

Insgesamt zeigen die beiden Diagramme, dass reale Bilder eine größere Variabilität in der Helligkeit aufweisen als die simulierten Bilder. Insbesondere die simulierten Regenbilder weisen in jedem Zeitintervall keine nennenswerte Variabilität auf.

Histogramme der Datensätze für spezielle Wetterbedingungen

In dem Histogramm für spezielle Wetterbedingungen (siehe Anhang Abbildung A.6), die durch Schattenwurf und Tropfen auf der Kamera-Linse ausgelöst werden, sind keine Tendenzen erkennbar. Die Helligkeiten der Beispielsbilder verteilen sich über die normalen Bereiche.

6.1.2. Kontrast

Implementierung

Die Berechnung des RMS-Kontrasts erfolgt, indem die Bilder zunächst in Graustufenbilder umgewandelt werden. Anschließend wird mithilfe der Funktion `std()` aus der NumPy-Bibliothek [86] der RMS-Kontrast berechnet. In der vorliegenden Untersuchung wird der Kontrast nicht normiert. Dementsprechend bewegen sich die Ergebnisse zwischen 0, was einem einfarbigen Bild entspricht, und 127,5, was einem Bild mit maximalem Kontrast entspricht, das zur Hälfte weiß und zur Hälfte schwarz ist.




Abbildung 6.3.: Histogramme für den Kontrast der Bilder der zugeschnittenen Varianten der Datensätze Real-CAVOK, Real-Regen, Sim-CAVOK und Sim-Regen-Datensatz 0.

Histogramme realer Bilder

Die durchschnittliche Kontrastwerte realer CAVOK-Bilder betragen 49,28, während der Median bei 51,22 liegt (siehe Abbildung 6.3a). Der niedrigste Kontrastwert liegt bei 21,81, der höchste bei 68,31, mit einer Standardabweichung von 7,48.

Abbildung 6.3b zeigt, dass reale Regenbilder, ähnlich wie bei den Helligkeitswerten, eine geringere Standardabweichung aufweisen als reale CAVOK-Bilder, nämlich 4,16. Zudem liegen der Durchschnitt bei 53,64 und der Median bei 54,68 etwas höher als bei realen CAVOK-Bildern. Dies ist vor allem darauf zurückzuführen, dass auch der kleinste gemessene Kontrastwert bei 37,10 deutlich höher liegt als bei realen CAVOK-Bildern. Gleichzeitig ist der höchste gemessene Wert bei 59,62 niedriger als bei realen CAVOK-Bildern.


Histogramme simulierter Bilder

Die simulierten CAVOK-Bilder weisen erneut Outlier mit sehr niedrigem Kontrast auf (siehe Abbildung 6.3c). Der niedrigste Kontrast von 0,25 entspricht einem der zuvor beschriebenen nahezu schwarzen Bilder. Der höchste Kontrast liegt bei 76,93. Der Durchschnittswert beträgt 62,12, während der Median bei 60,12 liegt. Die hohe Standardabweichung von 12,61 resultiert aus den zuvor erwähnten Outlier. Im Gegensatz zu den realen Bildern zeigt das Histogramm eine bimodale Verteilung mit dem größeren Maximum nahe dem Median. Ein zweites, kleineres Maximum tritt bei einem Kontrast von etwa 75 auf.

Das Histogramm für simulierte Regenbilder (Abbildung 6.3d) zeigt ebenfalls eine bimodale Verteilung. Das erste, kleinere Maximum liegt bei einem Kontrast von 60 und damit nur knapp über dem kleinsten gemessenen Kontrast von 58,15. Das zweite, deutlich ausgeprägtere Maximum korrespondiert mit dem Median bei 74,89. Der höchste Kontrast beträgt 76,60. Der Durchschnittswert liegt bei 71,57 mit einer Standardabweichung von 6,28.

Es ist festzustellen, dass der Kontrast für die simulierten Bilder im Allgemeinen höher ist als für die realen Bilder.

Tageszeitabhängige Diagramme



(a) Kontrast realer Bilder über den Tag in 3 Stunden Intervallen. (b) Kontrast simulierter Bilder über den Tag in 3 Stunden Intervallen.

Abbildung 6.4.: Kontrast der Bilder in Abhängigkeit von der Uhrzeit (blau: CAVOK Bilder; orange: Regen Bilder).

Abbildung 6.4 zeigt die Abhängigkeit des Kontrasts von der Tageszeit. Bei realen CAVOK-Bildern ist, mit Ausnahme des Zeitraums von 12 bis 14 Uhr, keine signifikante Änderung des Kontrastes nachweisbar. Für reale Regenbilder ist eine Tendenz erkennbar, dass der Kontrast zum Abend hin leicht abnimmt. Während des Tages, mit Ausnahme des Zeitraums von 12-14 Uhr, liegt der Kontrast für Regenbilder leicht über dem Kontrast der CAVOK-Bilder.

Der Kontrast für simulierte Bilder zeigt eine deutliche Abhängigkeit von der Tageszeit. Vor 8 Uhr und nach 21 Uhr ist der Kontrast tendenziell geringer. Zwischen 12 und 17 Uhr ist der Kontrast

konstant hoch. Zwischen 9 und 11 Uhr sowie 18 und 20 Uhr gibt es Bilder mit Kontrasten, die sich zwischen dem niedrigen und dem hohen gemessenen Kontrast der anderen Uhrzeiten bewegen. Zwischen Regen- und CAVOK-Bildern gibt es keinen signifikanten Unterschied im Kontrast über die Tageszeit.

Histogramme der Datensätze für spezielle Wetterbedingungen

Die Verteilung für spezielle Wetterbedingungen zeigt keine erkennbaren Tendenzen (siehe Anhang Abbildung A.7).

6.1.3. Bildschärfe

Implementierung

Für die Differenzanalyse in dieser Untersuchung werden die MLV Bildschärfe und die Laplace Bildschärfe verwendet. Zuerst werden die Bilder in Graustufenbilder umgewandelt. Die Implementierung der MLV Bildschärfe erfolgt nach der Methode, die im Originalpaper [13] beschrieben wurde, und ist als Anhang dieser Arbeit beigefügt (siehe Quellcodeausschnitt A.1). Die Laplace Bildschärfe wird mithilfe der OpenCV Funktion `cv2.Laplacian` berechnet und anschließend die Standardabweichung ermittelt.




Abbildung 6.5.: Histogramme für die MLV Bildschärfe der Bilder der zugeschnittenen Varianten der Datensätze Real-CAVOK, Real-Regen, Sim-CAVOK und Sim-Regen-Datensatz 0.

MLV Bildschärfe Histogramme realer Bilder

Die MLV-Bildschärfe realer CAVOK-Bilder variiert zwischen 6,42 und 16,89, wobei der Durchschnitt bei 14,48 und der Median bei 14,73 liegt. Die Standardabweichung beträgt 1,76. In Abbildung 6.5a zeigt sich, dass die meisten Bilder eine MLV-Bildschärfe zwischen 13 und 16,5 aufweisen, während es von den weniger scharfen Bildern jeweils nur wenige gibt.

Die realen Regenbilder weisen eine durchschnittliche Bildschärfe von 15,57 und einen Median von 29,31 auf, was darauf hindeutet, dass sie im Durchschnitt schärfer sind als reale CAVOK-Bilder. Das unschärfste Bild hat eine MLV-Bildschärfe von 11,14, während das schärfste eine MLV-Bildschärfe von 17,08 aufweist. Die Standardabweichung beträgt 1,32. Obwohl die geringste MLV-Bildschärfe bei 11,14 liegt, zeigt das Diagramm in Abbildung 6.5b, dass die meisten realen Regenbilder eine MLV-Bildschärfe über 15 haben und somit über dem Durchschnitt der realen CAVOK-Bilder liegen.

MLV Bildschärfe Histogramme simulierter Bilder


Die simulierten Bilder weisen eine durchschnittlich höhere MLV Bildschärfe auf als die realen Bilder. Die einzige Ausnahme bilden die wenigen Bilder des Sim-CAVOK Datensatzes, die als Outlier gelten, da sie nahezu vollständig schwarz sind. Diese Bilder haben eine MLV Bildschärfe von 0,45. Im Vergleich dazu liegt der Durchschnitt der simulierten CAVOK Bilder bei 19,86, und der Median liegt bei 20,00. Die maximale MLV Bildschärfe, die im Sim-CAVOK Datensatz gemessen wird, beträgt 24,29. Aufgrund der Outlier ist die Standardabweichung mit 3,95 entsprechend hoch. Im Gegensatz zu den realen CAVOK Bildern zeigt das Diagramm der simulierten CAVOK Bilder in Abbildung 6.5c eine deutlich bimodale Verteilung, wobei das erste Maximum direkt beim Durchschnitt liegt und das zweite Maximum bei den höchsten gemessenen MLV Bildschärfe-Werten auftritt.

Ähnlich verhält es sich bei den simulierten Regenbildern, bei denen das Maximum ebenfalls bei den höchsten MLV Bildschärfe-Werten auftritt (siehe Abbildung 6.5d). Der höchste gemessene Wert beträgt dabei 24,34. Der niedrigste Wert beträgt 17,00 und ist damit fast so hoch wie der höchste gemessene MLV Bildschärfe-Wert der realen Regenbilder. Der Durchschnitt für simulierte Regenbilder liegt bei 22,67. Der Median ist 23,64, und die Standardabweichung beträgt 1,90.

Tageszeitabhängige Diagramme der MLV Bildschärfe

Die Tageszeitabhängigkeit der MLV Bildschärfe für die Bilder ist in Abbildung 6.6 dargestellt. Bei den realen Bildern zeigt sich eine Tageszeitabhängigkeit, die dem Verlauf der Helligkeit ähnelt. Die Bilder, die während der frühen Morgenstunden und am Abend aufgenommen wurden, weisen eine geringere Bildschärfe auf. Im Gegensatz dazu sind die Bilder, die tagsüber aufgenommen wurden, schärfer. Darüber hinaus liegen die Daten der Regenbilder, mit Ausnahme des Zeitraums zwischen 21 und 23 Uhr, oberhalb der Daten für CAVOK Bilder. Dies deutet darauf hin, dass Regenbilder nach der MLV Bildschärfe schärfer erscheinen als CAVOK Bilder.

Bei simulierten Bildern ist die Tageszeitabhängigkeit stärker ausgeprägt als bei realen Bildern und ähnelt dem Verlauf des Kontrasts bei simulierten Bildern. Bilder, die für Zeiten vor 8 Uhr und nach 21 Uhr erzeugt wurden, weisen die geringste MLV Bildschärfe auf. Bilder, die für Zeiten zwischen 12 und 17 Uhr aufgenommen wurden, haben die höchste Bildschärfe. Auffällig ist, dass es für diesen Zeitraum nahezu keine Variabilität in der Bildschärfe gibt. Bilder, die für



(a) MLV Bildschärfe realer Bilder über den Tag in 3 Stunden Intervallen. (b) MLV Bildschärfe simulierter Bilder über den Tag in 3 Stunden Intervallen.

Abbildung 6.6.: MLV Bildschärfe der Bilder in Abhängigkeit von der Uhrzeit (blau: CAVOK Bilder; orange: Regen Bilder).

Zeiten zwischen den genannten Zeiträumen erzeugt wurden, variieren stark in der Bildschärfe. Mit Ausnahme des Zeitraums zwischen 12 und 17 Uhr weisen auch hier die Regenbilder höhere Bildschärfen auf als die CAVOK Bilder.

MLV Bildschärfe Histogramme der Datensätze für spezielle Wetterbedingungen





Abbildung 6.7.: Gestapeltes Histogramm für die MLV Bildschärfe von Bildern unter den speziellen Wetterbedingungen: Schatten auf dem Kalibriermuster bei CAVOK, Schatten auf dem Kalibriermuster bei Regen und Regentropfen auf der Linse

Die Ergebnisse für spezielle Wetterbedingungen werden in Abbildung 6.7 dargestellt. Bilder mit der Wetterbedingung CAVOK und Schatten weisen eine MLV Bildschärfe zwischen 10,88 und 16,61 auf. Eine Auswertung dieser Ergebnisse lässt keinen Einfluss von Schatten auf die MLV Bildschärfe erkennen. Ebenso ist bei Regenbildern mit Schatten kein Trend erkennbar. Diese Bilder bewegen sich in einem Bereich von 14,93 bis 16,55, was innerhalb des Hauptbereichs aller Regenbilder liegt. Bei Regenbildern mit Tropfen auf der Linse ist eine leichte Tendenz erkennbar. Diese Bilder fallen in einen Bereich von 11,48 bis 15,07 und liegen somit alle unterhalb des Durchschnittswerts für reale Regenbilder.

Vergleich Laplace Bildschärfe und MLV Bildschärfe




(a) Laplace Bildschärfe realer Bilder über den Tag in 3 Stunden Intervallen. (b) Laplace Bildschärfe bei den speziellen Wetterbedingungen.

Abbildung 6.8.: Laplace Bildschärfe Diagramme mit abweichenden Ergebnissen zu denen der MLV Bildschärfe. Linkes Diagramm: Bildschärfe in Abhängigkeit von der Uhrzeit (blau: CAVOK Bilder; orange: Regen Bilder); Rechtes Diagramm: Gestapeltes Histogramm von Bildern unter den speziellen Wetterbedingungen: Schatten auf dem Kalibriermuster bei CAVOK, Schatten auf dem Kalibriermuster bei Regen und Regentropfen auf der Linse.


Die Histogramme für die Laplace Bildschärfe weisen Ähnlichkeiten mit denen der MLV Bildschärfe auf (siehe Anhang Abbildung A.8 und Abbildung A.9). Daher wird hier auf eine detaillierte Beschreibung verzichtet. Stattdessen werden die Unterschiede zu den Ergebnissen der MLV Bildschärfe erläutert (siehe Abbildung 6.8). Auffällige Unterschiede sind im Diagramm für die Tageszeitabhängigkeit der Laplace Bildschärfe realer Bilder erkennbar (Abbildung 6.8a). Im Gegensatz zur MLV Bildschärfe, bei der eine Tageszeitabhängigkeit zu beobachten ist, zeigt sich bei der Laplace Bildschärfe keine solche Abhängigkeit. Allerdings ergibt sich aus diesem Diagramm, dass Regenbilder etwas schärfer als CAVOK Bilder sind. Ein weiterer Unterschied wird bei den speziellen Wetterbedingungen deutlich. Im Rahmen der Auswertung mit der Laplace Bildschärfe kann für keine der drei Kategorien eine Tendenz identifiziert werden.

6.2. Low-Level Feature Analyse


Methoden dieser Kategorie werden auf einzelnen Bildern angewendet. Das Vorgehen entspricht dem der Methoden strukturunabhängiger Bildmerkmale. Die Methoden werden auf jedem Bild der vorgestellten Datensätze mit zugeschnittenen Bildern angewendet und anschließend in die jeweiligen Gruppen eingeteilt. Folgende Diagramme werden für jede Methode erstellt: Histogramme der Verteilungen für die Bilder der Datensätze Real-CAVOK, Real-Regen, Sim-CAVOK und Sim-Regen-Datensatz 0, bezogen auf die entsprechende Metrik. Weiterhin werden Boxplots für den Verlauf der Daten realer und simulierter Bilder in Abhängigkeit von der Tageszeit erstellt, sowie ein Histogramm für reale Bilder unter speziellen Wetterbedingungen. Wie zuvor werden die zugeschnittenen Bilder genutzt, da die Einflüsse der Hintergründe zu komplex sind für eine sinnvolle Auswertung.



(a) Reales Regenbild mit Tropfen auf dem Muster und auf der Linse bei Sonnenschein.



(b) Erkannte Kanten für das Regenbild mit den meisten Kantenpixeln.



(c) Erkannte Ecken für das Regenbild mit den meisten Kantenpixeln.

Abbildung 6.9.: Reales Regenbild mit den meisten Kanten(pixel) von allen Bildern aus den gegebenen Datensätzen und die dazugehörige Darstellung der erkannten Kanten und Ecken.

6.2.1. Kantendetektion

Für die Kantendetektion wird der Canny-Algorithmus angewendet. Da dieser ausschließlich die Pixel eines Bildes identifiziert, die zu einer Kante gehören und im Folgenden als Kantenpixel bezeichnet werden, jedoch keine Auskunft darüber gibt, wie viele Kanten insgesamt vorhanden sind, wird ergänzend die Hough-Transformation herangezogen, um die Anzahl der Kanten zu bestimmen. Im weiteren Verlauf werden zwei Metriken im Zusammenhang mit den Kanten ausgewertet: Die erste Metrik ist die Anzahl der ermittelten Kantenpixel, die zweite Metrik ist die Anzahl der erkannten Kanten nach Anwendung der Hough-Transformation.

Implementierung

Für die Implementierung beider Metriken kommen OpenCV und NumPy zum Einsatz. Zunächst werden die Bilder in Graustufenbilder umgewandelt. Anschließend wird mithilfe der Funktion `cv2.Canny` eine Binärmatrix der Kantenpixel erzeugt, wobei neben dem zu untersuchenden Bild zwei weitere Parameter für die Schwellwerte des Canny-Algorithmus erforderlich sind. Bei der Differenzanalyse werden die Schwellwerte 100 und 200 verwendet. Die Anzahl der Kantenpixel kann durch die Funktion `np.sum(canny > 0)` berechnet werden, wenn der Parameter `canny` der erzeugten Binärmatrix entspricht.


Die Kantenberechnung erfolgt mithilfe der Funktion `cv2.HoughLinesP`, die mehrere Parameter erwartet. Dazu gehört die Genauigkeit für die Bestimmung der Kanten. In dieser Arbeit werden die Kanten mit einer Winkelgenauigkeit von 1° und einer Genauigkeit des Versatzes von 1 Pixel ermittelt. Darüber hinaus ist die minimale Länge einer Kante anzugeben, damit diese als Kante gezählt wird. Die Mindestlänge wird auf 50 Pixel eingestellt. Zudem können Schwellwerte für Kantensegmente angegeben werden. In dieser Arbeit muss ein Kantensegment mindestens 30 Pixel lang sein, um als solches gewertet zu werden, und zwei Kantensegmente dürfen nur maximal 10 Pixel auseinander liegen, um als eine Kante gezählt zu werden. Um nach der Berechnung der Kanten die Anzahl dieser zu ermitteln, wird die Länge der resultierenden Liste berechnet.

Outlierhandling für die Kantenpixelanzahl


Bei der Berechnung der Kantenpixelanzahl gibt es für reale Regenbilder einen Outlier mit 313332 Kantenpixeln. Dieser Outlier gehört zu dem in Abbildung 6.9a dargestellten Bild. Die Analyse des Bildes zeigt, dass auf dem Kalibriermuster zahlreiche Regentropfen zu sehen sind, die durch das Sonnenlicht sehr hell erscheinen. Abbildung 6.9b zeigt die erkannten Kanten. Aus den Bildern kann abgeleitet werden, dass die Regentropfen auf dem Kalibriermuster besonders auf hellen Bereichen zuverlässig erkannt werden. Auf dunklen Bereichen, wie z.B. den schwarzen Flächen des Schachbrettmusters, werden jedoch kaum Regentropfen erkannt. Darüber hinaus ist zu beobachten, dass der Tropfen auf der Linse die Kantenerkennung lokal negativ beeinflusst.

Neben diesem Outlier nach oben gibt es bei den simulierten CAVOK-Bildern Outlier nach unten. Diese Outlier sind auf die nahezu komplett schwarzen Bilder zurückzuführen, die durch einen fehlerhaften Sonnenstand in der Unreal Engine entstehen. Bei diesen Bildern kann mit dem Canny-Algorithmus keine Kante erkannt werden.


Da es abgesehen von diesem Regenbild keine weiteren Bilder mit einer so hohen Anzahl an Kantenpixel gibt und es auch die nahezu schwarzen simulierten CAVOK-Bilder mit weniger als 45000 Kanten gibt, werden die Diagramme zur Kantenpixelanzahl auf 45000 bis 75000 Kantenpixel beschränkt.




(a) Kantenpixelanzahl Histogramm für reale CAVOK Bilder.



(b) Kantenpixelanzahl Histogramm für reale Regenbilder.



(c) Kantenpixelanzahl Histogramm für simulierte CAVOK Bilder.



(d) Kantenpixelanzahl Histogramm für simulierte Regenbilder.

Abbildung 6.10.: Histogramme für die Kantenpixelanzahl der Bilder der zugeschnittenen Varianten der Datensätze Real-CAVOK, Real-Regen, Sim-CAVOK und Sim-Regen-Datensatz 0.

Kantenpixelanzahl Histogramme realer Bilder

Wenn die oben beschriebenen Outlier ignoriert werden, zeigt sich die höchste Streuung an Werten bei realen CAVOK-Bildern in Abbildung 6.10a. Für diese Bilder werden zwischen 48942 und 70076 Kantenpixel gemessen. Der Mittelwert beträgt 66650,33 und der Median 66758. Die Standardabweichung liegt bei 2107,26.


Wenn der Outlier des realen Regenbilds ignoriert wird, sinkt die Standardabweichung von 19111,73 auf 1470,22 (siehe Abbildung 6.10b). Der Mittelwert liegt dann bei 67076,91 und der Median bei 67053. Dies weist darauf hin, dass Bilder des Datensatzes Real-Regen durchschnittlich eine höhere Anzahl an Kantenpixel aufweisen als die des Real-CAVOK-Datensatzes.

Kantenpixelanzahl Histogramme realer Bilder

Die simulierten Bilder zeigen geringere Standardabweichungen, wenn die Outlier-Bilder ignoriert werden (siehe Abbildungen 6.10c und 6.10d). Bei simulierten CAVOK-Bildern liegt die Standardabweichung bei 672,14. Der Mittelwert beträgt 66591,65 und der Median liegt bei 66546,50. Die Verteilung liegt im gleichen Bereich wie bei den tatsächlichen CAVOK-Bildern. Jedoch beträgt die maximale Anzahl an Kantenpixeln 67961, was unterhalb der Werte für reale CAVOK-Bilder liegt.

Bei den synthetischen Regenbildern werden Kantenpixelwerte zwischen 66357 und 70272 erkannt. Der Mittelwert beträgt 67180,55, was über dem Mittelwert für reale Regenbilder liegt. Der Median liegt jedoch bei 66937, was etwas unterhalb des Medians für reale Regenbilder liegt. Die Standardabweichung von 792,74 ist vergleichsweise gering.

Tageszeitabhängige Diagramme der Kantenpixelanzahl



(a) Kantenpixelanzahl realer Bilder über den Tag in 3 Stunden Intervallen. (b) Kantenpixelanzahl simulierter Bilder über den Tag in 3 Stunden Intervallen.

Abbildung 6.11.: Kantenpixelanzahl der Bilder in Abhängigkeit von der Uhrzeit (blau: CAVOK Bilder; orange: Regen Bilder).

Eine Analyse der Diagramme, die den Einfluss der Tageszeit auf die detektierten Kantenpixel darstellen (siehe Abbildung 6.11), zeigt, dass keine signifikante Tageszeitabhängigkeit erkennbar ist. Eine Beobachtung ist jedoch, dass sowohl reale als auch simulierte Regenbilder ab dem Mittag tendenziell eine höhere Anzahl an Kantenpixeln aufweisen als CAVOK-Bilder.




Abbildung 6.12.: Gestapeltes Histogramm für die Kantenpixelanzahl von Bildern unter den speziellen Wetterbedingungen: Schatten auf dem Kalibriermuster bei CAVOK, Schatten auf dem Kalibriermuster bei Regen und Regentropfen auf der Linse

Kantenpixelanzahl Histogramme der Datensätze für spezielle Wetterbedingungen

Abbildung 6.12 zeigt, dass die Bilder mit Schatten in eine Kantenpixelanzahl den Bereichen der Hauptverteilung aller Daten aufweisen und daher keine Besonderheit aufweisen. Im Gegensatz dazu liegen die Bilder mit Tropfen auf der Linse unterhalb des Durchschnitts für Regenbilder und zeigen somit eine Tendenz, dass Tropfen auf der Linse die Anzahl der erkannten Kantenpixel verringern. Eine Ausnahme für diese Tendenz bildet das in Abbildung 6.9a dargestellte Bild, das ebenfalls Tropfen auf dem Kalibriermuster aufweist und einen einzelnen Tropfen auf der Linse, der nur einen kleinen Teil des Kalibrierusters bedeckt.


Kantenanzahl Histogramme realer Bilder

Die Anwendung der Hough-Transformation mit den zuvor spezifizierten Parametern resultiert in der Entstehung von Outliern, die denen in den vorherigen Ergebnissen entsprechen. Nach dem erneuten Ausschluss dieser Outlier können die Diagramme auf einen Bereich zwischen 350 und 650 Kanten eingeschränkt werden. Die entsprechenden Diagramme sind in Abbildung 6.13 dargestellt. Die Verteilung der Kantenanzahl in den realen CAVOK-Bildern nähert sich einer Normalverteilung mit einem Mittelwert von 543,52 und einem Median von 546. Die Standardabweichung beträgt 39,64.


Die Verteilung der Kantenanzahl in den realen Regenbildern zeigt kein ausgeprägtes Maximum, sondern eine Konzentration zwischen 530 und 610 Kanten. Einige Bilder weisen weniger Kanten auf, wobei das Bild mit der geringsten Kantenanzahl 466 Kanten enthält. Andere Bilder weisen etwas mehr Kanten auf. Der Mittelwert beträgt 563,99 Kanten, der Median liegt bei 562 und die Standardabweichung beträgt 35,87. Im Vergleich zu den realen CAVOK-Bildern ist die Standardabweichung minimal kleiner. Gleichzeitig zeigt die Analyse der Kantenpixel, dass Regenbilder tendenziell etwas mehr Kanten aufweisen als CAVOK-Bilder.

Kantenanzahl Histogramme simulierter Bilder


Im Gegensatz zur Verteilung der Kantenpixelanzahl, die für reale und synthetische Bilder in ähnlichen Bereichen liegt, zeigt sich bei der Anzahl der Kanten ein deutlicher Unterschied.




(a) Kantenanzahl Histogramm für reale CAVOK Bilder.



(b) Kantenanzahl Histogramm für reale Regenbilder.



(c) Kantenanzahl Histogramm für simulierte CAVOK Bilder.



(d) Kantenanzahl Histogramm für simulierte Regenbilder.


Abbildung 6.13.: Histogramme für die Kantenanzahl der Bilder der zugeschnittenen Varianten der Datensätze Real-CAVOK, Real-Regen, Sim-CAVOK und Sim-Regen-Datensatz 0.

Synthetische Bilder weisen deutlich weniger Kanten auf als reale Bilder. Für synthetische CAVOK-Bilder liegt der Mittelwert bei 413,99 und der Median bei 415, was rund 130 Kanten unterhalb der Werte für reale CAVOK-Bilder liegt. Die Standardabweichung von 29,28 ist deutlich geringer als die der realen Bilder. Das Bild mit den meisten Kanten hat 537 Kanten, was noch immer unterhalb des Mittelwertes für reale CAVOK-Bilder liegt.


Synthetische Regenbilder weisen ebenfalls weniger Kanten auf als reale Regenbilder. Der Mittelwert liegt bei 458,35 und der Median bei 451, was bedeutet, dass synthetische Regenbilder im Durchschnitt über 100 Kanten weniger als reale Regenbilder haben. Die Standardabweichung von 35,04 entspricht der Standardabweichung der realen Bilder. Wie bei den realen Bildern zeigt sich auch, dass synthetische Regenbilder im Schnitt mehr Kanten haben als synthetische CAVOK-Bilder, wobei der Unterschied größer ist als bei den realen Bildern.

Tageszeitabhängige Diagramme der Kantenanzahl

Ein weiterer Unterschied zur Messung der Kantenpixelanzahl ist, dass die Anzahl der Kanten eine deutliche Tageszeitabhängigkeit zeigt (siehe Abbildung 6.14). Bei realen Bildern wird deutlich, dass Bilder, die am Morgen aufgenommen werden, weniger Kanten aufweisen als Bilder, die tagsüber aufgenommen werden. Abends sinkt die Anzahl der erkannten Kanten wieder. Dies gilt sowohl für CAVOK- als auch für Regenbilder. Eine Ausnahme bilden Regenbilder zwischen 6 und 8 Uhr, die deutlich mehr Kanten aufweisen als Bilder, die zu einer späteren



(a) Kantenzahl realer Bilder über den Tag in 3 Stunden Intervallen.



(b) Kantenzahl simulierter Bilder über den Tag in 3 Stunden Intervallen.

Abbildung 6.14.: Kantenzahl der Bilder in Abhängigkeit von der Uhrzeit (blau: CAVOK Bilder; orange: Regen Bilder).

Tageszeit aufgenommen wurden. Es ist keine Tendenz erkennbar, ob Regen- oder CAVOK-Bilder durchschnittlich mehr Kanten haben.

Bei simulierten Bildern ist für CAVOK-Bilder ebenfalls eine Tageszeitabhängigkeit erkennbar. Allerdings steigt hier die Anzahl der erkannten Kanten über den gesamten Tag an und nimmt auch abends nicht ab. Bei simulierten Regenbildern ist keine deutliche Tageszeitabhängigkeit erkennbar. Abgesehen von den Bildern, die für die Tageszeit zwischen 21 und 23 Uhr erzeugt wurden, haben synthetische Regenbilder immer mehr Kanten als synthetische CAVOK-Bilder.


Kantenzahl Histogramme der Datensätze für spezielle Wetterbedingungen

Es ist keine Tendenz für die Anzahl der Kanten pro Bild unter den speziellen Wetterbedingungen erkennbar (siehe Anhang Abbildung A.10).


6.2.2. Eckendetektion

Implementierung


In der Shi-Tomasi-Eckendetektion wird eine Implementierung in OpenCV verwendet. Zunächst wird jedes Bild in ein Graustufenbild umgewandelt. Anschließend wird die OpenCV-Funktion `cv2.goodFeaturesToTrack` angewendet, die drei Parameter erwartet: `maxCorners` zur Begrenzung der Anzahl der zurückgegebenen Ecken, `qualityLevel` zur Angabe des mindesten Qualitätslevels für akzeptierte Ecken und `minDistance` zur Spezifikation des Mindestabstands zwischen zwei Ecken. Für die ersten Experimente wird `maxCorners` auf einen hohen Wert gesetzt, um viele Ecken zu detektieren. Später wird dieser Wert auf 15.000 reduziert, um Outlier auszuschließen. `qualityLevel` wird in dieser Arbeit auf 0,01 eingestellt. `minDistance` wird auf 5 gesetzt. Nach der Auswertung der Bilder mithilfe dieser Funktion wird die Länge der erzeugten Liste mit allen Ecken gezählt und als Metrik genutzt. Zudem werden Bilder mit den detektierten Ecken erzeugt.



(a) Synthetisches CAVOK Bild mit den meisten erkannten Ecken.



(b) Erkannte Ecken für das simulierte CAVOK Bild mit den meisten Ecken.



(c) Korrespondierendes reales CAVOK Bild um 5:16 Uhr aufgenommen.

Abbildung 6.15.: Synthetisches CAVOK Bild mit auffällig vielen Ecken und die dazugehörige Darstellung der erkannten Ecken, sowie das korrespondierende reale CAVOK Bild.

Outlierhandling für die Kantenpixelanzahl

Eine hohe Erlaubte maximale Anzahl von Ecken zeigt Outlier mit über über 45.000 erkannten Ecken für simulierten CAVOK-Bildern. Diese Ausreißer sind durch nahezu schwarze Bilder gekennzeichnet, wie in Abbildung 6.15 dargestellt. Ein weiterer Outlier tritt bei einem realen Regenbild mit 33.421 erkannten Ecken auf. Dieses Regenbild, das in Abbildung 6.9b gezeigt wird, sind die erkannten Ecken in Abbildung 6.9c dargestellt. Die Kantendetektion zeigt den Einfluss von Tropfen auf der Linse sowie dunkler Hintergründe.


Um den Einfluss dieser Outlier zu minimieren, wird die Shi-Tomasi-Eckendetektion erneut mit einer Begrenzung auf 15.000 Ecken angewendet. Dies führt zu übersichtlicheren Verteilungen, bei denen die meisten Bilder weniger als 5.000 Ecken aufweisen. Lediglich einige Bilder in den realen Datensätzen haben bis zu 13.000 Ecken. Bei Betrachtung der Hauptverteilungen können die Diagramme auf einen Bereich bis 5.000 Ecken beschränkt werden, um diese Hauptverteilung besser zu analysieren.

In Abbildung 6.16 sind die resultierenden Diagramme dargestellt. Für die Berechnung von Mittelwert, Median und Standardabweichung werden bei diesen Diagrammen nur die dargestellten Daten verwendet.


Histogramme realer Bilder

Das Diagramm für den Real-CAVOK Datensatz (Abbildung 6.16a) zeigt, dass die meisten Bilder weniger als 2000 Ecken aufweisen. Es gibt jedoch einige Bilder mit einer deutlich höheren Anzahl von Ecken, was zu einem Mittelwert von 1775,24 und einer Standardabweichung von 742,60 führt. Der Median liegt bei 1491 Ecken.


Die Verteilung der Ecken in realen Regenbildern (Abbildung 6.16b) ist ebenfalls weit gestreut. Die meisten Regenbilder weisen weniger als 1800 Ecken auf. Der Mittelwert beträgt 2161,89, der Median 1663,5. Die Standardabweichung ist mit 1141,19 höher als bei den realen CAVOK Bildern.




(a) Eckenanzahl Histogramm für reale CAVOK Bilder.



(b) Eckenanzahl Histogramm für reale Regenbilder.



(c) Eckenanzahl Histogramm für simulierte CAVOK Bilder.



(d) Eckenanzahl Histogramm für simulierte Regenbilder.

Abbildung 6.16.: Histogramme für die Eckenanzahl der Bilder der zugeschnittenen Varianten der Datensätze Real-CAVOK, Real-Regen, Sim-CAVOK und Sim-Regen-Datensatz 0.


Histogramme simulierter Bilder

Die Standardabweichung der simulierten Bilder ist deutlich geringer als bei den realen Bildern. Die Verteilung bei den simulierten CAVOK Bildern ist bimodal, mit dem größeren Maximum bei dem Median von 1734 Ecken und einem zweiten Maximum bei etwa 2250 Ecken. Der Mittelwert beträgt 1807 Ecken und die Standardabweichung 254,19.


Die Standardabweichung der synthetischen Regenbilder ist mit 333,15 ebenfalls klein. Der Mittelwert beträgt 2308,46, was fast mit dem Median von 2322,50 übereinstimmt. Die Verteilung zeigt ein deutliches Maximum bei dem Median und einige Bilder mit weniger als 2000 Ecken sowie einige mit etwa 3000 Ecken, ohne dass diese jedoch zusätzliche klare Maximas der Verteilung zu bilden.

Tageszeitabhängige Diagramme

Sowohl reale als auch synthetische Daten zeigen eine Tageszeitabhängigkeit (siehe Abbildung 6.17). Bei realen Bildern werden morgens und abends mehr Ecken erkannt als tagsüber. Dies trifft sowohl auf Bilder des Real-Regen Datensatzes als auch auf Bilder des Real-CAVOK Datensatzes zu. Gleichzeitig zeigen Regenbilder über den gesamten Tag starke Abweichungen in der Anzahl der Ecken pro Bild. Darüber hinaus werden tendenziell mehr Ecken in Regenbildern als in CAVOK Bildern erkannt.



(a) Eckenanzahl realer Bilder über den Tag in 3 Stunden Intervallen.



(b) Eckenanzahl simulierter Bilder über den Tag in 3 Stunden Intervallen.

Abbildung 6.17.: Eckenanzahl der Bilder in Abhängigkeit von der Uhrzeit (blau: CAVOK Bilder; orange: Regen Bilder).

Bei simulierten Bildern zeigt sich die umgekehrte Abhängigkeit von der Tageszeit. In den frühen Morgenstunden und den Abendstunden werden - mit Ausnahme der nahezu schwarzen Bilder - weniger Ecken erkannt. Die geringe Standardabweichung der Verteilungen zeigt sich auch in diesem Diagramm, da innerhalb der drei Stunden Intervalle keine signifikanten Schwankungen in den Eckenanzahlen auftreten. Auch bei den simulierten Bildern haben die Regenbilder tendenziell mehr Ecken als die CAVOK Bilder.

Histogramme der Datensätze für spezielle Wetterbedingungen




Abbildung 6.18.: Gestapeltes Histogramm für die Eckenanzahl von Bildern unter den speziellen Wetterbedingungen: Schatten auf dem Kalibriermuster bei CAVOK, Schatten auf dem Kalibriermuster bei Regen und Regentropfen auf der Linse

Gegenüber der Beobachtung in Abbildung 6.9c, dass in dem Bereich, in dem Regentropfen auf der Linse zu sehen sind, weniger Ecken erkannt werden, zeigt das Histogramm für die Eckenanzahl von Bildern unter speziellen Wetterbedingungen (siehe Abbildung 6.18) eine höhere Anzahl an Ecken bei Bildern mit Regentropfen auf der Linse. Bei Schattenbildern wurden keine signifikanten Tendenzen festgestellt.

6.3. Pixel- und Wahrnehmungsähnlichkeit

Methoden dieser Kategorie werden auf Bildpaaren angewendet. Zunächst müssen entsprechende Bildpaare bestimmt werden. Da die meisten Methoden dieser Kategorie entwickelt wurden, um Verluste bei der Bildkompression oder -übermittlung zu messen, sollten die Bildpaare aus Bildern bestehen, die sich grundsätzlich sehr ähnlich sind. Bei Methoden wie RMSE und PSNR, die Pixel für Pixel vergleichen, kann bereits eine leichte Farbverschiebung die Ergebnisse beeinflussen. Daher werden für die Auswertung mit den Methoden in dieser Kategorie nur Bildpaare aus der gleichen Generierungskategorie gebildet, also real-real und sim-sim. Der zu ermittelnde Unterschied ist der Einfluss von Regen. Dafür werden für alle Regenbilder passende CAVOK-Bilder gesucht, die zu einer ähnlichen Tageszeit (maximal 10 Minuten Unterschied) aufgenommen wurden. Wenn mehrere CAVOK-Bilder diese Bedingung erfüllen, wird das Bild ausgewählt, das vom Datum am nächsten an dem Aufnahmetag des Regenbildes liegt. Diese Bildpaarbildung wird mit einem Python-Skript automatisiert und nicht manuell überprüft. Mit diesen Kriterien werden 124 reale Bildpaare ermittelt. Die gleichen Bildpaare werden auch mit den simulierten Bildern gebildet. Anschließend findet die Auswertung auf den Bildpaaren statt. Es werden Histogramme für die Ergebnisse erzeugt und Diagramme für den Einfluss der Tageszeit erstellt. Durch die Bildpaarbildung wird die Auswahl der Bilder mit speziellen Wetterbedingungen weiter eingeschränkt, weswegen es für die folgenden Methoden keine Auswertung zum Einfluss dieser Wetterbedingungen gibt.

Alle Bildpaare werden aus Bildern der Datensatzvarianten mit zugeschnittenen Bildern gebildet. Grund hierfür ist, dass die Hintergründe in der Simulation nicht den Hintergründen auf den realen Bildern entsprechen, da die Fenster nicht nachgebildet werden. Deshalb würden die Hintergründe die Ergebnisse beeinflussen. Für alle in dieser Arbeit verwendeten Methoden dieser Kategorie wird das scikit-image-Paket für Python verwendet (van der Walt et al., 2014).

6.3.1. NRMSE

Implementierung

Die Berechnung von NRMSE erfolgt mithilfe der scikit-image Funktion `skimage.metrics.normalized_root_mse`.

Diese Funktion normalisiert standardmäßig über die gemittelte Euklidische Norm des Originalbildes. Die Ergebnisse liegen zwischen 0 und 1, wobei 0 identische Bilder und 1 vollkommen unterschiedliche Bilder darstellt. Der höchste gemessene Wert für die getesteten Bildpaare beträgt 0,36. Aus diesem Grund werden die Diagramme auf den Bereich von 0 bis 0,5 beschränkt.

Histogramme realer und simulierter Bildpaare

Abbildung 6.19 verdeutlicht, dass sich die Verteilungen von realen und simulierten Bildern erheblich unterscheiden. Die gemessenen Werte für reale Bildpaare liegen im Bereich von 0,038 bis 0,362. Im Gegensatz dazu reichen die Werte für simulierte Bildpaare von 0,006 bis 0,067. Die Werte der realen Bilder zeigen eine deutlich größere Streuung, was durch eine Standardabweichung von 0,083 bestätigt wird. Die NRMSE-Werte der simulierten Bildpaare sind mit einer Standardabweichung von 0,011 um den Mittelwert von 0,027 verteilt, wobei der Median bei 0,025 liegt. Im Gegensatz dazu liegt der Durchschnitt der realen Bildpaare bei einem NRMSE-Wert von 0,205, während der Median 0,218 beträgt.




Abbildung 6.19.: Histogramme für NRMSE der realen und simulierten Bildpaare zwischen Regen und CAVOK Bilder.

Tageszeitabhängigkeit




Abbildung 6.20.: NRMSE der Bildpaare in Abhängigkeit von der Uhrzeit (blau: reale Bildpaare; orange: simulierte Bildpaare).

Abbildung 6.20 zeigt, dass keine klare Abhängigkeit der NRMSE-Werte von der Tageszeit besteht. Bei den realen Werten werden für alle Tageszeiten große Schwankungen in den Werten beobachtet. Die für den Zeitraum 12-14 Uhr ermittelten Werte sind jedoch besonders hoch. Im Gegensatz dazu zeigen die simulierten Bildpaare über den gesamten Tag hinweg keine nennenswerten Unterschiede.

6.3.2. PSNR

Implementierung

Die Berechnung der PSNR zwischen Bildpaaren wird unter Verwendung der Funktion `skimage.metrics.peak_signal_noise_ratio` durchgeführt. Wenn die Bilder identisch sind, wird „unendlich“ als Ergebnis angegeben. Entsprechend der Formel 4.7, ist dies der Fall, wenn der MSE Wert null beträgt und somit in der Formel durch null geteilt wird. Für die Ergebnisse gilt folglich, dass höhere Werte für ähnlichere Bilder stehen.




Abbildung 6.21.: Histogramme für PSNR der realen und simulierten Bildpaare zwischen Regen und CAVOK Bilder.

Histogramme realer und simulierter Bildpaare

Die Analyse der PSNR-Werte realer und synthetischer Bildpaare zeigt, dass deren Verteilungen ähnlicher ist, als die Verteilung der NRMSE-Werte. Wie in Abbildung 6.21 dargestellt, weisen beide Verteilungen eine Standardabweichung von etwa 4 auf und zeigen ein deutliches Maximum. Bei den realen Daten entspricht das Maximum dem Median von 15,81, während der Mittelwert mit 17,47 höher ist. Der niedrigste gemessene PSNR-Wert für die realen Bildpaare beträgt 11,81, der höchste 33,33. Im Gegensatz dazu korreliert das Maximum bei den simulierten Bildpaaren mit dem Median von 34,25, und der Mittelwert ist nur geringfügig höher, bei 34,74. Dies deutet darauf hin, dass alle simulierten Bildpaare höhere PSNR-Werte aufweisen als die zugehörigen realen Bildpaare. Insgesamt liegen die PSNR-Werte der simulierten Bildpaare zwischen 25,98 und 47,02.

Tageszeitabhängigkeit




Abbildung 6.22.: PSNR der Bildpaare in Abhängigkeit von der Uhrzeit (blau: reale Bildpaare; orange: simulierte Bildpaare).

Für die realen Bildpaare kann eine schwache Abhängigkeit vom Tageszeitpunkt beobachtet werden (siehe Abbildung 6.22). Fröhnmorgens und abends liegen die PSNR-Werte für diese Bildpaare etwas höher als tagsüber. Der Zeitraum zwischen 12 und 14 Uhr weist die schlechtesten Werte auf. Für die simulierten Bildpaare ist hingegen keine entsprechende Abhängigkeit von der Tageszeit feststellbar.

6.3.3. SSIM

Implementierung

Die Funktion zur Berechnung von SSIM im scikit-image Paket heißt `skimage.metrics.structural_similarity`.

Die Ergebnisse liegen zwischen null für komplett unterschiedliche Bilder und eins für identische Bilder.

Outlierhandling




Abbildung 6.23.: Outlier Bildpaar mit SSIM von 0,254.

Während bei der Auswertung von NRMSE und PSNR keine deutlichen Outlier festgestellt werden, ist bei den realen Bildpaaren für SSIM ein deutlicher Outlier erkennbar, der mit einem Wert von 0,254 auffällt. Das Bildpaar, das zu diesem Outlier gehört, ist in Abbildung 6.23 dargestellt. Es handelt sich um das gleiche Regenbild, das auch bei der Kanten- und Eckendetektion aufgrund der zahlreichen Regentropfen auf dem Kalibriermuster in Kombination mit Sonnenschein als Outlier identifiziert wurde. Auf dem zugeordneten CAVOK-Bild sind keine besonderen Merkmale erkennbar.

Histogramme realer und simulierter Bildpaare




Abbildung 6.24.: Histogramme für SSIM der realen und simulierten Bildpaare zwischen Regen und CAVOK Bilder.

Die in Abbildung 6.24 präsentierte Verteilung weist Ähnlichkeiten zur Verteilung der NRMSE-Werte auf. Erneut ist eine größere Streuung bei den realen Bildpaaren erkennbar. Diese Beobachtung wird durch eine Standardabweichung von 0,119 unterstützt. Im Vergleich dazu weisen die simulierten Bildpaare eine Standardabweichung von 0,006 auf. Wenn der zuvor erwähnte Ausreißer ignoriert wird, liegen die restlichen realen Bildpaare zwischen 0,55 und 0,93. Der Mittelwert beträgt 0,75 und der Median 0,73. Die simulierten Bildpaare besitzen SSIM-Werte im Bereich von 0,958 bis 0,996, mit einem Mittelwert von 0,985 und einem Median von 0,986. Die Verteilung der realen Bildpaare zeigt kein ausgeprägtes Maximum, während die simulierten Bildpaare ein Maximum beim Mittelwert aufweisen.

Tageszeitabhängigkeit




Abbildung 6.25.: SSIM der Bildpaare in Abhängigkeit von der Uhrzeit (blau: reale Bildpaare; orange: simulierte Bildpaare).

Die Tageszeitabhängigkeit der SSIM-Werte wird in Abbildung 6.25 dargestellt. Bei den simulierten Bildpaaren ist keine Tageszeitabhängigkeit erkennbar. Demgegenüber weisen die realen Daten eine Tageszeitabhängigkeit auf, die darauf hindeutet, dass die Bildpaare in den frühen Morgen- und Abendstunden eine höhere Übereinstimmung aufweisen als tagsüber. Insbesondere der Zeitraum zwischen 12 und 14 Uhr zeigt wiederum eine geringere Übereinstimmung.

6.4. Klassifikator- und Anwendungsbasiert

Alle Klassifizierermodelle, die für diese Kategorie trainiert werden, basieren auf der Architektur von ResNet-18. Die Datensätze werden nach dem Schema 80-10-10 in Trainings-, Validierungs- und Testdatensätze aufgeteilt. Darüber hinaus werden drei Methoden implementiert, um mit dem Klassenungleichgewicht zwischen CAVOK- und Regenbildern umzugehen. Die erste Methode ignoriert das Klassenungleichgewicht. Modelle, die mit dieser Methode trainiert werden, erhalten den Zusatz "Nichts". Die zweite Methode verwendet für das Training gleich viele Bilder aller Klassen, indem Bilder von Klassen mit weniger Bildern mehrfach verwendet werden. Modelle, die mit dieser Methode trainiert werden, werden im Folgenden als "SSampler" bezeichnet. Die dritte Methode passt die Gewichtung der Klassen in der Verlustfunktion an, indem Fehler bei Klassen mit weniger Beispielbildern stärker bewertet werden als bei Klassen mit vielen Bildern. Diese Methode wird im Folgenden als "Wichtung" beschrieben, und Modelle, die mit dieser Methode trainiert werden, erhalten diesen Zusatz. Um den Einfluss des Klassenungleichgewichts auszuschließen, werden Modelle mit allen Methoden trainiert und untereinander verglichen.

Aufgrund des Black-Box-Problems können die Einflüsse, die zu einer Entscheidung der Klassifizierung führen, nicht direkt erklärt werden. Deshalb werden in dieser Kategorie Modelle auf zugeschnittenen und nicht zugeschnittenen Bildern trainiert, um zu ermitteln, wie wichtig der Hintergrund für entscheidende Merkmale der Klassifizierung ist.

6.4.1. Cross-Dataset Generalisierung

Methodik

Für die Bewertung der Cross-Dataset-Generalisierung sind mindestens zwei Datensätze erforderlich, auf denen trainiert und ausgewertet werden kann. Im Rahmen dieser Arbeit werden ein realer und ein synthetischer Datensatz verwendet. Für die Aufteilung in Trainings-, Validierungs- und Testdatensätze werden jeweils die gleichen Bildpaare (reales Bild und das darauf basierend synthetisch erzeugte Bild) verwendet.

Auf beiden Datensätzen werden jeweils drei Modelle trainiert. Anschließend werden alle Modelle auf beiden Datensätzen ausgewertet. Dieser Prozess wird identisch für die zugeschnittenen und die originalen Bilder durchgeführt. Es erfolgt jedoch kein direkter Vergleich zwischen Modellen, die auf zugeschnittenen Bildern trainiert wurden, und denen, die auf den originalen Bildern trainiert wurden.

Ergebnisse der Modelle auf realen Bildern nach Training auf zugeschnittenen Bildern


Abbildung 6.26 zeigt die Konfusionsmatrizen für alle Modelle, die auf zugeschnittenen Bildern trainiert und auf realen zugeschnittenen Bildern ausgewertet werden. Zusätzliche Tabellen mit einer Übersicht zu Metriken wie Recall, Precision, F1-Score und Genauigkeit, die sich aus der Konfusionsmatrix berechnen lassen, sind der Arbeit angefügt (siehe Anhang Tabellen A.1 und A.2). Die Konfusionsmatrizen der Modelle, die auf realen Daten trainiert wurden, zeigen sehr gute Ergebnisse. Es ist erkennbar, dass nahezu alle Bilder aus dem Testdatensatz korrekt zugeordnet werden. Je nach Modell werden nur vier bis sechs Bilder fehlerhaft zugeordnet, was zu Genauigkeiten zwischen 90 und 93,33% führt. Bei den Bildern, die falsch zugeordnet werden, tritt häufiger eine fehlerhafte Zuordnung eines CAVOK-Bildes als Regenbild auf als eine fehlerhafte Zuordnung eines Regenbildes als CAVOK-Bild.

Die Modelle, die auf simulierten Bildern trainiert wurden, weisen eine deutliche Bevorzugung der Klasse CAVOK auf. Keines der drei Modelle kann ein Regenbild korrekt klassifizieren. Da die meisten CAVOK-Bilder korrekt klassifiziert werden, liegen die Genauigkeiten dieser Modelle zwischen 68,33 und 71,67%.


Ergebnisse der Modelle auf synthetischen Bildern nach Training auf zugeschnittenen Bildern

Die Ergebnisse der Auswertung der Modelle auf den synthetischen zugeschnittenen Bildern sind in Abbildung 6.27 dargestellt. Für alle Modelle, die auf realen Daten trainiert werden, gilt, dass alle Bilder als CAVOK-Bilder klassifiziert werden. Aufgrund des Klassenungleichgewichts ergibt sich dadurch dennoch für alle Modelle eine Genauigkeit von 71,67%.


Bei den Modellen, die auf synthetischen Bildern trainiert werden, treten große Unterschiede auf. Die Modelle Sim-Nichts und Sim-Sampler bevorzugen weiterhin die Klasse CAVOK und klassifizieren nur wenige Bilder als Regenbilder. Bei diesen Bildern handelt es sich tatsächlich um




(a) Konfusionsmatrix für das Modell Real-Nichts auf dem realen zugeschnittenen Datensatz ausgewertet.




(b) Konfusionsmatrix für das Modell Real-Sampler auf dem realen zugeschnittenen Datensatz ausgewertet.




(c) Konfusionsmatrix für das Modell Real-Wichtung auf dem realen zugeschnittenen Datensatz ausgewertet.



(d) Konfusionsmatrix für das Modell Sim-Nichts auf dem realen zugeschnittenen Datensatz ausgewertet.



(e) Konfusionsmatrix für das Modell Sim-Sampler auf dem realen zugeschnittenen Datensatz ausgewertet.



(f) Konfusionsmatrix für das Modell Sim-Wichtung auf dem realen zugeschnittenen Datensatz ausgewertet.

Abbildung 6.26.: Vergleich der Ergebnisse aller Modelle für zugeschnittene Bilder auf dem realen Datensatz ausgewertet.

Regenbilder, sodass diese Modelle keine CAVOK-Bilder fälschlicherweise als Regenbilder klassifizieren. Dies resultiert in Genauigkeiten von 80,00% (Sim-Nichts) und 83,33% (Sim-Sampler). Das Modell Sim-Wichtung ist das beste Modell, das auch Regenbilder zuverlässig korrekt klassifiziert und nur wenige Fehler insgesamt macht. Dieses Modell weist eine Genauigkeit von 91,67% auf.

Die berechneten Ergebnisse zu Recall, Precision und F1-Score befinden sich im Anhang (siehe Anhang Tabellen A.3 und A.4).

Ergebnisse der Modelle auf realen Bildern nach Training auf originalen Bildern

Die Ergebnisse der Auswertung auf den realen originalen Bildern sind in Abbildung 6.28 dargestellt. Für alle drei Modelle, die auf realen Daten trainiert werden, zeigen die Konfusionsmatrizen die gewünschte Diagonale von oben links nach unten rechts. Dies zeigt, dass die Modelle die meisten Bilder korrekt klassifizieren. Das schlechteste Modell in dieser Kategorie ist Real-Nichts, das sieben Regenbilder fehlerhaft als CAVOK klassifiziert und dadurch eine Genauigkeit von nur 88,33% erreicht. Die anderen beiden Modelle machen kaum Fehler und erreichen Genauigkeiten von 95,00% (Real-Sampler) und 96,67% (Real-Wichtung). Mit Ausnahme des Real-Nichts-Modells sind die Modelle besser als die Modelle, die auf zugeschnittenen Bildern trainiert und ausgewertet werden.




Abbildung 6.27.: Vergleich der Ergebnisse aller Modelle für zugeschnittene Bilder auf dem synthetischen Datensatz ausgewertet.

Für die Modelle, die auf simulierten Daten trainiert werden, zeigt sich ein deutlicher Trend, dass die Klasse Regen bevorzugt wird. Das Modell Sim-Nichts klassifiziert kein einziges Bild als CAVOK. Sim-Sampler und Sim-Wichtung klassifizieren 2 bzw. 7 Bilder korrekt als CAVOK-Bilder. Aufgrund des Klassenungleichgewichts zwischen CAVOK und Regen ergeben sich dadurch dennoch nur Genauigkeiten zwischen 28,33% und 40,00%. Dass diese Modelle Regen als Klasse bevorzugen, steht im direkten Gegensatz zu den Ergebnissen bei den zugeschnittenen Bildern, wo CAVOK als Klasse bevorzugt wird. Weitere Informationen zu den Ergebnissen sind in den Tabellen A.5 und A.6 im Anhang aufgelistet.

Ergebnisse der Modelle auf synthetischen Bildern nach Training auf originalen Bildern

Werden die Modelle die auf realen originalen Daten trainiert wurden auf synthetischen Daten ausgewertet, zeigt sich ebenfalls eine Tendenz dazu die Klasse Regen zu bevorzugen (siehe Abbildung 6.29). Gleichzeitig werden einige CAVOK-Bilder korrekt klassifiziert. In diesem Szenario weist das Modell Real-Nichtsmit einer Genauigkeit von 80,00% die beste Leistung auf. Das schlechteste Modell für diese Kombination ist Real-Samplermit einer Genauigkeit von 51,67%.

Die Sim-Modelle zeigen bei der Auswertung auf simulierten, originalen Bildern eine sehr gute Leistung. Das schlechteste Modell ist SSim-Wichtungmit je einem fehlerhaft klassifizierten




Abbildung 6.28.: Vergleich der Ergebnisse aller Modelle für originalen Bilder auf dem realen Datensatz ausgewertet.

CAVOK- und Regenbild. Dieses Modell erreicht eine Genauigkeit von 96,67%. Die beiden anderen Modelle klassifizieren jeweils ein Regenbild als CAVOK-Bild und weisen eine Genauigkeit von 98,33% auf. Für Precision, Recall und F1-Score wird auf die Tabellen A.7 und A.8 im Anhang verwiesen.


6.4.2. Real/Synthetisch Klassifizierer

Methodik


Für den Real/Synthetisch-Klassifizierer wird ein neuer Datensatz erstellt, der die beiden zuvor verwendeten Datensätze kombiniert und vier Klassen umfasst: real-CAVOK, real-Regen, sim-CAVOK und sim-Regen. Es werden zwei Experimente durchgeführt, bei denen Modelle sowohl für die zugeschnittenen als auch die originalen Bilder trainiert werden.

Ergebnisse der Modelle nach Training auf zugeschnittenen Bildern


Abbildung 6.30 zeigt die Auswertung für zugeschnittene Bilder. Alle Modelle können zwischen realen und synthetischen Daten unterscheiden, ohne dass es zu Fehlklassifizierungen kommt. Darüber hinaus zeigt sich, dass alle Modelle die realen Daten gut klassifizieren können. Die synthetischen Daten werden jedoch nahezu vollständig als sim-CAVOK klassifiziert. Das Modell




(a) Konfusionsmatrix für das Modell Real-Nichts auf dem synthetischen originalen Datensatz ausgewertet.




(b) Konfusionsmatrix für das Modell Real-Sampler auf dem synthetischen originalen Datensatz ausgewertet.




(c) Konfusionsmatrix für das Modell Real-Wichtung auf dem synthetischen originalen Datensatz ausgewertet.



(d) Konfusionsmatrix für das Modell Sim-Nichts auf dem synthetischen originalen Datensatz ausgewertet.




(e) Konfusionsmatrix für das Modell Sim-Sampler auf dem synthetischen originalen Datensatz ausgewertet.




(f) Konfusionsmatrix für das Modell Sim-Wichtung auf dem synthetischen originalen Datensatz ausgewertet.


Abbildung 6.29.: Vergleich der Ergebnisse aller Modelle für originale Bilder auf dem synthetischen Datensatz ausgewertet.



(a) Konfusionsmatrix für das Modell Nichts auf dem zugeschnittenen Datensatz ausgewertet.



(b) Konfusionsmatrix für das Modell Sampler auf dem zugeschnittenen Datensatz ausgewertet.




(c) Konfusionsmatrix für das Modell Wichtung auf dem zugeschnittenen Datensatz ausgewertet.

Abbildung 6.30.: Vergleich der Ergebnisse aller Modelle für den Real/Synthetisch Klassifizierer auf zugeschnittenen Bildern.

„Wichtung“ weist mit einer Genauigkeit von 89,17% die beste Leistung auf. Mit einer Genauigkeit von 84,17% schneidet das Modell „Nichts“ am Schlechtesten ab. Tabelle A.9 im Anhang enthält eine Auflistung von Genauigkeit, Precision, Recall und F1-Score für alle Modelle.

Ergebnisse der Modelle nach Training auf originalen Bildern



(a) Konfusionsmatrix für das Modell Nichts auf dem originalen Datensatz ausgewertet.

(b) Konfusionsmatrix für das Modell Sampler auf dem originalen Datensatz ausgewertet.

(c) Konfusionsmatrix für das Modell Wichtung auf dem originalen Datensatz ausgewertet.

Abbildung 6.31.: Vergleich der Ergebnisse aller Modelle für den Real/Synthetisch Klassifizierer auf originalen Bildern.

Die Ergebnisse der Auswertung auf den originalen Bildern mit Hintergrund sind in Abbildung 6.31 dargestellt. Alle Modelle können zuverlässig zwischen realen und synthetischen Bildern unterscheiden. Darüber hinaus können die Modelle sowohl für reale als auch für synthetische Bilder zuverlässig zwischen CAVOK- und Regenbildern unterscheiden. Das Modell „Sampler“ weist in diesem Fall mit einer Genauigkeit von 97,50% die beste Leistung auf. Im Gegensatz dazu zeigt das Modell "Wichtung" mit einer Genauigkeit von 90,83% die schlechteste Leistung. Weitere Informationen zu den Ergebnissen der Modelle finden sich im Anhang (siehe Tabelle A.10).

Kapitel 7.

Auswertung und Diskussion der Differenzanalyse

Obwohl die Datensätze eher klein sind, können in Kapitel 6 Effekte in den Daten beobachtet werden, die in diesem Kapitel einer genaueren Untersuchung unterzogen werden. Wo möglich, werden die beschriebenen Effekte durch Bilder veranschaulicht, um die Auswertung zu unterstützen. Die Ergebnisse dieses Kapitels können als Grundlage für weitere, tiefer gehende Untersuchungen und eine Anpassung der Simulation dienen.

Das Kapitel ist in die in Kapitel 3 vorgestellten Kategorien und innerhalb dieser in die einzelnen Methoden unterteilt. Jede Methode wird einzeln ausgewertet. Am Ende der Unterkapitel für jede Kategorie folgt ein Abschnitt, in dem die Zusammenhänge der Ergebnisse der einzelnen Methoden diskutiert werden. Darüber hinaus enthält das Kapitel eine kritische Würdigung der hier durchgeführten Differenzanalyse und der Auswahl der Methoden.

7.1. Strukturunabhängige Bildmerkmale

Bei der Auswertung der Methoden dieser Kategorie wird berücksichtigt, dass diese Methoden globale Maße sind, aus denen keine Aussagen über lokale Einflüsse oder Strukturen gezogen werden können.

7.1.1. Helligkeit

Die durchgeführte Differenzanalyse ergibt, dass die Helligkeit sowohl realer als auch synthetischer Bilder in Abhängigkeit von der Tageszeit variiert. Zudem zeigen Regenbilder eine geringere Varianz im Vergleich zu Bildern unter CAVOK-Bedingungen. Für reale Bilder gilt zusätzlich, dass Regenbilder eine geringere Helligkeit aufweisen als CAVOK-Bilder. Im Kontrast dazu weisen Regenbilder aus der Simulation eine höhere Helligkeit auf.

Bevor die Bedeutung dieser Beobachtungen diskutiert wird, erfolgt ein Vergleich von Referenzbildern für jeden Datensatz. Als Referenzbilder werden solche ausgewählt, deren Helligkeitswert nahe am Median des jeweiligen Datensatzes liegt. Nach einer kurzen Auswertung dieser Referenzbilder werden die zuvor erwähnten Effekte erläutert.




Abbildung 7.1.: Repräsentative Bilder für die Helligkeitsverteilung der vier Subdatensätze.

Referenzbilder

Die in Abbildung 7.1 dargestellten Bilder dienen als Referenzbilder für die vier in der Differenzanalyse verwendeten Datensätze. Eine Untersuchung der Bilder zeigt, dass die Farben in den realen Bildern eine geringere Intensität aufweisen als in den simulierten Bildern und insbesondere im Vergleich zum originalen Entwurf des Kalibrierungsmusters (siehe Abbildung 5.1). Eine weitere Beobachtung ist, dass die weißen Flächen eher grau erscheinen, was die Helligkeit stark beeinflusst. Die Gründe hierfür können im Druckprozess, der Kamera und den Wetterbedingungen, einschließlich Umgebungslicht und Staub in der Luft, liegen.

Wie bereits erwähnt, weisen auch die Farben in den simulierten Bildern eine geringere Klarheit auf als im originalen Entwurf des Kalibrierungsmusters. Insbesondere die weißen Flächen sind von diesen farblichen Veränderungen betroffen. Im Rahmen der Simulation kann der Einfluss des Drucks ausgeschlossen werden. Stattdessen haben das simulierte Umgebungslicht durch die Sonne, das gewählte Material für das Kalibrierungsmuster und die Render-Einstellungen einen Einfluss auf das erzeugte Bild. Ohne weitere Untersuchungen kann der spezifische Einfluss dieser Faktoren nicht bestimmt werden.

Effekte realer Bilder

Die Auswertung der realen Bilder zeigt, dass die Helligkeit der Bilder stark von der Tageszeit abhängt. Dies kann durch die Veränderung des Umgebungslichtes im Laufe des Tages erklärt werden.

Darüber hinaus wird festgestellt, dass Regenbilder tendenziell dunkler sind als CAVOK-Bilder, selbst wenn die Bilder zur gleichen Tageszeit aufgenommen wurden. Dies deutet darauf hin, dass es neben den in dieser Arbeit betrachteten Effekten (fallende Regentropfen, Tropfen auf dem Kalibriermuster und Tropfen auf der Linse) weitere Faktoren gibt, die einen Einfluss haben. Der Einfluss auf die Helligkeit kann durch Wolken erklärt werden, die das Sonnenlicht blockieren oder nur teilweise durchlassen und die Umgebung somit dunkler erscheinen lassen.

Ein weiterer beobachteter Effekt bei den realen Bildern ist, dass die Regenbilder eine deutlich geringere Varianz aufweisen. Mögliche Erklärungen hierfür sind, dass keine Regenbilder aus den frühen Morgenstunden vorliegen, die auch bei den CAVOK-Bildern die Varianz stark beeinflussen. Eine andere Erklärung bezieht sich auf den Einfluss von Wolken, die nicht nur die Umgebungshelligkeit verringern, sondern auch helle Lichtflecken auf dem Kalibriermuster verhindern, wenn die Sonne direkt darauf scheint. Dies schließt besonders helle Bilder aus. Um den Grund für die geringere Varianz der Regenbilder besser zu verstehen, sind weitere Bildaufnahmen notwendig.

Effekte simulierter Bilder

Die simulierten Bilder zeigen mehrere Effekte. Ähnlich wie bei den realen Bildern besteht eine Tageszeitabhängigkeit, die jedoch abgesehen von den frühen Morgenstunden deutlich schwächer ausgeprägt ist. Insbesondere zum Abend hin bleibt die Helligkeit nahezu konstant. Dies könnte mit der Beobachtung zusammenhängen, dass der Sonnenstand in der Unreal Engine nicht dem realen Sonnenstand entspricht.

Während die realen Regenbilder tendenziell dunkler sind als entsprechende CAVOK-Bilder, zeigen die simulierten Regenbilder eine tendenziell höhere Helligkeit als simulierte CAVOK-Bilder. Die Helligkeit ergibt sich aus den einzelnen Pixelwerten eines Bildes. Da in der Simulation Wolken bisher nicht berücksichtigt werden, können diese das Umgebungslicht nicht beeinflussen. Dafür treten in den Regenbildern vereinzelt helle Regentropfen auf, die dunkle Bereiche des Kalibrierusters überlagern und somit die globale Helligkeit erhöhen.

Ähnlich wie bei den realen Bildern weisen simulierte Regenbilder eine geringere Standardabweichung auf. In diesem Fall kann ein Einfluss durch Wolken ausgeschlossen werden, und es bleibt nur die Erklärung, dass das Fehlen von Bildern aus den Morgenstunden einen deutlichen Einfluss hat.

Darüber hinaus zeigt sich, dass die simulierten CAVOK-Bilder, mit Ausnahme der Outlier, weniger gestreut sind als die realen CAVOK-Bilder. Dieser Effekt kann mit der Simulation der Sonne und der Dämmerung zusammenhängen. Darüber hinaus können auch Effekte durch die Kamera eine Rolle spielen. Aufgrund der aktuellen Ergebnisse ist es jedoch nicht möglich, eine deutliche Aussage zu treffen.

Zusammenfassung

Die Auswertung der Helligkeit zeigt, dass eine starke Abhängigkeit von der Tageszeit besteht, die in der Simulation jedoch bisher zu schwach ausgeprägt ist. Darüber hinaus haben übergreifende Abhängigkeiten, wie Wolken bei Regen, einen wichtigen Einfluss, der in zukünftigen Simulationen berücksichtigt werden sollte, um eine realistische Darstellung zu erzielen.

7.1.2. Kontrast

Für die Auswertung des Kontrasts ist es notwendig, die externen Faktoren, die nicht beeinflusst werden können, wie Kamera, Umgebungslicht und Druck, in die Analyse einzubeziehen. Diese Faktoren können bewirken, dass die Farben weniger intensiv erscheinen als ursprünglich im Entwurf des Kalibrierungsmusters vorgesehen. Als Folge davon können die Abweichungen zwischen hellen und dunklen Bildbereichen geringer ausfallen, was zu einem geringeren Kontrast führt.

Im Rahmen der Differenzanalyse werden verschiedene Effekte beobachtet. So weisen reale CAVOK-Bilder eine größere Varianz auf als reale Regenbilder. Bei realen Datensätzen ist keine deutliche Abhängigkeit von der Tageszeit erkennbar. Im Gegensatz dazu zeigen simulierte Datensätze eine solche Abhängigkeit. Darüber hinaus weisen simulierte Bilder eine bimodale Verteilung auf und besitzen einen höheren Durchschnittswert als reale Datensätze. Im Folgenden werden diese Effekte detaillierter analysiert.

Effekte realer Bilder

Es ist zu beobachten, dass die Streuung des Kontrasts in realen CAVOK-Bildern größer ist als in realen Regenbildern. Möglicherweise spielen fehlende Bilder aus den frühen Morgenstunden eine Rolle. Es zeigt sich jedoch, dass die Aufnahmen von realen CAVOK-Bildern zum frühen Morgen nicht unbedingt einen geringeren Kontrast aufweisen. Stattdessen hat die Tageszeit, abgesehen von 12-14 Uhr, keinen signifikanten Einfluss auf den Kontrast von CAVOK-Bildern. Es wird vermutet, dass die fehlende Varianz bei Regenbildern eher darauf zurückzuführen ist, dass es keine Bilder mit einem so hohen Kontrast gibt wie bei den CAVOK-Bildern zwischen 12 und 14 Uhr. Dies könnte auf Wolken zurückzuführen sein, die für ein einheitliches Umgebungslicht sorgen, und sollte in Zukunft gezielter untersucht werden. Eine Analyse der CAVOK-Bilder aus dem genannten Zeitraum ergibt keinen deutlichen Grund für den erhöhten Kontrast.

Der durchschnittlich höhere Kontrast bei realen Regenbildern könnte auf die Regentropfen zurückzuführen sein, die lokal die Intensität von Pixeln erhöhen. Da jedoch auf vielen Bildern nur wenige sehr kleine Regentropfen zu sehen sind und nur 166 Regenbilder zur Auswertung zur Verfügung stehen, sollten diese Ergebnisse in Zukunft genauer untersucht werden, um auszuschließen, dass die realen Regenbilder nur durch Zufall tagsüber durchschnittlich einen höheren Kontrast haben als die realen CAVOK-Bilder.

Effekte simulierter Bilder

Die Verteilung der Kontrastwerte aller simulierten Bilder ist bimodal und weicht von der annähernden Gauß-Verteilung der realen Daten ab. Die Ursache für diesen Effekt ist mit den vorliegenden Daten nicht eindeutig zu erklären. Ein möglicher Einflussfaktor könnten die störungsfreien Simulationsbedingungen sein, bei denen viele reale Effekte nicht abgebildet sind. Dies führt dazu, dass für jeden Tag in der Simulation Bilder mit dem gleichen Kontrast für dieselbe Uhrzeit entstehen. Im Gegensatz dazu scheinen reale Bilder über den gesamten Tag




Abbildung 7.2.: Beispiele für die Variabilität realer Bilder und die Einheitlichkeit simulierter Bilder die zu ähnlicher Zeit aufgenommen werden.

weitere Einflüsse zu unterliegen, die den Kontrast eines Bildes verändern können. Abbildung 7.2 zeigt, dass simulierte Bilder, die zu einer ähnlichen Zeit aufgenommen werden, nahezu identisch aussehen, während reale Bilder sowohl in der Farbe als auch der Farbintensität variieren können, was zu einer Änderung des Kontrasts führt.

Die Analyse der Kontraste simulierter Bilder zu unterschiedlichen Uhrzeiten ergibt, dass der Kontrast zwischen 12 und 17 Uhr sehr hoch ist, da die Bilder intensive Farben und einen hellen Hintergrund aufweisen (siehe Abbildungen 7.2c und 7.2d). Vor 8 und nach 21 Uhr ist der Kontrast dagegen deutlich geringer. Die Betrachtung dieser Bilder zeigt, dass die Farbintensität abnimmt und vor allem die schwarzen Bereiche des Kalibriermusters eher grau wirken, was den realen Bildern entspricht, die tagsüber aufgenommen werden (siehe Abbildung 7.3a). Diese zwei Zeitbereiche, in denen die simulierten Bilder alle den gleichen Kontrast aufweisen, entsprechen den beiden Maxima, die in den Histogrammen zu erkennen sind.

Die Beobachtung, dass die Durchschnittswerte des Kontrasts bei simulierten Bildern höher sind als bei realen Bildern, kann durch die Annahme erklärt werden, dass die Simulation störungsärmer und detailreichere Bilder generiert. Dies führt dazu, dass der Kontrast automatisch höher ist, wenn beispielsweise die Farbintensität höher ist, die im realen Aufbau durch Faktoren wie



(a) Simuliertes CAVOK Bild am 25.06.25 um 21:19 Uhr aufgenommen. Kontrast: 58,85 (b) Simuliertes Regenbild am 29.07.25 um 12:18 Uhr aufgenommen. Kontrast: 76,60

Abbildung 7.3.: Weitere Beispiele von simulierten Bildern mit interessanten Kontrast Effekten. Links: ausgegraut wirkenden Bild, welches in einen Zeitraum mit niedrigen Kontrastwerten fällt; Rechts: simuliertes Regenbild mit dem höchsten Kontrast, aber ohne sichtbare Regeneffekte.

Druck, Kamera und Umgebungseinflüsse reduziert werden kann.

Obwohl simulierte Regenbilder im Durchschnitt einen höheren Kontrast aufweisen als simulierte CAVOK-Bilder, ist es unwahrscheinlich, dass dies ein Effekt ist, der durch die Regeneffekte verursacht wird. Es ist eher anzunehmen, dass es sich um einen zufälligen Effekt der vorliegenden Datensätze handelt. Wie oben beschrieben korrespondieren die beiden Maxima mit den Hauptkontrasten zu verschiedenen Tageszeiten, und die beiden Maxima für die beiden Subdatensätze stimmen in ihrer Position überein. Im Regenbild-Datensatz sind jedoch deutlich mehr Bilder aus der Zeit zwischen 12 und 17 Uhr enthalten, während im CAVOK-Datensatz Bilder aus anderen Zeiträumen überwiegen. Außerdem kann die Hypothese, dass fallende Regentropfen einen großen Einfluss haben, widerlegt werden, wenn das simulierte Regenbild mit dem größten Kontrast betrachtet wird, auf dem keiner der Effekte für Regen zu erkennen ist (siehe Abbildung 7.3b).

Zusammenfassung

Die wichtigste Erkenntnis aus der Auswertung der Kontraste ist, dass die Simulation störungsarme Bilder erzeugt, die keine kleinen Abweichungen wie in der Realität beinhalten. Die Ursache dafür liegt wahrscheinlich in übergreifenden Abhängigkeiten, die an dieser Stelle nicht genauer benannt werden können. Im Gegensatz zur Helligkeit zeigt sich für den Kontrast nur eine schwache Tageszeitabhängigkeit, was darauf zurückzuführen sein könnte, dass zu den meisten Zeiten das gesamte Kalibriermuster heller oder dunkler wird und sich der Kontrast folglich nicht verändert. Für reale CAVOK-Bilder gibt es zwischen 12 und 14 Uhr unerklärlich hohe Kontrastwerte, die in Zukunft näher untersucht werden sollten. Es zeigt sich erneut, dass die identifizierten Regeneffekte einen deutlich geringeren Einfluss haben als übergreifende Abhängigkeiten wie die Tageszeit. Insbesondere die Regendatensätze sind bisher zu klein, um eine umfassende Analyse durchzuführen.

7.1.3. Bildschärfe

Im Folgenden werden die folgenden Effekte analysiert: Die Varianz von Regenbildern ist geringer als die von CAVOK-Bildern. Sowohl reale als auch simulierte Regenbilder weisen tendenziell höhere Bildschärfen auf als CAVOK-Bilder. Die MLV-Bildschärfe zeigt eine Abhängigkeit von der Tageszeit, während dies bei der Laplace-Bildschärfe nicht der Fall ist.

MLV Bildschärfe Effekte realer Bilder

Die geringere Varianz von realen und synthetischen Regenbildern kann durch die begrenzte Größe des Datensatzes und die mangelnde Repräsentation von Bildern aus dem frühen Morgen erklärt werden. Der höhere Bildschärfewert von realen Regenbildern im Vergleich zu realen CAVOK-Bildern ist möglicherweise auf weitere Faktoren zurückzuführen, wie aus dem Diagramm zur Tageszeitabhängigkeit hervorgeht. Dieses Diagramm zeigt, dass reale Regenbilder in den meisten Fällen eine höhere Bildschärfe aufweisen als reale CAVOK-Bilder. Ein möglicher Grund dafür sind die Regentropfen, die lokal die Pixelwerte verändern und somit die Bildschärfe beeinflussen. Obwohl Regentropfen ein Bild für einen Menschen tendenziell unschärfer wirken lassen, entsprechen sie der Definition der Bildschärfe, die die Klarheit von Details in einem Bild misst. Jeder Regentropfen stellt ein zusätzliches Detail dar, das klar dargestellt wird. Weitere übergreifende Abhängigkeiten könnten ebenfalls zur erhöhten Bildschärfe bei realen Regenbildern beitragen.

MLV Bildschärfe Effekte simulierter Bilder

Auch bei synthetischen Bildern zeigt sich, dass die Bildschärfe von Regenbildern tendenziell höher ist als die von CAVOK-Bildern. Dieser Unterschied ist im Histogramm deutlich sichtbar. Das Tageszeitendiagramm deutet darauf hin, dass der große Unterschied eher auf die Verteilung in den Datensätzen zurückzuführen ist. Dennoch weisen Regenbilder zu gleichen Tageszeiten durchschnittlich eine höhere Bildschärfe auf, mit Ausnahme des Zeitraums von 12 bis 17 Uhr. Die vorliegenden Daten reichen jedoch nicht aus, um die Ursachen für diese Ergebnisse zu erklären.

Des Weiteren fällt auf, dass simulierte Bilder eine generell höhere Bildschärfe aufweisen als reale Bilder. Dies deutet darauf hin, dass die Simulation Kanten und Details klarer rendert als dies in der Realität möglich ist.

Laplace Bildschärfe Effekte

Es fällt auf, dass die Laplace Bildschärfe keine Tageszeitabhängigkeit bei realen Bildern zeigt. Dies lässt sich durch die Definition der beiden Metriken erklären. Die Metrik MLV misst direkt den Unterschied zwischen zwei Pixelwerten und ist somit stark anfällig für Pixelrauschen. Im Gegensatz dazu ist der Laplace Operator ein zweiter Ableitungsfiler, der flaches Rauschen unterdrückt und somit einheitlichere Ergebnisse erzeugt. Dies könnte auch eine Erklärung für die unterschiedlichen Effekte bei speziellen Wetterbedingungen sein. Regentropfen auf der Linse können die betroffenen Bereiche ausgrauen und haben einen großflächigen Einfluss auf die MLV Bildschärfe. Im Gegensatz dazu hängt die Laplace Bildschärfe vor allem davon ab, ob noch immer Kanten zu erkennen sind. Solange die Tropfen auf der Linse die Kanten nicht komplett überlagern, werden diese noch immer betrachtet. Die Gründe für die Ähnlichkeit der Tageszeitabhängigkeit der Laplace Bildschärfe und der MLV Bildschärfe bei simulierten Bildern sind aus den vorhandenen Daten nicht ersichtlich.

Zusammenfassung

Diese Auswertung zeigt, dass sich die Effekte von Regen auf die Bildschärfe messbar auswirken. Der bestehende Datensatz schränkt jedoch eine tiefer gehende Untersuchung ein. Die Abhängigkeit der Bildschärfe von der Tageszeit hängt stark von der gewählten Methode ab. Die Simulation des Einflusses von Regen auf eine erhöhte Bildschärfe ist zwar erfolgreich, dennoch weist die Simulation erhebliche Unterschiede zu realen Effekten auf. Simulierte Bilder weisen generell eine höhere Bildschärfe auf als reale Bilder.

7.1.4. Zusammenhang der Ergebnisse für Methoden der einfachen Statistik

Ein Nachteil dieser Methoden ist, dass sie globale Maße darstellen. Dennoch können einige Beobachtungen gemacht werden. Alle Methoden zeigen, dass der Unterschied zwischen CAVOK und Regen nicht nur von den betrachteten Regeneffekten abhängt. Weitere übergreifende Abhängigkeiten, wie die Bewölkung bei Regen, haben einen wichtigen Einfluss, der in Zukunft genauer untersucht werden sollte. Außerdem erzeugt die Simulation für alle Methoden Bilder mit zu geringen Störungen. Dies zeigt sich darin, dass alle Bilder einer Uhrzeit nahezu identisch sind und die Bildschärfe deutlich höher liegt als bei realen Bildern.

Aus der Analyse der Metriken untereinander können ebenfalls Rückschlüsse gezogen werden. Während die Helligkeit eine starke Tageszeitabhängigkeit zeigt, ist der Kontrast für reale Bilder nahezu unabhängig von der Tageszeit. Da die Helligkeit in dieser Arbeit über RMS berechnet wird und der Kontrast als RMS-Kontrast die Standardabweichung dieses Maßes ist, kann der Schluss gezogen werden, dass bei realen Bildern alle Bereiche des Bildes über den Tag heller oder dunkler werden, ohne dass sich der Kontrast ändert. Bei simulierten Bildern ist dieses Verhalten nicht zu beobachten. Stattdessen ändert sich eher der Farbton und die Farbintensität über den Tag.

7.2. Low-Level Feature Analyse

Ähnlich wie die Methoden der strukturunabhängigen Bildmetriken liefern die vorgestellten Metriken wie Kantenpixelanzahl, Kantenanzahl und Eckenanzahl ein globales Ergebnis. Durch die Möglichkeit, die Position der Kanten und Ecken zu visualisieren, können weitere Eindrücke gewonnen werden. Dafür weisen diese Methoden den Nachteil auf, dass sie von mehreren Parametern abhängen, die die Ergebnisse beeinflussen können. In dieser Arbeit wird der Einfluss der verschiedenen Parameter nicht untersucht.

7.2.1. Kantendetektion

Bei der Kantendetektion werden sowohl die Kantenpixel, die durch den Canny-Algorithmus bestimmt werden, als auch die Kanten, die anschließend durch die Hough-Transformation identifiziert werden, berücksichtigt.

Optisch erkennbare Effekte im Outlier Bild


Abbildung 6.9 zeigt das Bild mit der höchsten Anzahl an Kanten. Bei diesem Bild können mehrere Effekte beobachtet werden, die aus der Auswertung der Metriken nicht direkt hervorgehen. Der zentrale Bereich, der vom Regentropfen auf der Linse der Kamera beeinflusst wird, weist keine erkannten Kanten auf. Am Rand des Bereichs werden die Kanten jedoch wieder zuverlässig erkannt. Des Weiteren kann beobachtet werden, dass Tropfen auf dem Kalibriermuster einen starken Einfluss auf die Anzahl der erkannten Kanten haben können. Der Unterschied zu anderen Regenbildern mit Tropfen auf dem Kalibriermuster besteht darin, dass bei diesem Bild die Sonne geschienen hat und die Tropfen angestrahlt hat. Diese Kombination sollte in Zukunft berücksichtigt werden, da sie einen starken Einfluss auf Anwendungen, die sich auf die Kantenerkennung stützen, haben kann. Außerdem ist zu beobachten, dass Regentropfen auf dunklen Flächen deutlich schlechter erkannt werden als auf hellen Flächen. Diese Erkenntnis ist für das Design weiterer Kalibriermuster relevant. Bisher sind diese Effekte jedoch nicht in der Simulation umsetzbar. Die Implementierung von Tropfen auf der Linse weist Fehler auf, und das Material der Regentropfen ist zum Zeitpunkt der Entstehung dieser Arbeit nicht reflektierend.

Effekte der Kantenpixellanzahl

Bei der Analyse der erkannten Kantenpixel wird deutlich, dass Regenbilder im Durchschnitt eine geringfügig höhere Anzahl an Kantenpixel aufweisen als CAVOK-Bilder. Dies könnte auf die Anwesenheit von Regentropfen zurückzuführen sein. Allerdings sind die Effekte so gering, dass sie als vernachlässigbar betrachtet werden können. Des Weiteren wird beobachtet, dass die Standardabweichung der Kantenpixellanzahl bei simulierten Bildern geringer ist als bei realen Bildern. Dies ist wahrscheinlich auf die Abwesenheit von Rauschen durch Umwelteinflüsse oder die Kamera bei simulierten Bildern zurückzuführen.

Sowohl für reale als auch synthetische Daten zeigt sich keine erkennbare Tageszeitabhängigkeit. Darüber hinaus liegt die Anzahl der Kantenpixel für alle Datensätze in einem ähnlichen Bereich, sodass aus dieser Metrik keine weiteren Erkenntnisse gewonnen werden können.

Einfluss von Verschiebungen und Rotation auf die Kantenzahl



(a) Reales zugeschnittenes Bild ohne Rotationseffekte.

(b) Reales zugeschnittenes Bild mit sichtbarer Rotation.

(c) Mehrere erkannte Kanten durch Rotation des Bildes.

Abbildung 7.4.: Beispielbilder für die Auswirkung mechanischer Einflüsse auf die Ausrichtung der realen Bilder nach dem Zuschneiden.

Im Vergleich dazu unterscheiden sich die Verteilungen für die Anzahl der Kanten zwischen realen und synthetischen Bildern deutlich. Simulierte Bilder weisen typischerweise eine geringere Anzahl an Kanten auf als ihre realen Pendanten. Eine mögliche Erklärung für dieses Phänomen liegt in der Art der Bildaufnahme. Bei synthetischen Bildern kann gewährleistet werden, dass diese immer aus dem gleichen Blickwinkel aufgenommen werden, was zu einer zuverlässigen automatischen Bildzuschneidung führt. Im Gegensatz dazu können bei realen Aufnahmen leichte Kameradrehungen durch äußere mechanische Effekte nicht ausgeschlossen werden, was sich auf die Berechnung der zugeschnittenen Bilder auswirken kann. Abbildung 7.4 veranschaulicht, wie zwei reale Bilder unterschiedlich stark vom Zuschneiden betroffen sind. Das linke Bild ist nahezu perfekt zugeschnitten, während das rechte Bild einen deutlichen Rand an der unteren Seite aufweist und zudem leicht rotiert erscheint. Diese leichte Rotation kann bereits dazu führen, dass eine durchgehende Kante als mehrere einzelne Kanten erkannt wird (siehe Abbildung 7.4c).

weitere Effekte der Kantenzahl

Die Analyse der Kantenzahl in Regenbildern und CAVOK Bildern zeigt, dass erstere durchschnittlich mehr Kanten aufweisen. Allerdings kann dies bei realen Bildern aufgrund der Verteilung im Datensatz auch zufällig sein, wie aus dem Diagramm zur Tageszeitabhängigkeit hervorgeht. Es ist daher wichtig, die Hough-Transformation in Zukunft mit verschiedenen Parametern zu testen, um auszuschließen, dass die gewählten Parameter Regeneffekte wie kleine Regentropfen zufällig ausblenden. Bei synthetischen Daten zeigt sich eindeutig, dass Regeneffekte die Kantenzahl signifikant erhöhen. Der Unterschied zu realen Bildern kann auf vielfältige Weise erklärt werden. Übergreifende Abhängigkeiten wie Wolken könnten die Detektion von Kanten durch Regentropfen beeinflussen. Zudem ist festzustellen, dass simulierte fallende Regentropfen teilweise auffälliger sind als reale fallende Regentropfen. (siehe Abbildung A.11 im Anhang).

Sowohl bei realen als auch bei synthetischen Bildern zeigt sich eine deutliche Tageszeitabhängigkeit in der Anzahl der Kanten. Bei realen Bildern nimmt die Anzahl der Kanten morgens und abends deutlich ab. Es ist naheliegend, dass die Kantendetektion bei zunehmend dunkleren Bildern schlechter wird. Die Tatsache, dass dennoch gleich viele Kantenpixel erkannt werden, könnte darauf hindeuten, dass bei dunkleren Bildern das Rauschen zunimmt und somit mehr Kantenpixel erkannt werden, die nicht als Kanten zugeordnet werden können. Dies muss jedoch in Zukunft genauer untersucht werden. Die Erklärung für die konstante Zunahme der erkannten Kanten bei simulierten Bildern im Laufe des Tages bleibt mit den vorliegenden Daten unklar.

Effekte spezieller Wetterbedingungen

Die Auswertung der speziellen Wetterbedingungen unterstützt die Beobachtung, dass Regentropfen auf der Linse die Detektion von Kanten beeinflussen. Obwohl durchschnittlich weniger Kantenpixel erkannt werden, ist die Anzahl der Kanten nicht auffällig gering. Dies könnte darauf hindeuten, dass Bereiche mit wenigen Kanten, die aus vielen Kantenpixeln bestehen, überdeckt werden, wodurch der Effekt bei den Kantenpixeln größer ist als bei der Kantenzahl.

Zusammenfassung

Die Untersuchung der Kanten zeigt, dass Regeneffekte einen signifikanten Einfluss haben können. Allerdings scheinen fallende Regentropfen einen geringeren Effekt zu haben. Statt-

dessen spielen Regentropfen auf der Linse und auf dem Kalibriermuster eine wichtigere Rolle. Darüber hinaus spielen weitere Umweltbedingungen wie Bewölkung oder Sonnenschein bei vorhandenen Tropfen eine wichtige Rolle. Weitere Phänomene, wie eine mögliche Tageszeitabhängigkeit, müssen näher untersucht werden. Dazu ist es wichtig, nicht nur die Datensätze zu erweitern, sondern auch verschiedene Einstellungen für den Canny-Algorithmus und die Hough-Transformation zu berücksichtigen. Zudem muss das Zuschneiden der Bilder in Zukunft überarbeitet werden, um zu verhindern, dass rotierte Bilder die Auswertung verfälschen.

7.2.2. Eckendetektion

Die Outlier der simulierten CAVOK Bilder zeigen, dass die Eckenerkennung mit den verwendeten Parametern eine hohe Sensibilität aufweist. Dies lässt darauf schließen, dass zukünftige Untersuchungen die Eckendetektion mit alternativen Einstellungen wiederholen sollten, um die Ergebnisse zu validieren.

Effekte der Eckendetektion

Die Standardabweichung der simulierten Datensätze ist deutlich geringer als die der realen Datensätze. Angesichts der Tatsache, dass die Eckendetektion auf kleine Schwankungen reagiert, deutet dies darauf hin, dass reale Bilder mehr - für Menschen nicht wahrnehmbares - Rauschen enthalten. Aufgrund der großen Streuung der Werte bei den realen Daten, insbesondere bei den Regenbildern, ist es schwierig, präzise Aussagen über die Durchschnittswerte zu treffen. Im Gegensatz dazu lässt sich bei den simulierten Daten eindeutig erkennen, dass Regenbilder mehr Ecken als CAVOK Bilder aufweisen, was auch durch die tageszeitabhängige Verteilung der Daten bestätigt wird. In der Simulation stammen diese zusätzlichen Ecken von den genannten Regeneffekten.

Darüber hinaus zeigt sich bei den simulierten Datensätzen eine deutliche Tageszeitabhängigkeit, wobei morgens und abends die Anzahl der erkannten Ecken abnimmt. Bei den realen Daten tritt der umgekehrte Effekt auf, was auf ein erhöhtes Rauschen in den Bildern zu diesen Tageszeiten hindeutet. Um diese Theorie zu überprüfen, könnte das mögliche Rauschen in den Bildern in zukünftigen Untersuchungen vor der Differenzanalyse durch einfache Filter unterdrückt werden.

Effekte bei speziellen Wetterbedingungen

Es ist auffällig, dass bei Regentropfen auf der Linse die Anzahl der Ecken eher zu- als abnimmt. Dies widerspricht der Beobachtung von Abbildung 6.9c. Eine nähere Betrachtung der betroffenen Bilder zeigt jedoch, dass die Regionen, die von den Tropfen auf der Linse betroffen sind, deutlich weniger Ecken aufweisen, während in anderen Bereichen deutlich mehr Ecken erkannt werden (siehe Abbildung A.12 im Anhang). Diese widersprüchliche Erkenntnis spricht eher dafür, dass Tropfen auf der Linse oft mit weiteren Effekten wie zusätzlichen Tropfen auf dem Kalibriermuster oder einem leichten Rauschen im Bild einhergehen.

Zusammenfassung

Es wird deutlich, dass die verwendeten Parameter nicht optimal für den gewünschten Zweck waren und weitere Untersuchungen mit alternativen Einstellungen für die Parameter der Shi-Tomasi Eckendetektion durchgeführt werden müssen.

7.2.3. Zusammenhang der Ergebnisse für Methoden der Low-Level Feature Analyse

Die Detektion von Kanten und Ecken wird durch Regeneffekte sowie weitere übergreifende Abhängigkeiten beeinflusst. Insbesondere Effekte, die Rauschen verursachen, haben eine starke Auswirkung. Dies sollte in weiteren Tests berücksichtigt werden.

Durch eine ungünstige Wahl an Parametereinstellungen konnte kein eindeutiger Bezug zwischen den Ergebnissen der Kanten- und Eckenerkennung hergestellt werden. Abbildung 6.9 zeigt jedoch, dass der Einfluss von Regeneffekten auf die Metriken ähnlich ist. Regentropfen auf der Linse verhindern sowohl eine erfolgreiche Kantendetektion als auch eine erfolgreiche Eckendetektion. Darüber hinaus werden sowohl Kanten als auch Ecken durch Regentropfen auf dunklen Flächen schlechter erkannt als auf hellen Regionen.

7.3. Pixel- und Wahrnehmungsähnlichkeit

Die Bilder werden in den zuvor betrachteten Kategorien einzeln ausgewertet. Diese Vorgehensweise ermöglicht den Vergleich der Eigenschaften zwischen den einzelnen Datensätzen. Die Methoden in dieser Kategorie erleichtern die Untersuchung der Unterschiede zwischen CAVOK- und Regenbildern.

7.3.1. NRMSE

Die Differenzanalyse weist auf folgende Besonderheiten hin: Reale Daten sind stark gestreut, während simulierte Bilder eine geringe Varianz aufweisen. Zudem ist keine Tageszeitabhängigkeit erkennbar, mit Ausnahme erhöhter NRMSE-Werte realer Daten zwischen 12 und 14 Uhr.

Effekte realer Bildpaare

Die breite Streuung der realen Daten deutet darauf hin, dass mehr Effekte als nur die betrachteten Regeneffekte eine Rolle spielen. Abbildungen 7.2a und 7.2b zeigen, dass reale Bilder selbst bei gleichen Wetterbedingungen und Aufnahmezeitpunkten stark voneinander abweichen können. Dies erklärt auch die weite Streuung der NRMSE-Werte realer Bilder. Zudem hat das Zuschneiden der Bilder einen großen Einfluss, da der NRMSE-Wert auf einem Pixel-zu-Pixel-Vergleich basiert und leichte Rotationen oder Verschiebungen der Bilder zu großen Fehlern führen können.

Effekte simulierter Bildpaare

Die NRMSE-Werte der synthetischen Bilder weisen eine sehr geringe Streuung auf. Dies deutet darauf hin, dass die Bilder sehr ähnlich sind und die beschriebenen Regeneffekte nur kleine Abweichungen verursachen. Dies spricht erneut dafür, dass die betrachteten Regeneffekte einen vergleichsweise geringen Einfluss haben und übergreifende Abhängigkeiten wie Wolken oder weitere Einflüsse wie die Eigenschaften der Kamera einen größeren Einfluss auf die realen Bilder haben.

Tageszeitabhängigkeit

Die fehlende Tageszeitabhängigkeit in den NRMSE-Werten der simulierten Bilder kann darauf zurückgeführt werden, dass die Bilder sich zu jeder Tageszeit sehr ähneln. Die große Streuung der realen Daten unabhängig von der Tageszeit zeigt, dass externe Effekte die Bilder zu jeder Tageszeit beeinflussen. Die Ursache für die besonders starken Unterschiede bei den Bildern zwischen 12 und 14 Uhr ist nicht ersichtlich und bedarf weiterer Untersuchung, um auszuschließen, dass dieser Effekt nur auf dem existierenden Datensatz basiert und nicht repräsentativ ist.

7.3.2. PSNR

Effekte simulierter Bildpaare

Im Gegensatz zu NRMSE verwendet PSNR eine logarithmische Skala. Diese Skalierung ermöglicht eine bessere Analyse der synthetischen Bildpaare mit geringen Abweichungen, da die Ergebnisse dadurch auseinandergezogen werden. Die vorliegenden Daten liefern jedoch keine neuen Erkenntnisse, da auch bei Verwendung von PSNR keine Tageszeitabhängigkeit oder andere interessante Effekte beobachtet werden können. In zukünftigen Analysen könnte es sinnvoll sein, bestimmte Regeneffekte wie Bilder mit Regentropfen auf dem Kalibriermuster hervorzuheben, um mögliche Auswirkungen auf den PSNR-Wert zu messen.

Effekte realer Bildpaare


Die PSNR-Verteilung der realen Daten zeigt eine starke Tendenz zu schlechten Ergebnissen und damit zu großen Unterschieden zwischen den Bildern eines Bildpaares. Der tageszeitabhängige Verlauf deutet darauf hin, dass die Ergebnisse morgens und abends etwas besser sind als zum Mittag und Nachmittag. Es ist jedoch zu beachten, dass diese Ergebnisse auch durch die Wahl der Bildpaare und somit durch Zufall zustande kommen können. Darüber hinaus ist zu beachten, dass auch PSNR eine Pixel-zu-Pixel-basierte Methode ist, bei der die Rotation der Bilder bereits große Fehler verursachen kann. Daher ist es wichtig, in zukünftigen Analysen ein genaues Zuschneiden der Bilder zu gewährleisten, um aussagekräftigere Ergebnisse zu erhalten.

7.3.3. SSIM


Die Histogramme für reale und simulierte Bilder zeigen deutliche Unterschiede. Bei realen Bildern ist eine breite Streuung erkennbar, während simulierten Bilder durch eine sehr geringe Varianz und nahezu perfekte SSIM-Werte gekennzeichnet sind.

Einfluss der Rotation von zugeschnittenen Bildern

Im Unterschied zu den NRMSE- und PSNR-Auswertungen bietet die SSIM-Analyse Einblicke in die Ursachen der Unterschiede zwischen realen und synthetischen Bildern. Abbildung 7.5 zeigt Beispiele für die SSIM-Analyse von realen und synthetischen Bildpaaren. Bei realen Bildern ist die Struktur des Kalibriermusters erkennbar, was auf die nicht identische Ausrichtung der Bilder zurückzuführen ist. Darüber hinaus ist Rauschen in vielen Bereichen erkennbar, das nicht immer durch Regentropfen auf dem Kalibriermuster erklärt werden kann.



(a) SSIM Differenzbild eines realen Bildpaares mit SSIM 0,88. (b) SSIM Differenzbild eines realen Bildpaares mit SSIM 0,67.



(c) SSIM Differenzbild eines simulierten Bildpaares mit SSIM 0,99. (d) SSIM Differenzbild eines simulierten Bildpaares mit SSIM 0,98.

Abbildung 7.5.: SSIM Differenzbilder für reale und simulierte Bildpaare. Bei den realen Bildpaaren ist ein deutlicher Einfluss der auftretenden Verschiebungen und Rotationen, sowie von Rauschen zu erkennen. Bei simulierten Bildpaaren sind hauptsächlich die Regeneffekte zu sehen.

Synthetische Bildpaare zeichnen sich durch eine kaum erkennbare Struktur des Kalibrierungsmusters aus, während die Regentropfen die einzigen starken Unterschiede bilden. Diese Bilder zeigen einerseits, dass Regentropfen die strukturelle Ähnlichkeit nur geringfügig beeinflussen. Andererseits wird gezeigt, wie Rauschen und kleine Rotationen in den Bildern die strukturelle Ähnlichkeit stark beeinflussen.

Tageszeitabhängigkeit

Aus dieser Erkenntnis folgt, dass die Schwankungen in der Tageszeitabhängigkeit für reale Bildpaare ohne weitere Untersuchung nicht aussagekräftig sind.

7.3.4. Zusammenhang der Ergebnisse für Methoden der Pixel- und Wahrnehmungsähnlichkeit

Die gewählten Methoden weisen eine enge Verwandtschaft auf. Sowohl NRMSE als auch PSNR basieren auf der Bestimmung des MSE-Wertes, was zu ähnlichen Ergebnissen führt.

Dennoch kann es von Vorteil sein, beide Methoden weiterhin zu berücksichtigen, da NRMSE aufgrund seiner linearen Skala eine bessere Interpretierbarkeit bietet und PSNR eine gezieltere Auswertung kleiner Fehler ermöglicht. Im Gegensatz dazu misst SSIM keine absoluten Fehler, sondern dient als Maß für die wahrgenommene strukturelle Ähnlichkeit. Ein Nachteil von SSIM besteht darin, dass die Ergebnisse ohne die Erzeugung von Differenzbildern noch schwieriger zu interpretieren sind als die Ergebnisse von NRMSE und PSNR. Gleichzeitig könnte SSIM jedoch eine wichtige Metrik sein, um dem Ziel des Fotorealismus näher zu kommen.

Da viele reale Bilder, die zu ähnlichen Zeitpunkten aufgenommen wurden, unterschiedlich aussehen, sollten die Bildpaare erneut überarbeitet werden, da möglicherweise ungünstige Bildpaare gewählt wurden. Besonders wichtig ist die sorgfältige Ausrichtung des Kalibrierungsmusters in den Bildern, da bereits kleine Verschiebungen oder Rotationen zu erheblichen Fehlern führen können. Für weitere Aufnahmen zur Ergänzung des Datensatzes sollte daher besonderes Augenmerk auf die Minimierung mechanischer Einflüsse auf die Kamera gelegt werden.

7.4. Klassifikator- und Anwendungsbasiert

Obwohl die Datensätze klein sind, liefert die Differenzanalyse auf der Grundlage von Methoden dieser Kategorie interessante Erkenntnisse über die Datensätze und deren Einsatz in DL-Methoden. Aufgrund des Blackbox-Problems bei solchen Methoden lässt sich die genaue Ursache für Klassifizierungsentscheidungen nicht bestimmen. Dennoch können anhand der Beobachtungen und Vergleiche allgemeine Aussagen formuliert werden, die als Basis für weitere Forschung unter Verwendung von XAI-Methoden dienen können.

7.4.1. Cross-Dataset Generalisierung

Die Cross-Dataset Generalisierung ist genau dann effektiv, wenn Modelle auf einem Datensatz trainiert werden und anschließend ohne weitere Anpassung auch auf einem anderen Datensatz erfolgreich eingesetzt werden können. Dies deutet darauf hin, dass die Datensätze ausreichende Ähnlichkeiten aufweisen.

Auswertung auf zugeschnittenen Bildern

Die Ergebnisse der Differenzanalyse zeigen, dass die Cross-Dataset-Generalisierung für Datensätze mit zugeschnittenen Bildern nur gering ist. Keines der trainierten Modelle zeigt auf dem jeweils anderen Datensatz eine gute Leistung. Stattdessen bevorzugen alle Modelle die Klasse CAVOK. Dieses Ergebnis deutet darauf hin, dass die Unterschiede zwischen den realen und synthetischen Datensätzen zu groß sind oder die Unterschiede zwischen CAVOK- und Regenbildern in diesen Datensätzen zu gering sind, um diese zuverlässig zu erkennen.

Ein Vergleich der Genauigkeit der Ergebnisse aller Modelle, die auf dem Datensatz ausgewertet werden, auf dem sie trainiert wurden, zeigt, dass Modelle, die auf realen Daten trainiert wurden, eine bessere Leistung zeigen. Daraus kann geschlossen werden, dass die realen Daten eine größere Anzahl an Merkmalen aufweisen als die synthetischen Daten. Dieses Ergebnis stimmt mit den Ergebnissen der zuvor ausgewerteten Metriken überein. Abbildung 7.3b zeigt ein Beispiel für ein simuliertes Regenbild, das keinen Regeneffekt zeigt und auch für Menschen nicht von einem simulierten CAVOK-Bild zu unterscheiden ist. Diese Erkenntnis unterstreicht

die Notwendigkeit, die Simulation in Zukunft um übergreifende Abhängigkeiten zu erweitern, um eine größere Variabilität in den Bildern zu erzeugen und somit mehr Merkmale für die Klassifizierung bereitzustellen. Um zu verstehen, welche Merkmale der realen Daten für die Klassifizierung besonders wichtig sind, sind weitere Experimente erforderlich.

Auswertung auf originalen, nicht zugeschnittenen Bildern

Die Cross-Dataset-Generalisierung für die originalen, nicht zugeschnittenen Bilder zeigt eine bessere Leistung als bei den zugeschnittenen Bildern. Dies gilt insbesondere für die Generalisierung von realen auf synthetische Daten. Obwohl die Klasse Regen bevorzugt wird, erkennen alle Modelle auch einige CAVOK-Bilder korrekt. Im Gegensatz dazu wird bei der Generalisierung von synthetischen auf reale Daten eine Klasse (hier Regen) deutlich bevorzugt, ähnlich wie bei den zugeschnittenen Bildern. Diese Ergebnisse bestätigen die oben beschriebenen Beobachtungen, dass die Unterschiede zwischen den realen und synthetischen Daten noch zu groß sind.

Es ist bemerkenswert, dass Modelle, die auf realen Daten trainiert wurden, besser auf synthetische Daten generalisieren können als umgekehrt. Dieser Effekt sollte in Zukunft näher untersucht werden, um die Ursache zu finden.

Die Auswertung zeigt außerdem, dass bei der Verwendung der ganzen Bilder die Genauigkeit bei der Auswertung der Sim-Modelle auf simulierten Daten sehr hoch ist, mit 96,67% bis 98,33%. Dies deutet darauf hin, dass entweder Overfitting aufgetreten ist, sodass die Modelle die wenigen vorhandenen Trainingsbilder auswendig gelernt haben, oder dass eindeutige Merkmale gefunden wurden, die jedoch nicht in gleicher Art bei den realen Bildern zu finden sind. Um dies genauer bestimmen zu können, könnten in Zukunft Ansätze aus dem XAI-Bereich hilfreich sein.

Zusätzlich kann beobachtet werden, dass die drei Varianten zum Umgang mit einer ungleichen Anzahl an Bildern für die verschiedenen Klassen kaum eine Auswirkung haben.

Zusammenfassung

Aus der Analyse der Cross-Dataset-Generalisierung lassen sich folgende Schlussfolgerungen ziehen: Es ist möglich, Klassifizierer zu trainieren, die zwischen CAVOK und Regen bei realen Bildern unterscheiden können. Dies gilt auch für zugeschnittene Bilder. Simulierte Bilder können nur dann zuverlässig klassifiziert werden, wenn die gesamten Bilder mit Hintergrund verwendet werden, was darauf hindeutet, dass zugeschnittene simulierte Bilder eine begrenzte Anzahl an aussagekräftigen Merkmalen aufweisen. Zudem zeigt sich, dass die Unterschiede zwischen realen und simulierten Bildern noch zu groß sind, um synthetische Bilder allein als Trainingsbasis für DL-Modelle zu verwenden.

7.4.2. Real/Synthetisch Klassifizierer

Die Ergebnisse der Differenzanalyse zeigen, dass Klassifizierer ohne Schwierigkeiten zwischen realen und synthetischen Daten unterscheiden können. Alle Modelle - unabhängig davon, ob sie auf zugeschnittenen oder originalen Daten trainiert wurden - ordnen diese Kategorien fehlerfrei zu.

Auswertung auf zugeschnittenen Bildern

Bei den zugeschnittenen Bildern weisen die Modelle eine hohe Treffsicherheit bei der Unterscheidung zwischen realen CAVOK- und Regenbildern auf. Dies lässt darauf schließen, dass entweder Overfitting auftritt oder die Daten eindeutige Merkmale aufweisen, mit denen zwischen CAVOK und Regen unterschieden werden kann. Im Gegensatz dazu bevorzugen die Modelle bei den synthetischen Daten die Klasse CAVOK und ordnen nur wenige Regenbilder korrekt zu. Dies deutet darauf hin, dass die Modelle keine Merkmale finden konnten, die Regen und CAVOK unterscheiden.

Auswertung auf originalen, nicht zugeschnittenen Bildern

Bei den originalen Bildern zeigt sich ein anderes Bild. Modelle, die auf diesen Bildern trainiert und ausgewertet werden, weisen eine hohe Genauigkeit auf. Die Ergänzung des Hintergrundes bietet zusätzliche Merkmale, die für eine korrekte Klassifizierung notwendig sind. Es ist möglich, dass ein größeres Bild die Chance erhöht, Merkmale wie Regentropfen zu identifizieren. Beispielbilder für den Effekt des Hintergrundes auf zusätzliche Merkmale sind in Abbildung A.11 im Anhang dargestellt.

Zusammenfassung

Obwohl die kleinen Datensätze die Gefahr von Overfitting erhöhen, zeigen die Ergebnisse deutlich, dass die Unterschiede zwischen realen und synthetischen Bildern noch sehr groß sind und die Simulation überarbeitet werden muss. Es ist möglich, dass Explainable Artificial Intelligence (XAI) dabei helfen kann, welche Merkmale für die deutliche Trennung von realen und synthetischen Daten entscheidend sind.

7.4.3. Zusammenhang der Ergebnisse für klassifikator- und anwendungsbasierte Methoden

Die beiden in dieser Kategorie angewendeten Methoden liefern konsistente Ergebnisse. Reale Bilder können von Klassifizierern einfacher in CAVOK und Regen klassifiziert werden. Dies kann auf die besseren Merkmale in den Bildern zurückzuführen sein. Synthetische Bilder sind schwieriger zu klassifizieren, können jedoch leicht von realen Bildern unterschieden werden. Für zukünftige Tests werden größere Datensätze benötigt, um das Risiko von Overfitting während des Trainings weiter zu reduzieren.

7.5. Limitationen der Differenzanalyse

Die Differenzanalyse umfasst die Bewertung und Darstellung verschiedener Metriken. Untersucht wird, wie bestimmte Metriken innerhalb einer Kategorie miteinander korrelieren. Zur genaueren Bestimmung der Korrelationen zwischen allen Metriken und ihrer qualitativen Bewertung sind jedoch weitere Forschungen erforderlich.

Die meisten Metriken werden anhand von Graustufenbildern ausgewertet, obwohl Farbunterschiede zwischen realen und synthetischen Bildern bei der manuellen Analyse der Datensätze deutlich werden. Diese Aspekte sollten in zukünftigen Analysen berücksichtigt werden.

Das Kalibriermuster ist in mehrere Bereiche unterteilt, die lokale Bewertungen ermöglichen. Die vorliegende Differenzanalyse konzentriert sich jedoch auf das gesamte Kalibriermuster, da die verfügbaren Daten für die Bewertung der einzelnen Bereiche nicht ausreichen.

Die durchgeführte Differenzanalyse gibt einen Überblick über mögliche Effekte. Allerdings können nicht alle beobachteten Effekte auf der Grundlage der verfügbaren Daten erklärt werden. Daher sind angepasste Experimente für verlässliche Aussagen erforderlich.

Kapitel 8.

Zusammenfassung & Ausblick

Zu Beginn dieser Arbeit werden die Hauptbeiträge dieser Arbeit aufgelistet. Dazu gehören die Erzeugung geeigneter Datensätze mit einem minimalen Setup, um wetterunabhängige Einflüsse zu minimieren, die Regensimulation und die Differenzanalyse der erzeugten Datensätze. Im Folgenden werden diese Beiträge detaillierter beschrieben. Die wichtigsten Ergebnisse der Differenzanalyse werden dabei in einer Zusammenfassung präsentiert, um einen schnellen Überblick zu ermöglichen. Darauf folgt ein Ausblick, der mögliche zukünftige Forschungsansätze beschreibt.

8.1. Beitrag der Arbeit

Datensätze

Im Rahmen dieser Arbeit wird ein Versuchsaufbau entwickelt, der einen Datensatz mit minimierten wetterunabhängigen Einflüssen erzeugt. Der Versuchsaufbau ermöglicht die automatische Aufnahme zahlreicher Wetterphänomene und bietet die Möglichkeit, für andere Untersuchungen modifiziert zu werden. Ein Vorteil dieses Versuchsaufbaus besteht darin, dass er mit hoher Genauigkeit in einer Simulation nachgebildet werden kann. Mit Hilfe dieses Versuchsaufbaus werden innerhalb von sieben Wochen fast 10.000 Bilder generiert.

Es wird exemplarisch gezeigt, wie dieser Datensatz nach verschiedenen Kriterien gefiltert werden kann, um für weitere Forschung relevante Subdatensätze zu erhalten. In dieser Arbeit werden jeweils ein Datensatz für CAVOK-Bilder und für Regenbilder erstellt und in der Differenzanalyse verwendet. Entsprechend diesen Datensätzen werden synthetische Datensätze generiert.

Alle genannten Datensätze stehen derzeit DLR-intern für weitere Forschungszwecke zur Verfügung.

Regensimulation

Innerhalb der Unreal Engine wird Regen typischerweise mithilfe von Partikeleffekten simuliert. Entsprechend basiert auch die Regensimulation in dieser Arbeit auf Partikeleffekten. Es wird eine Lösung entwickelt, die Größe der Partikel und deren Anzahl an den gewünschten Regentyp und die Regenintensität anzupassen. Darüber hinaus wird ein System erstellt, um Regentropfen auf Objekten zu simulieren, ohne dass Texturen erforderlich sind. Somit ermöglicht die Simulation die Nachbildung von fallenden Regentropfen und Regentropfen auf Objekten. Die Nachbildung von Regentropfen auf der Linse ist bisher nicht erfolgreich. Weitere Effekte von

Regen, wie beispielsweise Pfützen, werden bisher nicht umgesetzt, da sie in dieser Arbeit nicht betrachtet werden. Trotz der Einschränkungen der vorgestellten Regensimulation zeigt diese, dass auch mit Partikeleffekten reale Eigenschaften von Regen berücksichtigt werden können und gleichzeitig Echtzeitfähigkeit erreicht werden kann.

Differenzanalyse

Für eine umfassende Differenzanalyse werden 10 Methoden und insgesamt 12 Metriken ausgewählt, die ein breites Spektrum von Differenzanalysemethoden abdecken. Diese reichen von strukturunabhängigen Bildmerkmalen wie Helligkeit oder Kontrast bis hin zu Klassifizierern. Für die Analyse werden jeweils 429 reale und simulierte CAVOK-Bilder sowie jeweils 166 reale und simulierte Regenbilder verwendet. Somit werden sowohl reale CAVOK- und Regenbilder untereinander verglichen als auch die simulierten Bilder mit den realen. Es wird ein umfassender Überblick geschaffen, wie sich die Simulation verhalten sollte und wie die Effekte bisher tatsächlich abgebildet werden. Die wichtigsten Ergebnisse sind in den Tabellen A.11, A.12, A.13 und A.14 im Anhang dargestellt.

Mehrere Metriken weisen auf einige gemeinsame Schlussfolgerungen hin. So ist es wiederholt auffällig, dass Regendaten aus den frühen Morgenstunden fehlen, was die Notwendigkeit eines noch größeren und umfangreicheren Datensatzes für reale Daten unterstreicht. Darüber hinaus wird deutlich, dass Regen neben den betrachteten Effekten auch mit anderen Effekten wie Bewölkung einhergeht, die sich ebenfalls auf die Bilder auswirken. Die Ergebnisse zeigen generell, dass es zwischen den verschiedenen Wettereffekten viele übergreifende Abhängigkeiten gibt, die nach einer umfassenden Simulation verlangen und die Bedeutung umfassender Differenzanalysen unterstreichen.

Neben den Wettereffekten haben auch andere Faktoren Einfluss auf die Bilder. So sind die realen Bilder auch von anderen, bisher nicht genauer identifizierten Faktoren abhängig. Dies zeigt sich bei realen Bildern, die trotz gleicher Wetterbedingungen sich nicht immer ähnlich sehen. Schwankungen in der Auswertung der realen Bilder sind die Folge. Simulierte Bilder weisen diese Schwankungen nicht auf.

Weiterhin zeigen einige Methoden, dass die korrekte Ausrichtung der Bilder für eine erfolgreiche Differenzanalyse entscheidend sein kann. Besonders die Low-Level-Feature-Analyse-Methoden und die Methoden aus der Kategorie Pixel- und Wahrnehmungsähnlichkeit werden von leicht rotierten oder falsch zugeschnittenen Bildern negativ beeinflusst.

Insgesamt zeigt die Differenzanalyse, dass die vorgestellte Simulation an vielen Punkten überarbeitet werden muss, bevor sie als phänomenologisch korrekt angesehen werden kann. Gleichzeitig bewährt sich die Differenzanalyse, um zu identifizieren, was an der Simulation verbessert werden muss. Die Ergebnisse untermauern die Notwendigkeit von umfangreichen Differenzanalysen zum Nachweis phänomenologischer Korrektheit.

8.2. Ausblick

Die Umweltwahrnehmung unter schlechten Wetterbedingungen ist ein fortdauerndes Forschungsgebiet. Diese Arbeit leistet einen Beitrag zur Vergleichbarkeit von Effekten von simuliertem Wetter mit realen Wettereffekten. Es zeigen sich jedoch in den verschiedenen Abschnitten

dieser Arbeit unterschiedliche Limitationen. In zukünftigen Forschungsarbeiten sollte eine eingehendere Untersuchung dieser Limitationen erfolgen.

Beim realen Versuchsaufbau ist die Entfernung zwischen der Kamera und dem Kalibriermuster auf 2,5 m beschränkt. Durch die gezielte Auswahl anderer Kameras, Objektive oder durch die Anpassung der Kalibriermustergröße könnte dieser Abstand erweitert werden, um den Einfluss von Wettereffekten auf die Bilder stärker zu erfassen. Darüber hinaus ist es notwendig, eine Lösung für die mit dem Kamerasetup verbundenen Probleme zu finden, damit die Kamera über einen längeren Zeitraum ohne Überwachung Aufnahmen machen kann. Es wäre auch möglich, den Versuchsaufbau für weitere Anwendungsfälle anzupassen, um Effekte wie Pfützen aufzunehmen. Für die Untersuchung weiterer Wetterphänomene wie Schnee wäre es zweckmäßig, den Versuchsaufbau über das gesamte Jahr zu nutzen. Allgemein wäre es ratsam, weitere Bilder zu erstellen, um den bestehenden Datensatz zu ergänzen und detailliertere Untersuchungen der Wettereffekte zu ermöglichen.

In der Simulation ist eine Überarbeitung der Berechnung des Sonnenstandes und des Umgebungslichtes erforderlich. Ebenso sollte die vorgestellte Regensimulation auf Basis der Ergebnisse der Differenzanalyse angepasst werden. Für eine genauere Spezifizierung der notwendigen Anpassungen ist eine eingehende und gezielte Untersuchung der in der Differenzanalyse beobachteten Effekte erforderlich.

Das beschriebene Setup ermöglicht die Entwicklung einer Pipeline zur Untersuchung der phänomenologischen Korrektheit neuer Wettersimulationen. Durch die Erstellung einer ausreichenden Anzahl realer Bilder verschiedener Wetterphänomene kann die Pipeline in Zukunft weitestgehend automatisiert werden. Es sollte untersucht werden, ob die bereits genutzten Methoden für eine solche automatische Pipeline geeignet sind und ob weitere Methoden existieren, die für diesen Zweck geeignet sein könnten. Es wäre sinnvoll, Methoden zu nutzen, die die einzelnen Bereiche des Kalibrierusters für die Auswertung berücksichtigen. Darüber hinaus spielen Farbveränderungen, wie beschrieben, eine Rolle und sollten ebenfalls berücksichtigt werden. Des Weiteren sollte die Korrelation zwischen den vorgestellten Differenzanalysemethoden untersucht werden, um eine aussagekräftige Differenzanalyse zu ermöglichen.

Literaturverzeichnis

- [1] “Wetter und Klima - Deutscher Wetterdienst - Glossar - N - Niederschlagsintensität.” (Cited on pages IX and 15)
- [2] Y. Zhang, A. Carballo, H. Yang, and K. Takeda, “Perception and sensing for autonomous vehicles under adverse weather conditions: A survey,” *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 196, pp. 146–177, Feb. 2023. (Cited on pages 1, 2, 4, and 12)
- [3] D. Liu, Y. Cui, Z. Cao, and Y. Chen, “A Large-scale Simulation Dataset: Boost the Detection Accuracy for Special Weather Conditions,” in *2020 International Joint Conference on Neural Networks (IJCNN)*, (Glasgow, United Kingdom), pp. 1–8, IEEE, July 2020. (Cited on pages 2, 4, and 5)
- [4] M. Tremblay, S. S. Halder, R. de Charette, and J.-F. Lalonde, “Rain Rendering for Evaluating and Improving Robustness to Bad Weather,” *International Journal of Computer Vision*, vol. 129, pp. 341–360, Feb. 2021. (Cited on pages 2, 4, and 5)
- [5] D. Yang, Z. Liu, W. Jiang, G. Yan, X. Gao, B. Shi, S. Liu, and X. Cai, “Realistic Rainy Weather Simulation for LiDARs in CARLA Simulator,” Dec. 2023. arXiv:2312.12772 [cs] version: 1. (Cited on pages 2, 4, and 5)
- [6] S. S. Halder, J.-F. Lalonde, and R. d. Charette, “Physics-Based Rendering for Improving Robustness to Rain,” Aug. 2019. arXiv:1908.10335 [cs]. (Cited on pages 4 and 5)
- [7] A. Marchisio, G. Caramia, M. Martina, and M. Shafique, “fakeWeather: Adversarial Attacks for Deep Neural Networks Emulating Weather Conditions on the Camera Lens of Autonomous Systems,” May 2022. arXiv:2205.13807 [cs]. (Cited on page 4)
- [8] X. Zhong, S. Tu, X. Ma, K. Jiang, W. Huang, and Z. Wang, “Rainy WCity: A Real Rainfall Dataset with Diverse Conditions for Semantic Driving Scene Understanding,” in *Proceedings of the Thirty-First International Joint Conference on Artificial Intelligence*, (Vienna, Austria), pp. 1743–1749, International Joint Conferences on Artificial Intelligence Organization, July 2022. (Cited on page 5)
- [9] M. Bijelic, T. Gruber, F. Mannan, F. Kraus, W. Ritter, K. Dietmayer, and F. Heide, “Seeing Through Fog Without Seeing Fog: Deep Multimodal Sensor Fusion in Unseen Adverse Weather,” in *2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, (Seattle, WA, USA), pp. 11679–11689, IEEE, June 2020. (Cited on page 5)
- [10] Z.-X. Feng, M. Tang, J.-X. Dong, and S.-C. Chou, “Real-Time Rain Simulation,” in *Computer Supported Cooperative Work in Design II*, Springer Berlin Heidelberg. (Cited on page 5)
- [11] W. Changbo, Z. Wang, X. Zhang, L. Huang, Z. Yang, and Q. Peng, “Real-time modeling and rendering of raining scenes,” *The Visual Computer*, vol. 24, pp. 605–616, July 2008. (Cited on page 5)
- [12] “Blade Runner 2049: going deep with DNEG – vfxblog.” (Cited on page 5)

- [13] P. Bauer, A. Thorpe, and G. Brunet, “The quiet revolution of numerical weather prediction,” *Nature*, vol. 525, pp. 47–55, Sept. 2015. Publisher: Nature Publishing Group. (Cited on pages 5 and 47)
- [14] C. A. Dimmig, G. Silano, K. McGuire, C. Gabellieri, W. Hönig, J. Moore, and M. Kobilarov, “Survey of Simulators for Aerial Robots: An Overview and In-Depth Systematic Comparisons [Survey],” *IEEE Robotics & Automation Magazine*, vol. 32, pp. 153–166, June 2025. (Cited on page 6)
- [15] S. Shah, D. Dey, C. Lovett, and A. Kapoor, “AirSim: High-Fidelity Visual and Physical Simulation for Autonomous Vehicles,” July 2017. arXiv:1705.05065 [cs]. (Cited on page 6)
- [16] “Flight Simulator | X-Plane 12: Flight Simulation Done Right.” (Cited on page 6)
- [17] “Das leistungsstärkste Werkzeug für 3D-Echtzeit-Entwicklung.” (Cited on page 6)
- [18] A. McNamara, A. Chalmers, T. Troscianko, and I. Gilchrist, “Comparing Real & Synthetic Scenes using Human Judgements of Lightness,” in *Rendering Techniques 2000* (B. Péroche and H. Rushmeier, eds.), (Vienna), pp. 207–218, Springer, 2000. (Cited on pages 6 and 8)
- [19] H. Rushmeier, G. Ward, C. Piatko, P. Sanders, and B. Rust, “Comparing Real and Synthetic Images: Some Ideas About Metrics,” in *Rendering Techniques '95* (P. M. Hanrahan and W. Purgathofer, eds.), (Vienna), pp. 82–91, Springer, 1995. (Cited on page 6)
- [20] M. Heusel, H. Ramsauer, T. Unterthiner, B. Nessler, and S. Hochreiter, “GANs Trained by a Two Time-Scale Update Rule Converge to a Local Nash Equilibrium,” in *Advances in Neural Information Processing Systems*, vol. 30, Curran Associates, Inc., 2017. (Cited on pages 7, 11, and 23)
- [21] J. Rüter, T. Maienschein, S. Schirmer, S. Schopferer, and C. Torens, “Filling the Gaps: Using Synthetic Low-Altitude Aerial Images to Increase Operational Design Domain Coverage,” *Sensors*, vol. 24, p. 1144, Feb. 2024. (Cited on page 7)
- [22] A. Torralba and A. A. Efros, “Unbiased look at dataset bias,” in *CVPR 2011*, pp. 1521–1528, June 2011. ISSN: 1063-6919. (Cited on pages 7 and 13)
- [23] Z. You, X. Zhang, H. Guo, J. Wang, and C. Li, “Are Images Indistinguishable to Humans Also Indistinguishable to Classifiers?,” (Cited on pages 7 and 13)
- [24] J. J. Bird and A. Lotfi, “CIFAKE: Image Classification and Explainable Identification of AI-Generated Synthetic Images,” Mar. 2023. arXiv:2303.14126 [cs]. (Cited on page 7)
- [25] M. Grapinet, P. De Souza, J.-C. Smal, and J.-M. Blosseville, “Characterization and Simulation of Optical Sensors,” *Procedia - Social and Behavioral Sciences*, vol. 48, pp. 962–971, 2012. (Cited on page 7)
- [26] C. Avatavului and M. Prodan, “EVALUATING IMAGE CONTRAST: A COMPREHENSIVE REVIEW AND COMPARISON OF METRICS,” *Journal of Information Systems*, vol. 17, 2023. (Cited on pages 8 and 18)
- [27] R. A. Pagaduan, M. C. R. Aragon, and R. P. Medina, “iBlurDetect: Image Blur Detection Techniques Assessment and Evaluation Study,” in *Proceedings of the International Conference on Culture Heritage, Education, Sustainable Tourism, and Innovation Technologies*, (Medan, Indonesia), pp. 286–291, SCITEPRESS - Science and Technology Publications, 2020. (Cited on page 8)

- [28] P. Rajput, S. Kumari, S. Arya, and P. Lehana, “Effect of Contrast and Brightness on Digital Images under Outdoor Conditions,” *Advances in Research*, pp. 266–278, Mar. 2014. (Cited on page 8)
- [29] N. Hartmann, J. Rüter, and F. Jünger, “Ensuring Safety of Deep Learning Components Using Improved Image-Level Property Selection for Monitoring,” in *AIAA SCITECH 2025 Forum*, AIAA SciTech Forum, American Institute of Aeronautics and Astronautics, Jan. 2025. (Cited on page 8)
- [30] J. Canny, “A Computational Approach to Edge Detection,” (Cited on pages 8, 12, and 20)
- [31] I. Sobel, “An Isotropic 3x3 Image Gradient Operator,” *Presentation at Stanford A.I. Project 1968*, Feb. 2014. (Cited on page 8)
- [32] D. Marr and E. Hildreth, “Theory of Edge Detection,” *Proceedings of the Royal Society of London. Series B, Containing papers of a Biological character. Royal Society (Great Britain)*, vol. 207, pp. 187–217, Feb. 1980. (Cited on page 8)
- [33] C. Harris and M. Stephens, “A Combined Corner and Edge Detector,” in *Proceedings of the Alvey Vision Conference 1988*, (Manchester), pp. 23.1–23.6, Alvey Vision Club, 1988. (Cited on page 8)
- [34] E. Rosten and T. Drummond, “Machine Learning for High-Speed Corner Detection,” in *Computer Vision – ECCV 2006* (A. Leonardis, H. Bischof, and A. Pinz, eds.), (Berlin, Heidelberg), pp. 430–443, Springer, 2006. (Cited on page 8)
- [35] D. Gabor, “THEORY OF COMMUNICATION,” (Cited on page 8)
- [36] P. S. Cooper, E. Colton, S. Bode, and T. T.-J. Chong, “Standardised images of novel objects created with generative adversarial networks,” *Scientific Data*, vol. 10, p. 575, Sept. 2023. Publisher: Nature Publishing Group. (Cited on page 8)
- [37] Zhou Wang and A. Bovik, “Mean squared error: Love it or leave it? A new look at Signal Fidelity Measures,” *IEEE Signal Processing Magazine*, vol. 26, pp. 98–117, Jan. 2009. (Cited on pages 8, 11, 16, and 21)
- [38] Z. Wang, A. Bovik, H. Sheikh, and E. Simoncelli, “Image quality assessment: from error visibility to structural similarity,” *IEEE Transactions on Image Processing*, vol. 13, pp. 600–612, Apr. 2004. (Cited on pages 8, 11, 21, and 22)
- [39] P. Kapoor, P. Agrawal, Z. Ahmad, and Narayanamoorthi, *Duplicate Image Detection and Comparison using Single Core, Multiprocessing, and Multithreading*. July 2021. (Cited on page 8)
- [40] U. Sara, M. Akter, and M. S. Uddin, “Image Quality Assessment through FSIM, SSIM, MSE and PSNR—A Comparative Study,” *Journal of Computer and Communications*, vol. 7, pp. 8–18, Mar. 2019. Publisher: Scientific Research Publishing. (Cited on page 8)
- [41] M. Bińkowski, D. J. Sutherland, M. Arbel, and A. Gretton, “Demystifying MMD GANs,” Jan. 2021. arXiv:1801.01401 [stat]. (Cited on page 10)
- [42] F. A. Fardo, V. H. Conforto, F. C. d. Oliveira, and P. S. Rodrigues, “A Formal Evaluation of PSNR as Quality Measurement Parameter for Image Segmentation Algorithms,” May 2016. arXiv:1605.07116 [cs]. (Cited on page 11)

- [43] K. Garg and S. Nayar, “When does a camera see rain?,” in *Tenth IEEE International Conference on Computer Vision (ICCV’05) Volume 1*, vol. 2, pp. 1067–1074 Vol. 2, Oct. 2005. ISSN: 2380-7504. (Cited on pages 11, 15, 25, and 38)
- [44] H. Kim, Y. Yang, Y. Kim, D.-W. Jang, D. Choi, K. Park, S. Chung, and D. Kim, “Effect of Droplet Contamination on Camera Lens Surfaces: Degradation of Image Quality and Object Detection Performance,” *Applied Sciences*, vol. 15, p. 2690, Jan. 2025. Publisher: Multidisciplinary Digital Publishing Institute. (Cited on pages 11 and 16)
- [45] J. Shi and Tomasi, “Good features to track,” in *1994 Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, pp. 593–600, June 1994. ISSN: 1063-6919. (Cited on pages 12, 20, and 21)
- [46] “Wetter und Klima - Deutscher Wetterdienst - Glossar - R - Regen.” (Cited on pages 14 and 15)
- [47] R. Gunn and G. D. Kinzer, “THE TERMINAL VELOCITY OF FALL FOR WATER DROPLETS IN STAGNANT AIR,” Aug. 1949. Section: Journal of the Atmospheric Sciences. (Cited on pages 14 and 15)
- [48] K. V. Beard and C. Chuang, “A New Model for the Equilibrium Shape of Raindrops,” June 1987. Section: Journal of the Atmospheric Sciences. (Cited on page 14)
- [49] D. C. Blanchard and A. T. Spencer, “Experiments on the Generation of Raindrop-Size Distributions by Drop Breakup,” Jan. 1970. Section: Journal of the Atmospheric Sciences. (Cited on page 15)
- [50] “Wetter und Klima - Deutscher Wetterdienst - Glossar - N - Niederschlagshöhe.” (Cited on page 15)
- [51] X. Han, C. Nguyen, S. You, and J. Lu, “Single Image Water Hazard Detection using FCN with Reflection Attention Units,” pp. 105–120, 2018. (Cited on page 16)
- [52] A. Von Bernuth, G. Volk, and O. Bringmann, “Augmenting Image Data Sets With Water Spray Caused by Vehicles on Wet Roads,” in *2021 IEEE International Intelligent Transportation Systems Conference (ITSC)*, (Indianapolis, IN, USA), pp. 3055–3060, IEEE, Sept. 2021. (Cited on page 16)
- [53] J. Romero, J. Hernández-Andrés, J. L. Nieves, and J. A. García, “Color coordinates of objects with daylight changes,” *Color Research & Application*, vol. 28, pp. 25–35, Feb. 2003. (Cited on page 16)
- [54] L. Guo, C. Wang, Y. Wang, S. Huang, W. Yang, A. C. Kot, and B. Wen, “Single-Image Shadow Removal Using Deep Learning: A Comprehensive Survey,” July 2024. arXiv:2407.08865 [cs] version: 1. (Cited on page 16)
- [55] Y. Kotp and M. Torki, “Toward Flare-Free Images: A Survey,” Oct. 2023. arXiv:2310.14354 [eess]. (Cited on page 16)
- [56] “Unreal Engine 5.3 is now available—find out what’s new!.” (Cited on page 17)
- [57] “Learn About Epic Games.” (Cited on page 17)
- [58] “Introduction to Blueprints Visual Scripting in Unreal Engine | Unreal Engine 5.6 Documentation | Epic Developer Community.” (Cited on page 17)

- [59] “Fab, Epic’s New Unified Content Marketplace, Launches Today!” (Cited on page 17)
- [60] “Overview of Niagara Effects for Unreal Engine | Unreal Engine 5.6 Documentation | Epic Developer Community.” (Cited on page 17)
- [61] “Create Rain in Unreal Engine 5 with Niagara - Quick and Easy Tutorial | Community tutorial,” Nov. 2024. (Cited on page 17)
- [62] “Sun and Sky Actor in Unreal Engine | Unreal Engine 5.6 Documentation | Epic Developer Community.” (Cited on pages 17 and 33)
- [63] “FPostProcessSettings | Unreal Engine 5.6 Documentation | Epic Developer Community.” (Cited on pages 17 and 33)
- [64] “Lumen Global Illumination and Reflections in Unreal Engine | Unreal Engine 5.6 Documentation | Epic Developer Community.” (Cited on page 18)
- [65] S. Bezryadin, P. Bourov, and D. Ilinih, “Brightness Calculation in Digital Image Processing,” *International Symposium on Technologies for Digital Photo Fulfillment*, vol. 2007, pp. 10–15, Jan. 2007. (Cited on page 18)
- [66] S. Ploumis, R. Boitard, and P. Nasiopoulos, “Image Brightness Quantification for HDR,” in *2020 28th European Signal Processing Conference (EUSIPCO)*, (Amsterdam, Netherlands), pp. 640–644, IEEE, Jan. 2021. (Cited on page 18)
- [67] E. Peli, “Contrast in complex images,” (Cited on page 19)
- [68] K. Bahrami and A. C. Kot, “A Fast Approach for No-Reference Image Sharpness Assessment Based on Maximum Local Variation,” *IEEE Signal Processing Letters*, vol. 21, pp. 751–755, June 2014. (Cited on page 19)
- [69] S. Pertuz, D. Puig, and M. García, “Analysis of focus measure operators in shape-from-focus,” *Pattern Recognition*, vol. 46, Nov. 2012. (Cited on page 19)
- [70] R. O. Duda and P. E. Hart, “Use of the Hough transformation to detect lines and curves in pictures,” *Communications of the ACM*, vol. 15, pp. 11–15, Jan. 1972. (Cited on page 20)
- [71] S. Van Der Walt, J. L. Schönberger, J. Nunez-Iglesias, F. Boulogne, J. D. Warner, N. Yager, E. Gouillart, and T. Yu, “scikit-image: image processing in Python,” *PeerJ*, vol. 2, p. e453, June 2014. (Cited on page 21)
- [72] A. Horé and D. Ziou, “Image Quality Metrics: PSNR vs. SSIM,” in *2010 20th International Conference on Pattern Recognition*, pp. 2366–2369, Aug. 2010. ISSN: 1051-4651. (Cited on pages 21 and 22)
- [73] Y. Bengio, P. Simard, and P. Frasconi, “Learning long-term dependencies with gradient descent is difficult,” *IEEE Transactions on Neural Networks*, vol. 5, pp. 157–166, Mar. 1994. (Cited on page 23)
- [74] PHILIPS, “electronic measuring and microwave notes,” 1970. (Cited on page 24)
- [75] EBU, “Tech 3373 - Colour Bars for use in the production of hybrid log gamma (HDR) UHD TV,” Mar. 2020. (Cited on page 24)
- [76] E. Messina, “Standards for Visual Acuity,” (Cited on page 25)

- [77] G. Birch and J. Griffin, “Security camera resolution measurements: Horizontal TV lines versus modulation transfer function measurements,” Tech. Rep. SAND–2015-20779, 1167406, 558220, Jan. 2015. (Cited on page 25)
- [78] “LWI Klimastation.” (Cited on page 26)
- [79] “Formulario para peticion de mensajes aeronauticos.” (Cited on page 27)
- [80] “So lesen Sie einen METAR.” (Cited on page 27)
- [81] “GoPro HERO11 Black (Sport- und Unterwasserkamera).” (Cited on page 28)
- [82] “What Is Linear Field Of View (FOV)?” (Cited on page 29)
- [83] “OpenCV: OpenCV-Python Tutorials.” (Cited on page 32)
- [84] “Cesium: The Platform for 3D Geospatial.” (Cited on page 37)
- [85] “ImageStat Module — Pillow v2.4.0 (PIL fork).” (Cited on page 43)
- [86] “NumPy.” (Cited on page 45)
- [87] “GPT-5 ist da.” (Cited on page 116)
- [88] “BLABLADOR - Services - Helmholtz Cloud.” (Cited on page 116)

Anhang A.

Appendix

A.1. Abbildungen

Datum	Uhrzeit	Ausschnitt METAR Bericht	Bildname
2025:06:26	16:19	32003KT 290V360 9999 TSRA FEW005 SCT///CB	G0069282.JPG
2025:06:26	16:24	32003KT 290V360 9999 TSRA FEW005 SCT///CB	G0069283.JPG
2025:07:17	14:48	27010KT 5000 RADZ BR OVC005	G0093266.JPG
2025:07:17	14:53	27010KT 5000 RADZ BR OVC005	G0093267.JPG
2025:07:17	15:18	27011KT 7000 RADZ OVC005	G0093272.JPG

Abbildung A.1.: Ausschnitt der Logdatei für Regenbilder mit Aufnahmedatum und -Uhrzeit, sowie dem wichtigen Ausschnitt des zugeordneten METAR-Berichts und dem Bildnamen. Die Beschriftung der Daten in der obersten Zeile gehört nicht zur eigentlichen Logdatei und wird nur für das bessere Verständnis eingefügt.




Abbildung A.2.: Grundlegende Version des BP_DropCollision Blueprints zur Erzeugung von Regentropfen auf Objekten in der Simulation.







Abbildung A.3.: Erweiterte Version des BP_DropCollision Blueprints zur Erzeugung von Regentropfen auf ausgewählten Objekten in der Simulation.




(a) Simuliertes zugeschnittenes Bild mit keiner sichtbaren Farbveränderung.




(b) Simuliertes zugeschnittenes Bild mit einem Braunstich




(c) Simuliertes zugeschnittenes Bild mit einer Farbveränderung ins Lila.



(d) Reales zugeschnittenes Bild zum simulierten Bild ohne Farbveränderung.




(e) Reales zugeschnittenes Bild zum simulierten Bild mit Braunstich.




(f) Reales zugeschnittenes Bild zum simulierten Bild mit Lilafarbtön.


Abbildung A.4.: Vergleich der Farbveränderungen zwischen realen und synthetischen Bildern über den Tag.




(a) Simuliertes zugeschnittenes CAVOK Bild für den 19.06.2025 um 04:16 Uhr erstellt.




(b) Simuliertes zugeschnittenes CAVOK Bild für den 08.07.2025 um 05:16 Uhr erstellt.




(c) Simuliertes zugeschnittenes CAVOK Bild für den 14.07.2025 um 05:16 Uhr erstellt.



(d) Reales zugeschnittenes CAVOK Bild am 19.06.2025 um 04:16 Uhr aufgenommen.



(e) Reales zugeschnittenes CAVOK Bild am 08.07.2025 um 05:16 Uhr aufgenommen.



(f) Reales zugeschnittenes CAVOK Bild am 14.07.2025 um 05:16 Uhr aufgenommen.

Abbildung A.5.: Vergleich der realen und simulierten CAVOK Bilder aus den frühen Morgenstunden.




Abbildung A.6.: Gestapeltes Histogramm für die Helligkeit von Bildern unter den speziellen Wetterbedingungen: Schatten auf dem Kalibriermuster bei CAVOK, Schatten auf dem Kalibriermuster bei Regen und Regentropfen auf der Linse







Abbildung A.7.: Gestapeltes Histogramm für den Kontrast von Bildern unter den speziellen Wetterbedingungen: Schatten auf dem Kalibriermuster bei CAVOK, Schatten auf dem Kalibriermuster bei Regen und Regentropfen auf der Linse




(a) Laplace Bildschärfe Histogramm für reale CAVOK Bilder.



(b) Laplace Bildschärfe Histogramm für reale Regenbilder.




(c) Laplace Bildschärfe Histogramm für simulierte CAVOK Bilder.




(d) Laplace Bildschärfe Histogramm für simulierte Regenbilder.

Abbildung A.8.: Histogramme für die Laplace Bildschärfe der Bilder der vier Subdatensätze.



(a) Laplace Bildschärfe realer Bilder über den Tag in 3 Stunden Intervallen.



(b) Laplace Bildschärfe simulierter Bilder über den Tag in 3 Stunden Intervallen.

Abbildung A.9.: Laplace Bildschärfe der Bilder in Abhängigkeit von der Uhrzeit (blau: CAVOK Bilder; orange: Regen Bilder).






Abbildung A.10.: Gestapeltes Histogramm für die Kantenanzahl von Bildern unter den speziellen Wetterbedingungen: Schatten auf dem Kalibriermuster bei CAVOK, Schatten auf dem Kalibriermuster bei Regen und Regentropfen auf der Linse




(a) Originales reales Regenbild.



(b) Zugeschnittenes reales Regenbild.




(c) Originales simuliertes Regenbild.




(d) Zugeschnittenes simuliertes Regenbild.

Abbildung A.11.: Beispielbilder für die Auswirkung des Hintergrundes auf die Erkennung weiterer Features zur Klassifizierung von CAVOK und Regenbildern. Die zugeschnittenen Varianten sind die Zuschnitte der gezeigten originalen Bilder. Das simulierte Bild ist das für die Daten des realen Bildes generierte Bild.



(a) Erstes Beispielbild für die Eckenerkennung bei Tropfen auf der Linse.



(b) Zweites Beispielbild für die Eckenerkennung bei Tropfen auf der Linse.

Abbildung A.12.: Beispiele für die Auswirkung von Regentropfen auf der Linse auf die Eckenerkennung. In Bereichen mit erkennbaren Regentropfen nimmt die Anzahl der erkannten Ecken ab. Allerdings werden auf dem restlichen Bild viele andere Kanten erkannt.

A.2. Tabellen

Tabelle A.1.: Klassifikationsberichte für alle Modelle die auf realen zugeschnittenen Bildern trainiert wurden, ausgewertet auf realen Daten.

Modell	Klasse	Precision	Recall	F1-Score	Genauigkeit
Real-Nichts					90,00%
	real CAVOK	0,95	0,91	0,93	
	real Regen	0,79	0,88	0,83	
Real-Sampler					93,33%
	real CAVOK	0,98	0,93	0,95	
	real Regen	0,84	0,94	0,89	
Real-Wichtung					91,67%
	real CAVOK	0,95	0,93	0,94	
	real Regen	0,83	0,88	0,86	

Tabelle A.2.: Klassifikationsberichte für alle Modelle die auf simulierten zugeschnittenen Bildern trainiert wurden, ausgewertet auf realen Daten.

Modell	Klasse	Precision	Recall	F1-Score	Genauigkeit
Sim-Nichts					71,67%
	real CAVOK	0,72	1,00	0,83	
	real Regen	0,00	0,00	0,00	
Sim-Sampler					70,00%
	real CAVOK	0,71	0,98	0,82	
	real Regen	0,00	0,00	0,00	
Sim-Wichtung					68,33%
	real CAVOK	0,71	0,95	0,81	
	real Regen	0,00	0,00	0,00	

Tabelle A.3.: Klassifikationsberichte für alle Modelle die auf realen zugeschnittenen Bildern trainiert wurden, ausgewertet auf simulierten Daten.

Modell	Klasse	Precision	Recall	F1-Score	Genauigkeit
Real-Nichts					71,67%
	real CAVOK	0,72	1,00	0,83	
	real Regen	0,00	0,00	0,00	
Real-Sampler					71,67%
	real CAVOK	0,72	1,00	0,83	
	real Regen	0,00	0,00	0,00	
Real-Wichtung					71,67%
	real CAVOK	0,72	1,00	0,83	
	real Regen	0,00	0,00	0,00	

Tabelle A.4.: Klassifikationsberichte für alle Modelle die auf simulierten zugeschnittenen Bildern trainiert wurden, ausgewertet auf simulierten Daten.

Modell	Klasse	Precision	Recall	F1-Score	Genauigkeit
Sim-Nichts					80,00%
	real CAVOK	0,78	1,00	0,88	
	real Regen	1,00	0,29	0,45	
Sim-Sampler					83,33%
	real CAVOK	0,81	1,00	0,90	
	real Regen	1,00	0,41	0,58	
Sim-Wichtung					91,67%
	real CAVOK	0,95	0,93	0,94	
	real Regen	0,83	0,88	0,86	

Tabelle A.5.: Klassifikationsberichte für alle Modelle die auf realen originalen Bildern trainiert wurden, ausgewertet auf realen Daten.

Modell	Klasse	Precision	Recall	F1-Score	Genauigkeit
Real-Nichts					88,33%
	real CAVOK	0,86	1,00	0,92	
	real Regen	1,00	0,59	0,74	
Real-Sampler					95,00%
	real CAVOK	0,93	1,00	0,97	
	real Regen	1,00	0,82	0,90	
Real-Wichtung					96,67%
	real CAVOK	0,98	0,98	0,98	
	real Regen	0,94	0,97	0,97	

Tabelle A.6.: Klassifikationsberichte für alle Modelle die auf simulierten originalen Bildern trainiert wurden, ausgewertet auf realen Daten.

Modell	Klasse	Precision	Recall	F1-Score	Genauigkeit
Sim-Nichts					28,33%
	real CAVOK	0,00	0,00	0,00	
	real Regen	0,28	1,00	0,44	
Sim-Sampler					31,67%
	real CAVOK	1,00	0,05	0,09	
	real Regen	0,29	1,00	0,45	
Sim-Wichtung					40,00%
	real CAVOK	1,00	0,16	0,28	
	real Regen	0,32	1,00	0,49	

Tabelle A.7.: Klassifikationsberichte für alle Modelle die auf realen originalen Bildern trainiert wurden, ausgewertet auf simulierten Daten.

Modell	Klasse	Precision	Recall	F1-Score	Genauigkeit
Real-Nichts					80,00%
	real CAVOK	0,94	0,77	0,85	
	real Regen	0,60	0,88	0,71	
Real-Sampler					51,67%
	real CAVOK	0,89	0,37	0,52	
	real Regen	0,36	0,88	0,51	
Real-Wichtung					60,00%
	real CAVOK	0,91	0,49	0,64	
	real Regen	0,41	0,88	0,56	

Tabelle A.8.: Klassifikationsberichte für alle Modelle die auf simulierten originalen Bildern trainiert wurden, ausgewertet auf simulierten Daten.

Modell	Klasse	Precision	Recall	F1-Score	Genauigkeit
Sim-Nichts					98,33%
	real CAVOK	0,98	1,00	0,99	
	real Regen	1,00	0,94	0,97	
Sim-Sampler					98,33%
	real CAVOK	0,98	1,00	0,99	
	real Regen	1,00	0,94	0,97	
Sim-Wichtung					96,67%
	real CAVOK	0,98	0,98	0,98	
	real Regen	0,94	0,94	0,94	

Tabelle A.9.: Klassifikationsberichte für alle Sim vs. Real Modelle die auf zugeschnittenen Bildern trainiert wurden.

Modell	Klasse	Precision	Recall	F1-Score	Genauigkeit
Nichts					84,17%
	real CAVOK	0,93	1,00	0,97	
	real Regen	1,00	0,82	0,90	
	sim CAVOK	0,73	1,00	0,84	
	sim Regen	1,00	0,06	0,11	
Sampler					87,50%
	real CAVOK	1,00	0,93	0,96	
	real Regen	0,85	1,00	0,92	
	sim CAVOK	0,78	1,00	0,88	
	sim Regen	1,00	0,29	0,45	
Wichtung					89,17%
	real CAVOK	0,93	1,00	0,97	
	real Regen	1,00	0,82	0,90	
	sim CAVOK	0,81	1,00	0,90	
	sim Regen	1,00	0,41	0,58	

Tabelle A.10.: Klassifikationsberichte für alle Sim vs. Real Modelle die auf originalen Bildern trainiert wurden.

Modell	Klasse	Precision	Recall	F1-Score	Genauigkeit
Nichts					92,50%
	real CAVOK	0,90	1,00	0,95	
	real Regen	1,00	0,71	0,83	
	sim CAVOK	0,98	0,93	0,95	
	sim Regen	0,84	0,94	0,89	
Sampler					97,50%
	real CAVOK	1,00	0,98	0,99	
	real Regen	0,94	1,00	0,97	
	sim CAVOK	0,96	1,00	0,98	
	sim Regen	1,00	0,88	0,94	
Wichtung					90,83%
	real CAVOK	0,97	0,88	0,93	
	real Regen	0,76	0,94	0,84	
	sim CAVOK	1,00	0,88	0,94	
	sim Regen	0,77	1,00	0,87	

Tabelle A.11.: Zusammenfassung der Ergebnisse der Differenzanalyse für die Kategorie der strukturunabhängigen Bildmerkmale.

Methode	wichtigste Beobachtungen	Schlussfolgerungen
Helligkeit	- deutliche Tageszeitabhängigkeit bei realen Bildern → tagsüber heller - Real-Regen dunkler als Real-CAVOK - Sim-Regen heller als Sim-CAVOK - Real-Regen geringere Varianz	- Veränderung des Umgebungslichtes über den Tag - zusätzliche Effekte wie Bewölkung haben Einfluss auf reale Regenbilder - Simulation zusätzlicher Effekte fehlt - Regenbilder aus frühen Morgenstunden fehlen
Kontrast	- Real-Regen geringere Varianz als Real-CAVOK - bimodale Verteilung bei simulierten Bildern - keine Tageszeitabhängigkeit realer Bilder - deutliche Tageszeitabhängigkeit simulierter Bilder - durchschnittlich höhere Kontraste für simulierte Bilder	- Vermutung: Wolken verhindern tagsüber starke Kontraste - simulierte Bilder unterliegen keinen störenden Effekten → Kontrast nur von Tageszeit abhängig
Bildschärfe	- geringe Varianz realer und synthetischer Regenbilder - höhere Bildschärfe für Real-Regen als Real-CAVOK - höhere Bildschärfe für simulierte Bilder	- Regenbilder aus frühen Morgenstunden fehlen - Vermutung: Regentropfen erhöhen die Bildschärfe - simulierte Bilder unterliegen keinen störenden Effekten

Tabelle A.12.: Zusammenfassung der Ergebnisse der Differenzanalyse für die Kategorie der Low-Level Feature Analyse.

Methode	wichtigste Beobachtungen	Schlussfolgerungen
Kanten	- keine Kanten hinter Regentropfen auf Linse - Regentropfen auf dunklen Flächen schlecht erkannt - weniger erkannte Kanten für simulierte Bilder gegenüber realen Bildern - mehr erkannte Kanten für Sim-Regen gegenüber Sim-CAVOK - deutliche Tageszeitabhängigkeit der Kantenzahl für reale Bilder → tagsüber mehr Kanten	- Regentropfen auf Linse stören Kantenerkennung - dunkle Flächen stören die Detektion von Regentropfen als Kanten - Ausrichtung der Bilder ist entscheidend - simulierte Regentropfen werden als Kanten erkannt - Dunkelheit beeinträchtigt zuverlässige Kantenerkennung
Ecken	- geringere Varianz für simulierte Bilder - mehr Ecken für Sim-Regen gegenüber Sim-CAVOK - deutliche Tageszeitabhängigkeit für simulierte Bilder → tagsüber mehr Ecken - umgedrehter Tageszeiteffekt bei realen Bildern	- simulierte Bilder unterliegen keinen störenden Effekten - simulierte Regeneffekte haben deutlichen Einfluss - Dunkelheit beeinträchtigt Eckenerkennung, Rauschen verursacht Fehldetektionen

Tabelle A.13.: Zusammenfassung der Ergebnisse der Differenzanalyse für die Kategorie der Pixel- und Wahrnehmungsähnlichkeit.

Methode	wichtigste Beobachtungen	Schlussfolgerungen
NRMSE	- breite Streuung realer Bildpaare - sehr gute Ergebnisse für simulierte Bildpaare	- weitere Effekte spielen eine große Rolle - simulierte Regeneffekte haben nur geringe Auswirkungen
PSNR	- niedrige Werte für reale Bildpaare	- reale Bildpaare unterscheiden sich stark, trotz ähnlicher Aufnahmezeit
SSIM	- große Streuung bei realen Bildpaaren - simulierte Bildpaare nahezu identisch - Tageszeitabhängigkeit bei realen Bildpaaren → tagsüber größere Unterschiede	- weitere Effekte durch die realen Bildpaare voneinander abweichen - simulierte Regeneffekte haben nur geringe Auswirkungen

Tabelle A.14.: Zusammenfassung der Ergebnisse der Differenzanalyse für die Kategorie Klassifikator- und Anwendungsbasiert.

Methode	wichtigste Beobachtungen	Schlussfolgerungen
Cross-Dataset Generalisierung	- real zu real sehr gut - sim zu sim für original sehr gut - cross Generalisierung bevorzugt bei zugeschnitten CAVOK - cross Generalisierung bevorzugt bei original Regen - cross Generalisierung original Real zu Sim am Besten	- Unterschiede zwischen realen und synthetischen Daten sehr groß - Unterschiede zwischen zugeschnittenen synthetischen CAVOK und Regenbildern sehr gering - simulierte Bilder haben zu wenig Features - Hintergrund erhöht die Zahl der Features
Real vs. Sim Klassifizierer	- real und sim immer korrekt klassifiziert - reale Wetterklassen immer gut klassifiziert - simulierte Wetterdaten für originale Bilder gut klassifiziert	- Unterschiede zwischen realen und synthetischen Daten sehr groß - Unterschiede zwischen zugeschnittenen synthetischen CAVOK und Regenbildern sehr gering - simulierte Bilder haben zu wenig Features - Hintergrund erhöht die Zahl der Features

A.3. Quellcodeausschnitte

```
1  import numpy as np
2
3  def MLV_Sharpness(img):
4      offsets = [(-1, -1), (-1, 0), (-1, 1),
5                (0, -1),      (0, 1),
6                (1, -1),  (1, 0), (1, 1)]
7
8      max_diff = np.zeros_like(img, dtype=np.int16)
9
10     for dy, dx in offsets:
11         shifted = np.roll(np.roll(img, dy, axis=0), dx, axis=1)
12         diff = np.abs(img - shifted)
13         max_diff = np.maximum(max_diff, diff)
14
15     mlv = np.clip(max_diff, 0, 255).astype(np.uint8)
16
17     return np.std(mlv)
```

Listing A.1: Implementierung der MLV Bildschärfe basierend auf der Originaldefinition

Verwendete Hilfsmittel

Nutzung von KI Modellen

Für die sprachliche Verbesserung der Arbeit wurden KI Modelle genutzt. Im Genaueren wurden die Kurzfassung, sowie die Kapitel 1, 2, 3 und 4 mittels ChatGPT 5.0 [87] sprachlich verbessert.

Für die sprachliche Verbesserung der Kapitel 5, 6, 7 und 8 wurde BLABLADOR [88] verwendet.

Selbstständigkeitserklärung

Hiermit erkläre ich, Theresa Maienschein,

- dass ich die vorgelegte Arbeit selbstständig und ohne unerlaubte Hilfe angefertigt habe
- dass ich keine über die im Vorfeld explizit zugelassenen und von mir angegebenen Hilfsmittel hinausgehenden Mittel benutzt habe
- dass ich die vorliegende Arbeit bisher nicht in gleicher oder ähnlicher Form einer anderen Prüfungsbehörde vorgelegt habe

Ich willige ein,

- dass meine Arbeit mittels Software auf Plagiate überprüft werden kann. Mir ist bekannt, dass es sich bei der Abgabe eines Plagiats um ein schweres akademisches Fehlverhalten handelt und dass Täuschungen nach der für mich gültigen Studien- und Prüfungsordnung geahndet werden.

Mir ist bewusst,

- dass im Falle eines Täuschungsversuchs die Arbeit von Amts wegen als mit „nicht ausreichend (5,0)“ bewertet gilt
- dass ich im Fall der Verwendung von KI-Tools in der Arbeit die vollumfängliche Verantwortung für eventuell durch die KI generierte fehlerhafte oder verzerrte Inhalte, fehlerhafte Referenzen, Verstöße gegen das Datenschutz- und Urheberrecht oder Plagiate trage.

Meine eigene geistige Leistung stand immer im Vordergrund und ich habe jederzeit den Prozess steuernd gearbeitet.

Magdeburg, 1. Oktober 2025



Unterschrift