Hochschule
Bonn-Rhein-Sieg
University
of Applied Sciences

Fachbereich Informatik
Department of Computer Sciences

Masterarbeit

Studiengang Informatik

Parallelisierung der Kamera-Target Methode zur Heliostat Kalibration auf Grundlage von Deep Learning

von

Amin Dianati
9032294

Erstprüfer	Prof. Dr. Rainer Herpers
Zweitprüfer	Prof. Dr.-Ing. Robert Pitz-Paal
Betreuer	Max Pargmann
eingereicht am	12.09.2022

Eidesstattliche Erklärung

Ich versichere an Eides statt, die von mir vorgelegte Arbeit selbstständig verfasst zu haben. Alle Stellen, die wörtlich oder sinngemäß aus veröffentlichten oder nicht veröffentlichten Arbeiten anderer entnommen sind, habe ich als entnommen kenntlich gemacht. Sämtliche Quellen und Hilfsmittel, die ich für die Arbeit benutzt habe, sind angegeben. Die Arbeit hat mit gleichem Inhalt bzw. in wesentlichen Teilen noch keiner anderen Prüfungsbehörde vorgelegen.

(Datum, Ort, Unterschrift)

Inhaltsverzeichnis

1 Einleitung **1**

2 Problemstellung **3**

3 Grundlagen **6**

3.1 Turmkraftwerke . . . 6

3.1.1 Aufbau . . . 6

3.1.2 Heliostate . . . 7

3.2 Fehlerursachen . . . 8

3.3 Kalibrierung der Heliostate . . . 9

3.4 Kamera Target-Methode . . . 9

3.5 Simulation . . . 10

3.5.1 Solar Tower Raytracing Laboratory . . . 10

3.6 Stand der Forschung . . . 11

3.6.1 Kamera im Feld . . . 12

3.6.2 Kamera am Turm . . . 12

3.7 Machine Learning . . . 13

3.7.1 Transfer Learning . . . 13

3.7.2 Data Augmentation . . . 13

4 Material und Methoden **15**

4.0.1 Auswahl der Heliostate . . . 16

4.0.2 Segmentierung der Brennflecken . . . 18

4.0.3 Ursprung des Brennflecks vorhersagen . . . 18

4.0.4 Heliostat und Brennfleck zuordnen . . . 19

4.1 Segmentierung der Brennflecke . . . 19

4.1.1 Watershed . . . 19

4.1.2 U-Net . . . 20

4.2 Versuchsaufbau . . . 21

4.2.1 Datensätze . . . 21

4.2.2 Simulierter-Fehler . . . 22

4.2.3 Homogene Oberfläche . . . 23

4.2.4 Reale Oberfläche . . . 24

4.3 Netzwerke zur Auswertung der Position . . . 25

4.3.1 Einfaches CNN . . . 26

4.3.2 DenseNet . . . 27

4.3.3 Generator (StyleGAN) . . . 27

4.3.4 Recurrent Neural Network (RNN) . . . 28

4.4 Auswertung der Daten . . . 28

4.5 Bewertungskriterien . . . 30

4.5.1 Segmentierung . . . 30

4.5.2 Vorhersage der Position . . . 31

4.5.3 Zuordnung . . . 31

5 Ergebnisse **33**
5.1 Segmentierung . . . 33
5.1.1 Watershed . . . 33
5.2 Bildauflösung . . . 34
5.3 Vorhersage der Position im Feld . . . 34
5.3.1 Bildserie . . . 36
5.4 Data Augmentation . . . 37
5.4.1 Verringerte IoU . . . 37
5.4.2 Anwendung auf unbekanntes Feld . . . 38
5.4.3 Transfer Learning . . . 38
5.5 Heliostat Zuordnung . . . 39

6 Diskussion **41**
6.1 Segmentierung . . . 41
6.1.1 Watershed . . . 41
6.1.2 U-Net . . . 43
6.2 Vorhersage der Position . . . 43
6.2.1 Vergleich eingesetzter Modelle . . . 45
6.2.2 Bildreihen . . . 47
6.3 Zuordnung der Brennflecken . . . 47
6.4 Anwendung in der Praxis . . . 49

7 Fazit **50**
7.1 Ausblick . . . 50

Abbildungsverzeichnis

Abbildung 1: Solarturm Jülich - Blick aus dem Feld 1
Abbildung 2: Solarturm Jülich - Blick auf den Turm 3
Abbildung 3: Solarthermisches Kraftwerk - Schematischer Aufbau 6
Abbildung 4: Heliostate 7
Abbildung 5: Kamera-Target Methode - Schematisch 9
Abbildung 6: STRAL Benutzeroberfläche 11
Abbildung 7: Methodik 16
Abbildung 8: Heliostat Auswahl 17
Abbildung 9: Bildserie - Brennflecken tauschen Positionen 18
Abbildung 10: Watershed - Schematische Darstellung 20
Abbildung 11: U-Net - Schematischer Aufbau 20
Abbildung 12: Bildserie - Beispiel für zwei Heliostate 21
Abbildung 13: Heliostat - Befestigung der Achsen 23
Abbildung 14: Brennflecken - Vergleich verschiedener Oberflächen 24
Abbildung 15: Brennflecken - Vergleich der bildlichen Darstellung 24
Abbildung 16: Parallele Architektur - Schematische Darstellung 26
Abbildung 17: Einfaches CNN - Schematische Darstellung 27
Abbildung 18: Brennfleck - Reale Spiegeloberfläche 31
Abbildung 19: Vergleich - Segmentierte Brennflecken 33
Abbildung 20: Trainingsverlauf in Relation zur Datensatzgröße 36
Abbildung 21: Überlauf bei Segmentierung 41
Abbildung 22: Beispiel einer Fehlerhaften Segmentierung 42
Abbildung 23: Fragmentierung bei Einsatz von U-Net 43
Abbildung 24: Vergleich vom Trainingsverlauf 44
Abbildung 25: Beispiel analytische Auswertung zweier Brennflecken 44

Tabellenverzeichnis

Tabelle 1: Simulationsdaten 25

Tabelle 2: Segmentierung 33

Tabelle 3: Einfluss der Bildauflösung 34

Tabelle 4: Vergleich eingesetzter Modelle 1024 Kalibrationen 35

Tabelle 5: Vergleich eingesetzter Modelle 4096 Kalibrationen 35

Tabelle 6: Bildserie 36

Tabelle 7: Data Augmentation 37

Tabelle 8: Verringerte IoU 37

Tabelle 9: Unbekanntes Feld 38

Tabelle 10: Transfer Learning 38

Tabelle 11: Heliostat Zuordnung 39

Tabelle 12: Heliostat Zuordnung mit Segmentierungsfehler 39

1 Einleitung

Weltweit steigt der Energieverbrauch aufgrund von wirtschaftlichem Wachstum. Einen großen Beitrag dazu liefern vor allem Schwellenländern, welche prognostiziert zu einem gesamten Wachstum von 30% bis 2050 beitragen sollen [1]. Gleichzeitig werden auch die ausgestoßenen mengen Kohlenstoffdioxid (CO_2) drastisch steigen. Um den CO_2-Ausstoß trotz steigendem Energieverbrauch niedrig zu halten, wollen vor allem die führenden Industriestaaten dem entgegenwirken. Dazu wird aktuell, und auch in Zukunft, vermehrt auf erneuerbare Energien gesetzt.

Weltweit steuerten erneuerbare Energien in den letzten Jahren circa 17% zu dem gesamten Primärenergieverbrauch bei [1]. Die Energiegewinnung, mit Hilfe von Solarenergie, wurde dabei hauptsächlich mit Photovoltaikanlagen erzielt. Diese wandeln eintreffende Solarstrahlung direkt in elektrische Energie um. Wird diese elektrische Energie für die Erzeugung von Wärme eingesetzt, entstehen bei der Umwandlung erneut Verluste.

Abbildung 1: Mit beweglichen Spiegeln (Heliostaten) wird die einfallende Sonnenstrahlung auf einem Punkt, hier der Turm links im Bild, konzentriert. Gezeigt wird der Solarturm vom Deutschen Zentrum für Luft- und Raumfahrt (DLR) in Jülich. (Quelle Foto: DLR)

Anders als Photovoltaikanlagen bündeln solarthermische Kraftwerke direkte Sonnenstrahlung mit Hilfe von Heliostaten auf einen Punkt. Als Heliostat werden Spiegel bezeichnet, mit denen das Sonnenlicht unabhängig der Sonnenposition auf eine festgelegte Position reflektieren. Die so erzeugte Wärme kann direkt genutzt werden, oder beispielsweise zur Erzeugung von Wasserdampf, um in einem zweiten Schritt elektrische Energie durch eine Turbine zu erzeugen [2]. Wie bereits in der Praxis durchgeführt, kann die hohe Temperatur dazu genutzt werden um thermochemische Verfahren durchzuführen [3]. Ebenfalls können, mit Hilfe eines Turmkraftwerks, synthetische Kraftstoffe auf Basis von Wasser und Kohlenstoffdioxid hergestellt werden [4].

Damit die Heliostate immer auf einen bestimmten Punkt reflektieren, müssen die Spiegel der Sonnenposition nachgeführt werden. Dabei können durch Umwelteinflüsse, ungenaue Motoren und nicht homogenen Spiegeloberflächen Fehler in das System eingeführt

werden. Diese beeinflussen das Zielverhalten der Heliostate und führen dazu, dass die Energieausbeute des Kraftwerks mit steigender Einsatzdauer sinkt.

Um die in der Praxis aufkommenden Fehler auszugleichen, muss regelmäßig eine Kalibrierung der Reflektoren durchgeführt werden. Der letzte Stand der Technik ist die Kamera-Target Methode [5]. Bei dieser wird jedes Heliostat einzeln kalibriert. Jeder Kalibrierungsvorgang kann dabei bis zu einer Minute dauern.

In dieser Arbeit wird ein Verfahren vorgestellt und untersucht, bei dem die Kamera-Target Methode modifiziert wird. Durch dieses Verfahren ist es möglich mehrere Heliostate zur selben Zeit zu kalibrieren. So kann die benötigte Zeit für die gesamte Kalibrierung verringert werden und es ist außerdem möglich das Verfahren sofort für die meisten bestehenden Kraftwerke einzusetzen, ohne weitere Änderungen an der Anlage durchzuführen zu müssen.

2 Problemstellung

Solarthermische Kraftwerke bestehen aus einem Turm, auf dem die Strahlung gebündelt wird und vielen Heliostaten, mit denen die Sonnenstrahlung auf einen Punkt auf dem Turm gebündelt wird (siehe Abbildung 2). Das Feld eines Turmkraftwerks kann dabei mit einer großen Anzahl einzelner Heliostate bestückt werden. Die Anzahl kann dabei von mehreren tausend bis hin zu über hunderttausend Heliostaten variieren. Damit ist der primäre Kostenfaktor eines solchen Kraftwerks die Produktion und Installation der Heliostate. Um Kosten zu sparen werden daher in der Praxis günstige Bauteile eingesetzt, welche höhere Toleranzen mit sich bringen. Da die Heliostate der Sonne nachgeführt werden müssen, wirken sich die größeren Toleranzen negativ auf das Verfolgungsverhalten der einzelnen Heliostate aus. Der dadurch entstehende Verfolgungsfehler muss regelmäßig ausgeglichen werden, damit die Heliostate, auch nach längerem Einsatz, die Strahlung weiterhin auf den vorgegebenen Zielpunkt reflektieren.

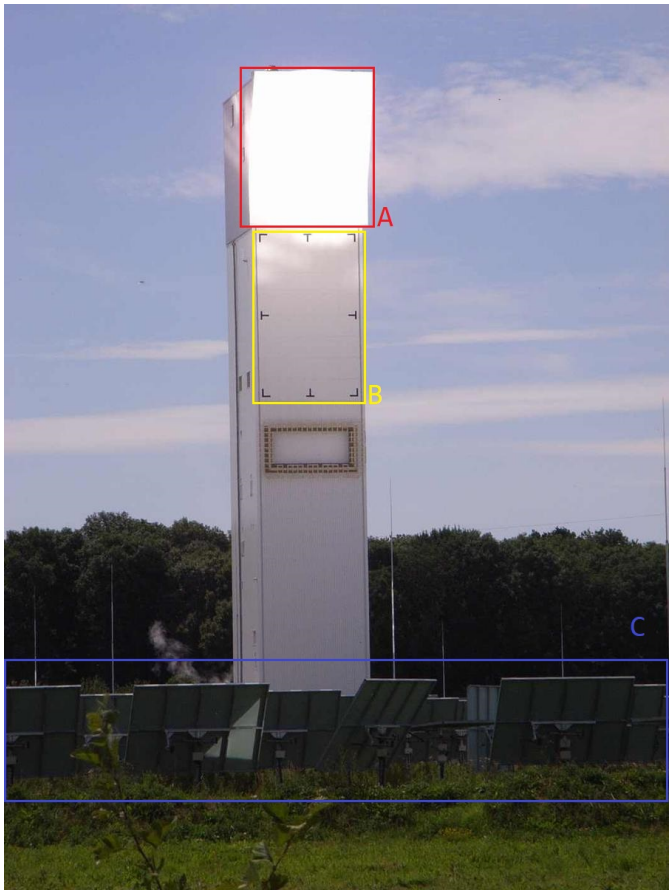

Abbildung 2: Zu sehen ist das Turmkraftwerk in Jülich. Das Turmkraftwerk hat einen Receiver (A) auf den alle Heliostate (C) gerichtet sind. Zur Kalibration mit der Kamera-Target Methode wird als Target (B) die weiße Fläche direkt unter dem Receiver genutzt. (Quelle Foto: DLR)

Dabei hat sich die Kamera-Target Methode weitestgehend durchgesetzt. Bei dieser wird das Heliostat von dem Zielpunkt auf dem Receiver abgezogen und auf eine diffuse weiße Fläche (siehe Abbildung 2) gerichtet. Der entstehende Lichtfleck auf dem Target wird anschließend mit einer Kamera, die im Feld steht, aufgenommen. Anhand der Bilddaten kann die Ist-Position des Brennflecks mit der Soll-Position abgeglichen werden. Der dabei

berechnete Fehler wird dann über das Steuerungsprogramm korrigiert, sodass die Differenz der Ist- und Soll-Position angepasst wird. Während die Kalibration durchgeführt wird trägt das betroffene Heliostat nicht zur Energiegewinnung bei. Sobald die Korrektur abgeschlossen ist, wird das Heliostat wieder auf den Receiver gerichtet und der Prozess wird mit dem nächsten Heliostat wiederholt. Das bedeutet auch, dass bei steigender Anzahl an Heliostaten im Feld auch der Zeitabstand zwischen den Kalibrierungen für die einzelnen Heliostate steigt. Dies führt zwangsläufig dazu, dass solarthermische Kraftwerke bei längerem Einsatz ohne regelmäßige Kalibrierung an Effizienz verlieren.

Um einerseits Zeit zu sparen und andererseits das Kalibrierintervall zu erhöhen, soll in dieser Arbeit ein Verfahren entwickelt und evaluiert werden, welches auf Grundlage der Kamera-Target Methode mehrere Heliostate zur gleichen Zeit kalibriert. Grundsätzlich müssen dazu mehrere Heliostate parallel auf das Target gerichtet werden. Im Gegensatz zur Kamera-Target Methode müssen die entstehenden Brennflecken segmentiert und den jeweiligen Heliostaten zugewiesen werden, da durch den Fehler der Heliostate keine direkte Zuordnung allein über die Zielposition auf dem Target mehr möglich ist. Die beiden Hauptaufgaben sind dabei die Segmentierung der einzelnen Brennflecken und die Zuordnung des Lichtflecks auf dem Target zu dem passenden Heliostat im Feld.

Für das Verfahren stehen weitere Parameter zur Verfügung. Dazu gehören die Bilddaten der Lichtflecken, die Position der Heliostate, der dazugehörige Zielpunkt und die Sonnenposition. Das Modell soll anhand dieser Parameter eine Zuordnung von Heliostat zu Brennfleck prognostizieren. Mit Hilfe der Position des Brennflecks und dem angefahrenen Zielpunkt wird für jedes Heliostat im Anschluss, wie bei der Kamera-Target Methode, eine Deltakorrektur ausgerechnet.

Die eigentliche Ausrichtung und Ansteuerung der Heliostate wird in dieser Arbeit nicht weiter besprochen, da nach der Zuordnung die Korrektur wie bei der Kamera-Target Methode durchgeführt wird.

Im nächsten Kapitel werden dazu die theoretischen Grundlagen erläutert und auf bereits erforschte Verfahren eingegangen, mit denen es möglich ist mehrere Heliostate parallel zu kalibrieren.

Im vierten Kapitel wird auf diese Grundlagen aufgebaut und ein Verfahren vorgestellt, mit dem die parallele Kalibrierung mehrerer Heliostate möglich ist. Dazu wird ebenfalls auf die einzelnen Schritte des Verfahrens wie die Segmentierung, Vorhersage und Zuordnung eingegangen. Abschließend wird die Testumgebung und der Versuchsaufbau besprochen, auf dessen Grundlage die Evaluation durchgeführt wird.

Im fünften Kapitel werden zunächst die Ergebnisse der Segmentierung präsentiert. Nachfolgend werden die Ergebnisse verschiedener Machine Learning Methoden zur Vorhersage des Ursprungs eines Brennflecks im Feld verglichen. Außerdem wird die Anwendbarkeit auf unbekannte Datensätze Evaluiert, dazu werden auch Datensatzoptimierungen wie Data Augmentation [6] berücksichtigt. Abschließend wird die Genauigkeit des kombinierten Verfahrens, der Zuordnung von Heliostat zu Brennfleck, anhand verschiedener

Datensätze vorgestellt.

Im letzten Kapitel werden die Ergebnisse diskutiert und auf Vor- und Nachteile der einzelnen Methoden eingegangen. Außerdem werden dazu Grenzfälle aufgezeigt und deren Einfluss auf das Verfahren erläutert. Es wird abschließend besprochen, wie dieses Verfahren in der Praxis angewendet werden kann und welche zusätzlichen Faktoren dabei beachtet werden müssen.

3 Grundlagen

3.1 Turmkraftwerke

Solarthermische Kraftwerke bündeln einfallendes Sonnenlicht auf einen Strahlungsempfaenger (Receiver), um die so entstehende Wärme zu Nutzen (siehe Abbildung 3). Diese kann beispielsweise mit Hilfe eines Dampfkraftwerks zur Stromerzeugung genutzt werden. Um Sonnenstrahlen auf dem Receiver zu bündeln werden Spiegel (Heliostate) genutzt, die mit Hilfe von Motoren der Sonne nachgeführt werden. Aufgrund der Verfolgung der sich ändernden Sonnenposition, Verschleiß und anderen Umwelteinflüssen, entstehen über Zeit Verfolgungsfehler. Diese beeinflussen das Zielverhalten der Heliostate und verringern so den Energieertrag der gesamten Anlage.

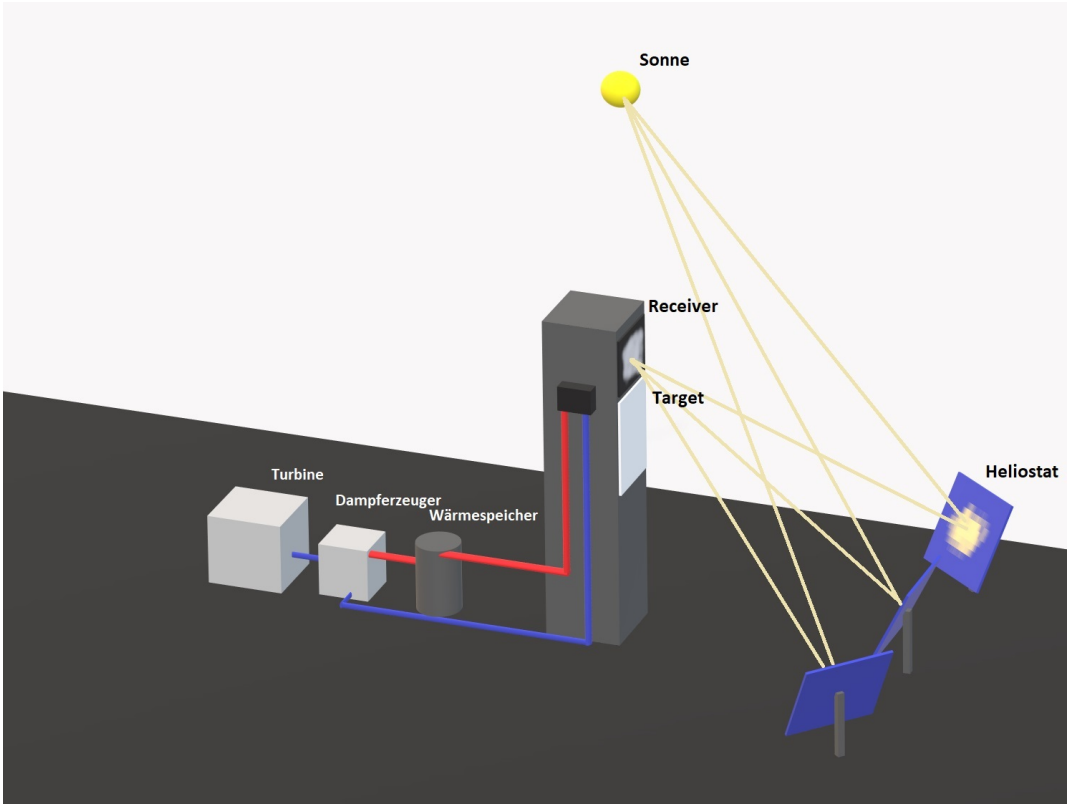

Abbildung 3: Dargestellt ist eine schematischer Aufbau eines solarthermischen Kraftwerks, welches zur Gewinnung elektrischer Energie genutzt wird. dazu wird die eintreffende Sonnenstrahlung mit Hilfe von Heliostatemn auf einem Receiver gebündelt. Die Wärme wird mit einer Flüssigkeit zu einem Wärmespeicher übertragen. Im Anschluss wird Dampf erzeugt, um über eine Dampfturbine die Wärme Energie in elektrische Energie umzuwandeln.

3.1.1 Aufbau

Die Sonnentrahlung wird auf dem Receiver gebündelt, welcher sich im oberen Bereich des Turms befindet. Der Receiver wird genutzt um die eintreffende konzentrierte Sonnenstrahlung in Wärme umzuwandeln. Die so entstandene Wärme wird mit Hilfe eines Wärmeträgers an die nachfolgenden Anlagen weitergegeben. Die so erzeugte Wärme kann direkt genutzt werden oder in weiteren Schritten zur Stromerzeugung eingesetzt werden. Dazu wird beispielsweise die erzeugte Wärme genutzt um mit Hilfe eines Damp-

ferzeugers eine Dampfturbine anzutreiben um letztendlich Strom generieren zu können. Ebenfalls ist an dem Turm eine diffuse Fläche (siehe Abbildung 3) angebracht, diese wird zum Beispiel während der Kalibrierung des Heliostatenfeldes genutzt.

3.1.2 Heliostate

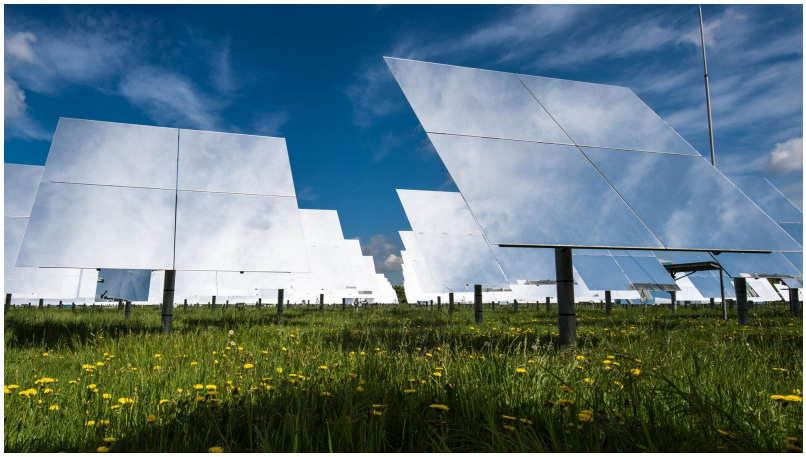

Abbildung 4: Bildausschnitt eines Heliostanenfelds mit rechteckigen Spiegelflächen. Die Flächen sind unterteilt in vier Facetten. Die Oberfläche ist meist konkav, sodass die Heliostate das Licht gebündelt auf einen Punkt konzentrieren. (Quelle Foto: DLR)

Heliostate werden eingesetzt um die einfallende Sonnenstrahlung zu konzentrieren, indem diese mit Hilfe eines Spiegels auf einen Punkt konzentriert wird. Dazu sind die Heliostate mit beweglichen Achsen ausgestattet, welche mit Motoren eingestellt werden können. Mit einer Computersteuerung werden die Motoren anhand eines Zielpunktes auf den Receiver des Turms ausgerichtet. Die Verfolgung der Sonne erfolgt dabei anhand eines Modells, da eine direkte Steuerung durch Sensoren an den Heliostaten zu viele Kosten verursachen würde. Die Form und Größe eines Heliostaten ist sehr unterschiedlich und wird meist dem Gesamtkonzept der Anlage angepasst. Üblicherweise werden Rechteckige Spiegel mit einer Gesamtfläche zwischen 30m^2 oder 150m^2 verwendet. Da das Heliostatenfeld das kostspieligste Element eines solchen Kraftwerks darstellt, wird dementsprechend versucht die Kosten der einzelnen Bauteile gering zu halten. In der Produktion wirkt sich das vor allem auf die Qualität der Oberflächen und der eingesetzten Motoren zur Einstellung des Winkels aus.

Ein Heliostat kann mit einem oder mehreren Spiegeln, auch Facetten genannt, bestückt werden (siehe Abbildung 4). In einem Heliostatenfeld werden üblicherweise baugleiche Heliostate aufgestellt. Da jedoch bei steigendem Abstand zu dem Turm auch der reflektierte Brennfleck größer wird, kann dem in der Praxis entgegen gewirkt werden. Dazu wird zum einen 'Focusing' angewendet, wobei die Oberfläche der Spiegel konkav verbogen werden [7]. Es ist ebenfalls möglich die einzelnen Facetten konkav zueinander zu verkippen ('Canting') [7].

3.2 Fehlerursachen

Fehler des Zielverhaltens von Heliostaten kann auf verschiedene Ursachen zurückgeführt werden und wurde bereits in verschiedenen Studien untersucht. Díaz-Félix et al. beschaeftigten sich vor allem mit den physikalischen Einflüssen auf das Zielverhalten [8] . Gross und Balz konnten zeigen, dass auch durch Nutzung unterschiedlicher Koordinatensysteme während der Planung eines Kraftwerks Ungenauigkeiten entstehen können [9]. Die Autoren stellten außerdem fest, dass auch Software- und Programmierfehler zu dem Verfolgungsfehler beitragen können.

Es ist zu beachten, dass der Verfolgungsfehler nicht auf eine bestimmte Ursache zurück zu führen ist. Vielmehr muss eine Kombination aus verschiedenen Ursachen betrachtet werden, wobei der größte Einfluss auf die Motoren, beziehungsweise die beweglichen Achsen, zurückgeführt werden kann. Um einen Überblick zu bekommen, werden in der folgenden Auflistung einige der Fehlerursachen vorgestellt:

- **Konstruktion**: Bei der Herstellung der einzelnen Komponenten, die zum Bau eines Heliostaten genutzt werden, muss in der Praxis mit bestimmten Toleranzen gerechnet werden. Auch bei der Konstruktion des Sockels kann eine Unebenheit die Ausrichtung eines Heliostaten beeinflussen.
- **Spiegeloberfläche** / **Facetten**: Um die Größe des Brennflecks auf dem Receiver zu verkleinern, wird die Spiegeloberfläche gekrümmt. Bei Heliostaten mit mehreren Facetten können diese zusätzlich angewinkelt werden, um ebenfalls die Größe der Reflexion anzupassen.
- **Motoren**: Wie auch bei den Spiegeloberflächen können die Motoren, die zur Verfolgung der Sonne genutzt werden, in der Praxis nicht ohne bestimmte Toleranzen produziert werden. Das führt dazu, dass jedes Heliostat zusätzlich einen individuellen Fehler durch die Ausrichtung der Motoren haben.
- **Sensoren**: Auch die Sensoren, welche Beispielsweise während einer Kalibrierung genutzt werden, sind fehlerbehaftet und tragen zu einer nicht perfekten Ausrichtung bei.
- **Modell**: Um die Heliostate auszurichten wird ein Modell angenommen, bei dem zum Beispiel anhand der Uhrzeit eine bestimmte Sonnenposition angenommen wird. Diese Annahmen basieren auf Vorhersagen, welche nicht direkt mit der tatsächlichen Sonnenposition übereinstimmen. Dieser Fehler ist in der Praxis jedoch sehr gering.
- **Software**: Die Steuerung der Heliostate erfolgt über ein Softwareprogramm. Auch dieses kann durch numerische Ungenauigkeit aber auch durch fehlerhafte Programmierung zu einem Fehler führen.
- **Umwelt**: Atmosphärische Änderungen, Wind, Regen und andere äußere Einflüsse können die Ausrichtung der Heliostate beeinflussen.
- **Alterung und Abnutzung**: Alterung und Abnutzung der einzelnen Bauteile, wie

der Achsen oder den Motoren, tragen dazu bei, dass bei längerem Einsatz eines Heliostaten die eingestellten Parameter des unterliegenden Modells nicht mehr, mit denen in der Realität vorliegenden, übereinstimmen.

3.3 Kalibrierung der Heliostate

Wie im vorherigen Kapitel bereits beschrieben, müssen die Heliostate der Sonne nachgeführt werden damit das reflektierte Sonnenlicht auf den Receiver trifft. Dazu werden physikalische Modelle genutzt, die anhand der vorherbestimmten Sonnenposition die Ausrichtung der einzelnen Heliostate individuell anpassen. Die beiden Hauptfehler sind dabei die mechanische Ungenauigkeit der einzelnen Motoren, die zur Ausrichtung der Heliostate benutzt werden und der Fehler des Modells, welches die Sonnenposition vorhersagt. Mit einbezogen sind dabei auch die numerischen Fehler, welche durch die Nutzung eines Computers für die Berechnungen mit einhergeht. Um diese Fehler auszugleichen werden die Heliostate in der Praxis regelmäßig kalibriert.

3.4 Kamera Target-Methode

Die Kamera-Target-Methode ist Stand der Technik und wird bei den meisten aktuell betriebenen Solarwärmekraftwerken eingesetzt. Diese Methode hat sich vor allem wegen der ausreichend hohen Genauigkeit, bei vollständiger Automatisierung, durchgesetzt. Der größte Nachteil dieser Methode ist jedoch, dass zu einem Zeitpunkt nur ein einzelnes Heliostat kalibriert werden kann. Bei großen Anlagen kann das dazu führen, dass die zeitlichen Abstände zwischen zwei Kalibrierungen sehr groß werden. Das kann wiederum zur Folge haben, dass nur ein Teil der Heliostate optimal genutzt wird. Ebenfalls muss das Heliostat dazu von dem Receiver abgezogen und auf das Target gerichtet werden. Während der Kalibrierung trägt das Heliostat nicht mehr zu der Energiegewinnung bei.

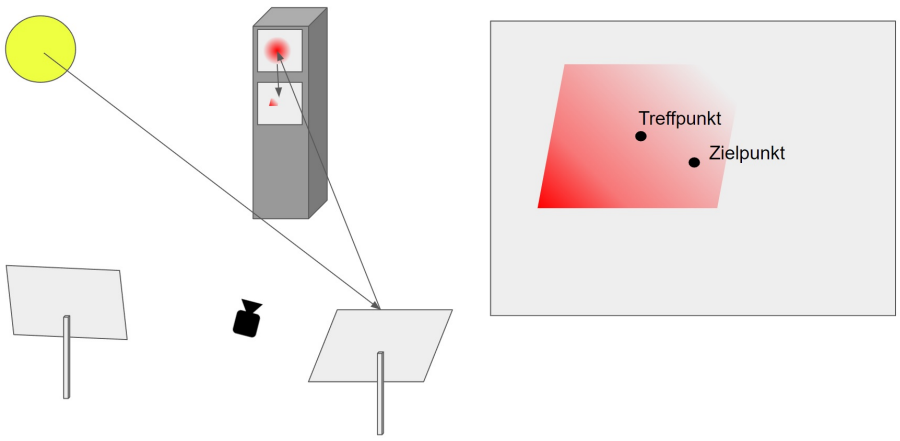

Abbildung 5: Um ein Heliostat mit der Kamera-Target Methode kalibrieren zu können wird zunächst eine Kamera im Feld positioniert. Diese wird genutzt um die Brennflecken auf dem Target aufzunehmen. Während der Kalibrierung wird das Heliostat von dem Receiver abgezogen und auf das Target gerichtet. Anhand der Differenz von Ziel- und Treffpunkts des Brennflecks auf dem Target kann die Ausrichtung des Heliostaten angepasst werden, um so den Verfolgungsfehler auszugleichen.

Um die Kalibrierung mit der Kamera-Target Methode durchzuführen muss zunächst eine Kamera im Feld platziert werden. Diese Kamera wird auf das Target ausgerichtet (siehe Abbildung 5). Im ersten Schritt wird das zu kalibrierende Heliostat auf das Target ausgerichtet. Im zweiten Schritt wird die Soll-Position, die durch das unterliegende Modell vorgegeben ist mit der tatsächlichen Position auf dem Kamerabild verglichen. Im letzten Schritt wird das Modell anhand des Deltas der Ist- und Soll-Position angepasst. Abschließend wird das Heliostat wieder auf den Receiver ausgerichtet und kann so wieder zu der Energiegewinnung beitragen.

3.5 Simulation

Für die Auswertung des Verfahrens werden simulierte Daten genutzt um während des Trainings der Modelle, aber auch bei der Auswertung, einzelne Probleme explizit betrachten zu können. Auch wäre der Zeitaufwand um genügend reale Datensätze zu erstellen nicht im Rahmen dieser Arbeit. Um dennoch reale Spiegeloberflächen zu berücksichtigen, sollen vermessene Heliostate aus dem Kraftwerk in Jülich eingesetzt werden. Da eine Simulation für ein solches Kraftwerk im Grunde auf einem Rayctracer basiert, können bei Nutzung realer Spiegeloberflächen und synthetischen Fehlern, Ergebnisse erzielt werden, die der Realität sehr nahe kommen [10].

3.5.1 Solar Tower Raytracing Laboratory

Um das Verhalten verschiedener solarthermischer Kraftwerke zu erforschen, wurde vom DLR das Simulationsprogramm 'Solar Tower Raytracing Laboratory' (STRAL) entwickelt [11]. Mit diesem Programm können Turmkraftwerke unter verschiedenen realitätsnahen Bedingungen simuliert werden. Die Funktionalität wird mit Hilfe von Raytracing umgesetzt, bei dem das Verhalten der eintreffenden Sonnenstrahlung berechnet wird. Es stehen verschiedene Parameter zur Verfügung damit unterschiedliche Szenarien abgebildet werden können. Dazu gehören unter anderen die Sonnenposition und der Standpunkt der zu analysierenden Anlage. Ebenfalls können die Positionen der Heliostate auf dem Feld frei eingestellt werden. Es ist möglich für jedes Heliostat eine unterschiedliche Form und Oberflächenbeschaffenheit vorzugeben. Um Fehler oder Toleranzen zu simulieren, kann zusätzliche, oder auch selbst definierte Funktionalität mittels Bibliotheken an bestimmte Heliostate angebunden werden. So kann beispielsweise der Verfolgungsfehler während der Simulation mit STRAL berücksichtigt werden.

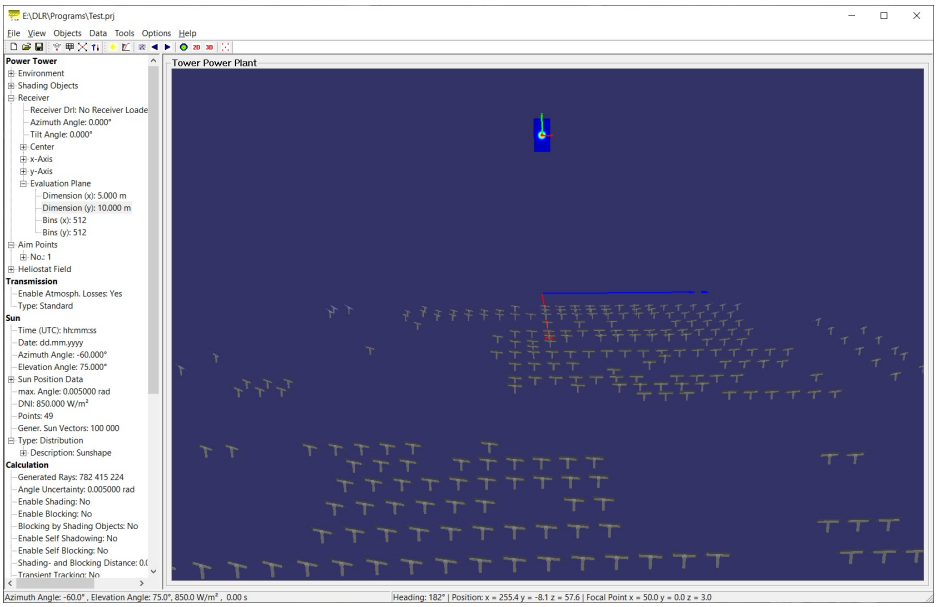

Abbildung 6: Mit Hilfe der Simulationssoftware STRAL wurde ein Teil der vermessenen Heliostat-Daten von dem solarthermischen Kraftwerk in Jülich ohne Verfolgungsfehler simuliert. Die Strahlungsdichte, für den in dieser Simulation eingestellten Sonnenstand, wird auf dem Target abgebildet. Diese Daten können auch in tabellarischer Form exportiert werden.

Eine Veröffentlichung vom DLR konnte zeigen, dass die so simulierten Brennflecken, bei Annahme realer Oberflächendaten, eine ausreichend gute Annäherung an die in der Realität gemessenen Werte bietet und wies eine Genauigkeit von bis zu 98% aus [12]. Die Simulationsdaten können ebenfalls genutzt werden um die Anzahl der benötigten Realdaten zu ergänzen und damit den Messaufwand gering zu halten, beziehungsweise eine auf Daten gestützte Methode möglich zu machen.

3.6 Stand der Forschung

Solarthermische Kraftwerke können aufgrund der in der Praxis vorkommenden Abweichungen und Toleranzen nicht ohne regelmäßige Kalibrierung betrieben werden. Die Kamera-Target Methode ist aktuell Stand der Technik, allerdings weist dieses Methode, wie oben beschrieben, auch Nachteile auf die den Einsatz in der Praxis nicht optimal machen. In der folgenden Auflistung werden wichtige Bewertungskategorien für Kalibrierverfahren aufgelistet:

- Kosten
- Genauigkeit
- Zeitaufwand
- Automatisierung

Nachfolgend werden verschiedene Ansätze vorgestellt mit denen es möglich ist, mehrere Heliostate zur selben Zeit zu kalibrieren, oder aber die Kalibrierung außerhalb der Betriebszeiten eines Kraftwerks zu ermöglichen. Außerdem wird anhand der oben genannten Kriterien erläutert wieso diese noch nicht in der Praxis eingesetzt werden.

3.6.1 Kamera im Feld

Mit einer Kamera im Feld wurden bereits weitere Verfahren vorgestellt, welche ähnlich der Kamera-Target Methode mit Bilddaten einer oder mehrerer Kamera(s), die im Heliostatenfeld installiert werden, eine Kalibrierung durchführt. Anstatt die Heliostate auf dem Target zu kalibrieren stellen Bern et al. ein Verfahren vor, bei dem die Ausrichtung der Heliostate periodisch leicht geändert wird [13]. Dabei werden Bildsequenzen aufgenommen. Diese werden mit Hilfe von Bildverarbeitung ausgewertet. Wie bei der Kamera-Target Methode kann dann die Abweichung von Ist- und Soll Position durchgeführt werden. Das Verfahren wurde in Laborbedingungen getestet und kann dort ähnliche Genauigkeiten erzielen wie die Kamera-Target Methode. Die dort erzielten Ergebnisse sind jedoch nicht direkt auf die Praixs übertragbar, da unter realen Bedingungen die Bildaufnahmen direkt auf dem Receiver durch hohe Temperaturen gestört werden können.Bern et al. nutzen zur Zuordnung eine vorgegebene Frequenz, welche außerdem durch Bewegung der Heliostate durch Wind oder Vibration beeinflusst werden kann und somit eine robuste Bildverarbeitung voraussetzt.

Eine weitere Möglichkeit die Kamera-Target Methode zu nutzen, ist es die Heliostate immer auf dem Receiver zu richten und stattdessen eine weitere Strahlungsquelle am Heliostaten zu befestigen, welche immer auf das Target gerichtet ist [14]. Auch hier wird von Flesch et al. eine ähnliche Genauigkeit angegeben. Mit dieser Methode wäre es auch möglich mehrere Heliostate zur selben Zeit zu kalibrieren, indem die einzelnen Spiegel beispielsweise mit Farbfiltern erweitert werden. Dieses Verfahren erhöht jedoch die Kosten eines Kraftwerks. Außerdem müssen bei größeren Feldern zusätzliche Probleme gelöst werden, da dort die sekundären Spiegel, falls alle gleichzeitig auf das Target gerichtet werden, ebenfalls nicht mehr zugeordnet werden können. Von den Autoren wird vorgeschlagen die Spiegel zu verschatten. In einer automatisierten Anwendung müssten dazu zusätzlich weitere Bauteile angebracht werden, wodurch die Kosten weiter ansteigen.

3.6.2 Kamera am Turm

Anstatt den reflektierten Brennfleck auf dem Target auszuwerten, können auch eine oder mehrere Kameras an dem Turm angebracht werden. Mit diesen kann beispielsweise mit Hilfe von Kantenerkennung, die Ausrichtung der Heliostate über die geometrischen Eigenschaften berechnet werden [15]. Damit ein solches Verfahren hohe Genauigkeiten erzielen kann, muss das Heliostat aus verschiedenen Perspektiven erfasst werden. Wird eine Kamera am Turm angebracht, so ist eine einzelne Kalibrierung zeitaufwändig. Um dieses Problem zu lösen und gleichzeitig die Genauigkeit zu verbessern, können die Fotos mit einem unbemannten Luftfahrzeug aufgenommen werden [16]. Außerdem ist es dadurch möglich mehrere Heliostate gleichzeitig zu kalibrieren, auch die zusätzlichen Kosten sind nicht erheblich. Aus Sicht der Bildverarbeitung ist dieses Verfahren jedoch komplexer als Methoden mit klar definierter Kameraposition. Sattler et al. gehen, basierend auf ähnlichen Methode, von einer Genauigkeit zwischen 2-6 $mrad$ aus, womit dieses Verfahren nicht die benötigte Genauigkeit erreichen würde [5].

3.7 Machine Learning

Im Bereich der Klassifizierung und Objekterkennung in Bilddaten haben sich Machine Learning (ML) Ansätze, speziell Convolutional Neural Networks (CNN), in den letzten Jahren immer stärker gegen die analytischen Methoden durchgesetzt [17]. Dies zeigen vor allem die Ergebnisse, die mit den neueren CNN Architekturen bei Datensätzen wie COCO oder ImageNet erzielt werden konnten [18, 19]. In dieser Arbeit werden diese Ansätze sowohl für die Bildverarbeitung, als auch Klassifizierung, beziehungsweise Zuordnung der Brennflecken zu dem Heliostat, eingesetzt.

3.7.1 Transfer Learning

Ein Kalibriervorgang mit der Kamera-Target Methode kann in der Praxis bis zu einer Minute lang dauern. Die Größe der realen Datensätze ist dadurch limitiert und neue Daten zu erheben kann sehr Zeitaufwändig sein. Das zu untersuchende Verfahren soll den Zeitaufwand der Kalibrierung verringern, aber auch den spezifischen Zeitaufwand zur Vorbereitung des Verfahrens niedrig halten. Aus diesem Grund soll das zu untersuchende Verfahren mit möglichst kleinen Datensätzen auskommen können.

'Transfer Learning' ist eine Methode, bei der ein für einen ähnlichen Anwendungsfall trainiertes Modell als Grundlage für das Training genutzt wird [20]. Im Gegensatz zu zufällig oder heuristisch initialisierten Gewichten, ist hierbei der Vorteil, dass die von dem Modell bereits angelernten Muster nur auf das neue Problem angepasst werden müssen. Dadurch ist es möglich, dass ein so trainiertes Modell mit einer geringeren Datenmenge auskommen kann um eine ähnliche Genauigkeit zu erreichen.

Da die Simulation der Bilddateien eine gute Annäherung an die realen Daten liefert, kann ein bereits trainiertes Modell die Anzahl benötigter Realdaten reduzieren. Ebenfalls können Modelle mit Hilfe von Simulationen im Voraus auf bestimmte Eigenschaften eines Kraftwerks eingestellt werden. Beispielsweise können mit Hilfe von 'Transfer Learning' die Form und Größe, der im realen Feld eingesetzten Heliostate, bereits vorher trainiert werden.

3.7.2 Data Augmentation

Eine weitere Möglichkeit Trainingsdaten künstlich zu vervielfältigen ist der Einsatz von 'Data Augmentation' [6]. Bei dieser Methode werden die Input-Daten der Modelle während des Trainings vorverarbeitet. Bei Bilddaten wird beispielsweise häufig die Rotation zufällig abgeändert. So ist es möglich die Größe eines Datensatzes deutlich zu verringern, indem in den Trainingsdaten lediglich eine Rotations-Variation pro Objekt vorgegeben werden muss. Durch eine solche Vorverarbeitung ist es ebenfalls möglich dem Modell einen Bias anzutrainieren, indem zum Beispiel nur ein bestimmter Rotationsbereich angelernt wird.

In dieser Arbeit kann 'Data Augmentation' dazu eingesetzt werden um die Datensätze künstlich zu vergrößern. Es müssen mehrere Heliostate zur gleichen Zeit auf dem Target

abgebildet sein, dazu müsste während der Simulation jedoch für jede mögliche Kombination der Heliostate im Feld eine Simulation durchgeführt werden. Ein weiterer Nachteil hierbei ist es, dass für jede gegebene Anzahl parallel zu kalibrierender Heliostate ebenfalls alle Daten neu simuliert werden müssten. Um das zu vermeiden, können für jedes Heliostat vorbestimmte Positionen auf dem Target simuliert werden. In der Vorverarbeitung des Trainings können die Bilder der einzelnen Heliostate beliebig kombiniert werden. Zum einen wird so der Simulationsaufwand gesenkt und zum anderen können während des Trainings verschiedene Szenarien mit dem gleichen Datensatz abgebildet werden.

Wird das gesamte zu untersuchende Verfahren betrachtet fällt auf, dass bei der Positionsvorhersage, segmentierte Bilddaten verwendet werden müssen. Auch hier kann mit 'Data Augmentation' während des Trainings ein synthetischer Fehler erzeugt werden, um so schon beim Training der Modelle den Fehler der Segmentierung mit zu berücksichtigen. Dadurch wird das Modell schon im Training mit nicht perfekten Input-Daten konfrontiert.

4 Material und Methoden

Aktuell untersuchte Verfahren, die auf Machine Learning oder Bildverarbeitung setzen, versuchen den Verfolgungsfehler mit Hilfe der Vorhersage des Brennflecks auf dem Target zu bestimmen oder die Ausrichtung der Heliostate anhand der Reflektor-Geometrie anzupassen. Dabei wird der Fehler entweder durch den Vergleich der vorhergesagten Position und der ist Position gebildet oder die Vorhersage wird abgeglichen mit dem zu erwartenden Zielpunkt, falls beispielsweise die Ausrichtung eines Heliostaten anahand von Bilddaten gemessen wird. Damit eine Zuordnung von Heliostat und Brennfleck möglich ist muss beim Einsatz dieser Verfahren eine hohe Genauigkeit, im Bezug auf die Bildverarbeitung, erreicht werden um eine eindeutige Zuordnung gewährleisten zu können.

Das zu untersuchende Verfahren soll die auf den Stand der Technik aufbaut und durch Auswertung mehrerer Heliostate zum gleichen Zeitpunkt die Kalibrierdauer verringern. So Ist es auch möglich die Genauigkeit der Kamera-Target Methode beizubehalten. Grundlegend sollen mehrere Heliostate zur gleichen Zeit auf das Target gerichtet werden. Nachdem die Brennflecken auf dem Target segmentiert wurden, soll das zu untersuchende Verfahren die Position des zu dem Brennfleck gehörenden Heliostaten vorhersagen. Die Aufgabe des Neuronalen Netzes wird dabei sein anhand der Form des Brennflecks und weiteren Parametern wie der Sonnenposition, den Ursprung der Reflexion zu finden.

Eine Spiegelung oder Reflexion mit Hilfe eines 'Machine Learning' Ansatzes vorherzusagen wurde bereits in verschiedenen Veröffentlichungen untersucht [21–23]. Ebenfalls wurde gezeigt, dass es möglich ist Distanzen abzuschätzen [24]. Die erzielten Ergebnisse zeigen, dass es möglich ist für stationäre Objekte auch den Ursprung einer Spiegelung herauszufinden, beziehungsweise den Ursprung einer Lichtquelle zu identifizieren.

Bei dieser Methode wird die Position eines Heliostaten im Feld, beziehungsweise der Abstand zum Turm, anhand des Brennflecks vorhergesagt. Die so ermittelte Position wird anschließend zur Zuordnung eines Brennflecks zu einem bestimmten Heliostaten genutzt. Der Vorteil durch die Vorhersage der Position sind vor allem die größeren Toleranzen, welche es ermöglichen eine sichere Zuordnung zu gewährleisten. Die höheren Toleranzen können angenommen werden, da Heliostate auf einer großen Fläche verteilt stehen. Selbst bei einer zufälligen Auswahl kann davon ausgegangen werden, dass diese versetzt im Feld stehen und nicht keine direkten Nachbarn sind. Das bedeutet, dass sowohl die einzelnen Fehler, als auch die gesamte Toleranz dieser Methode, größer sein können. Die größeren numerischen Werte wirken sich auch positiv die Toleranzen bei der Verarbeitung der Daten aus.

Ebenfalls kann in dem Fall einer nicht oder nur teilweise Übereinstimmung der vorhergesagten Position mit einem der Heliostate im Feld eine falsch Zuordnung (False Positive) verhindert beziehungsweise erkannt werden. Während der Kalibrierung kann diese Information genutzt werden um algorithmische Fehler frühzeitig zu vermeiden. Bei diesem Verfahren nicht zugeordnete Heliostate können in einem zweiten Schritt erneut parallel

ausgewertet werden. Sollte auch in dem zweiten Durchgang keine eindeutige Zuordnung möglich sein, können die verbliebenen Heliostate mit der Kamera-Target Methode einzeln kalibriert werden.

Die Methode ist in vier Schritte aufgeteilt. Ebenfalls ist es möglich einzelne Schritte zu kombinieren, um beispielsweise genauere Vorhersagen zu erzielen.

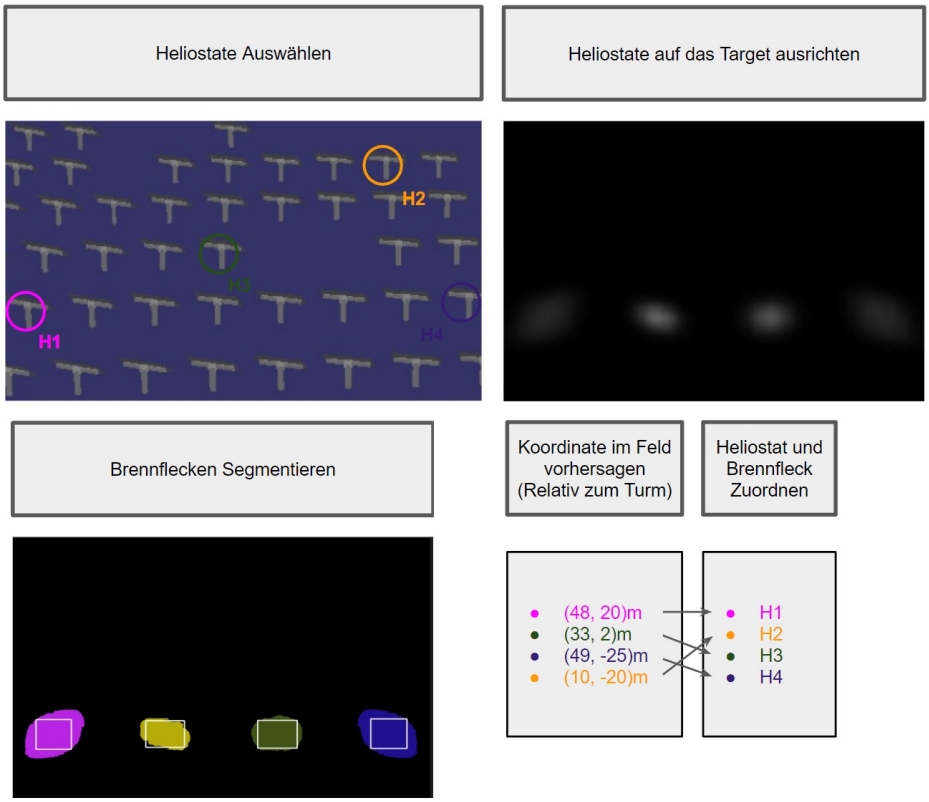

Abbildung 7: Das zu untersuchende Verfahren ist in vier Bereiche unterteilt. Zunächst müssen die parallel zu kalibrierenden Heliostate aus dem Feld ausgewählt und auf das Target gerichtet werden. Dieser Vorgang wird wie bei der Kamera-Target Methode aufgenommen, die Bild-Daten werden für die weiter Verarbeitung segmentiert. Im nächsten Schritt wird für alle segmentierten Brennflecken die Position abgeschätzt. Im letzten Schritt wird, falls möglich, jedem Heliostat ein Brennfleck zugeordnet. Abschließend werden die einzelnen Brennflecken wie bei der Kamera-Target Methode verarbeitet und das zugeordnete Heliostat ausgerichtet.

4.0.1 Auswahl der Heliostate

Im Gegensatz zu der Kamera-Target Methode müssen die Heliostate im Feld vor Beginn der Kalibrierung in Gruppen unterteilt werden. Die Größe der Gruppen wird durch die Anzahl der zur gleichen Zeit auszuwertenden Heliostate bestimmt. Sollen dabei zum Beispiel drei Heliostate parallel ausgewertet werden, so muss das gesamte Feld in dreier Gruppen aufgeteilt werden. In dieser Arbeit werden verschiedene Auswahlverfahren berücksichtigt, dazu gehört die Auswahl nach Zufall und heuristische Verfahren, bei denen die Heliostate nach bestimmten Kriterien ausgewählt werden. Mit einer Heuristik können physikalische Eigenschaften, wie der Abstand der Heliostate untereinander (siehe Abbildung 8) oder aber auch der Abstand zum Turm berücksichtigt werden. Dadurch kann zum Beispiel vermieden werden, dass Heliostate die direkt nebeneinander aufge-

stellt wurden, in dem selben Kalibrierungs-Schritt ausgewertet werden. Wird beispielsweise ein Mindestabstand zwischen den parallel auszuwertenden Heliostaten gewählt, der den durchschnittliche Fehler des Modells übersteigt, kann der Gesamtfehler, wenn eine Normalverteilung angenommen wird, durch die statistische Wahrscheinlichkeit verringert werden.

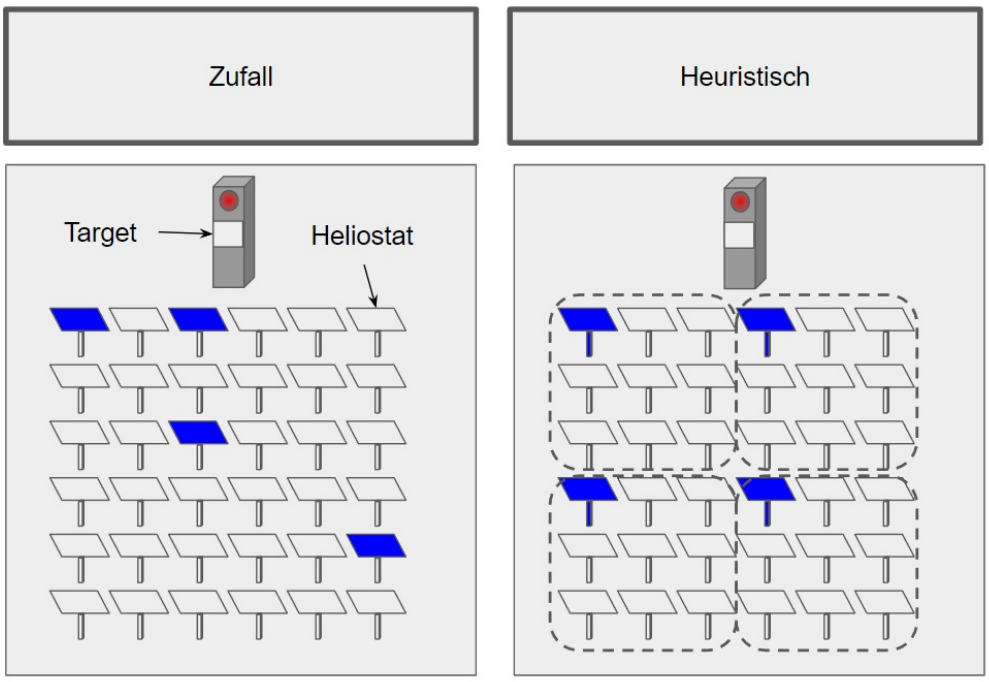

Abbildung 8: Die Auswahl der parallel zu kalibrierenden Heliostate kann nach beliebigen Muster getroffen werden. Auf der linken Hälfte wird schematisch gezeigt, wie vier Heliostate zufällig gewählt wurden. Die ausgewählten Heliostate sind Blau gekennzeichnet. Auf der rechten Seite wird ein heuristisches Verfahren veranschaulicht. In diesem Fall werden die Heliostate in vier gleich große Gruppen aufgeteilt. Für jeden Kalibrationsvorgang wird aus jeder Gruppe ein Heliostat gewählt. So wird in diesem Beispiel sicher gestellt, dass der Abstand zwischen den gewählten Heliostaten konstant bleibt.

Die Methode baut als Grundlage auf der Kamera-Target-Methode auf. Damit können alle Vorteile, aber auch die Nachteile, der in der Praxis eingesetzten Methode beibehalten werden. Durch die parallele Auswertung mehrerer Heliostate kann die benötigte Zeit für die Kalibration des gesamten Feldes deutlich verringert werden. Das bedeutet bei einem Feld von 1000 Heliostaten, einer Kalibrierdauer von einer Minute pro Heliostat und der parallelen Auswertung von drei Heliostaten, rechnerisch insgesamt über 11 Stunden eingespart werden können. Zu beachten ist, dass die Ausfallzeit der Heliostate insgesamt zwar deutlich geringer ausfällt, jedoch der Energieverlust durch die Kalibrierung der gleiche wie bei der normalen Kamera-Target-Methode ist. Das beruht auf der Grundlage der Kamera-Target Methode, da diese nur bei guten Wetterbedingungen durchgeführt werden kann. Es ist auch zu beachten, dass die Kamera-Target Methode eine Abhängigkeit zur Sonnenposition aufweist. Diese entsteht da der Fehler der Ausrichtung nicht linear ist. Beispielsweise kann der absolute Fehler verschiedener Motorstellungen sich unterscheiden. Es ist also von Vorteil wenn mehrere Heliostate in kürzeren Abständen oder gleichzeitig kalibriert werden.

4.0.2 Segmentierung der Brennflecken

Wie auch bei der Kamera-Target Methode müssen die aufgenommenen Bilddaten in der Praxis korrigiert werden, um für alle Bilddaten eine einheitliche Perspektive zu gewährleisten. Für die Kamera-Target Methode ist dieser Schritt wichtig, da die so entstandenen Bilddaten genutzt werden, um die Differenz von dem Zielpunkt zu dem eigentlichen Treffpunkt auf dem Target zu berechnen. Für das zu untersuchende Verfahren ist diese Korrektur ebenfalls nötig, da die Vorhersage der Position mit einer bestimmten Kamera Position, beziehungsweise Perspektive, trainiert werden. Ein weiterer Unterschied zu der Kamera-Target Methode ist, dass die aufgenommenen Bilddaten zusätzlich segmentiert werden müssen. Wie in Abbildung 7 zu sehen ist, sind auf einem Target Bild mehrere Brennflecke zu sehen. Diese müssen segmentiert werden, um zum einen eine Vorhersage in dem nachfolgenden Schritt zu ermöglichen, aber auch um im Anschluss dieses Verfahrens die Abweichung der einzelnen Heliostate zu ermitteln. Die Anpassung der Heliostate erfolgt anhand des gewichteten Mittelpunkts des aufgenommenen Brennflecks. Eine schlechte Segmentierung kann daher zu einer Verringerung der Genauigkeit im Vergleich zu der einfachen Kamera-Target Methode führen.

4.0.3 Ursprung des Brennflecks vorhersagen

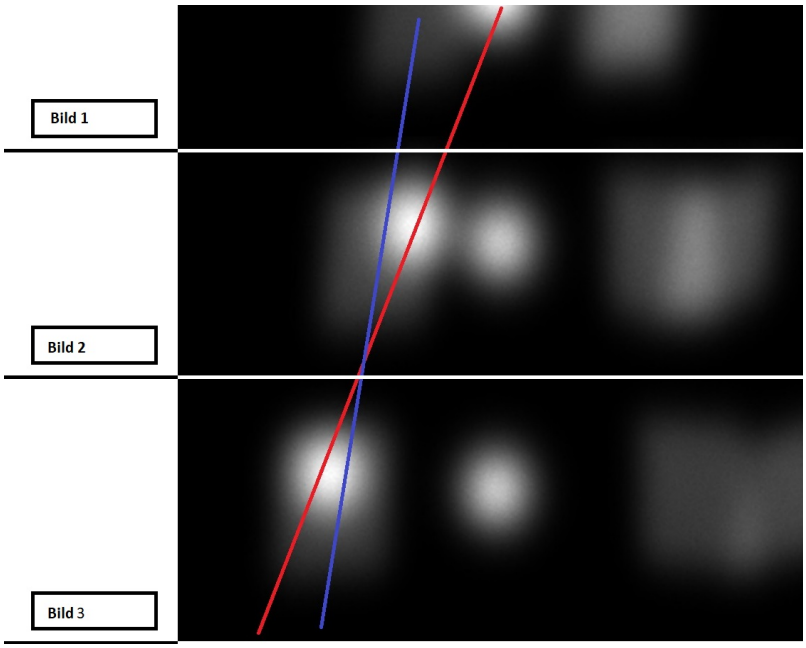

Abbildung 9: Dargestellt wird eine Bildserie, welche bei einem Kalibrierungs-Vorgang entstehen könnte. Es sind vier Brennflecken auf dem Target zu sehen. Die weißen Flecken bilden jeweils einen Brennfleck von einem Heliostaten ab. Die blaue Linie deutet die Laufbahn des ersten Brennflecks und die rote die des zweiten an. Während die Heliostate von dem Receiver auf das Target gefahren wurden, haben die ersten beiden Brennflecken die Position getauscht.

Da in diesem Verfahren mehrere Heliostate zur gleichen Zeit ausgewertet werden sollen, entstehen auf dem Target mehrere Brennflecke. Durch den Verfolgungsfehler kann daher keine direkte Zuordnung von Brennfleck zu Heliostat erfolgen. Abbildung 9 zeigt den Ausschnitt einer Bildserie, bei der zwei Brennflecken die Position tauschen. In die-

sem Fall wurden zufällig zwei Heliostate gewählt, bei denen der tatsächliche Treffpunkt auf dem Target jeweils dem Zielpunkt des anderen Heliostaten entspricht. Aus diesem Grund reicht es nicht aus den Zielpunkt mit dem Treffpunkt des Heliostaten zu vergleichen, um einen Brennfleck zuzuordnen.

Um eine weitere Bewertungsgrundlage zu schaffen wird deshalb ein Modell trainiert, welches anhand der Bildaufnahmen und weiterer Parameter, wie der Sonnenposition oder den Zielpunkten, für jeden Brennfleck eine Ursprungsposition bestimmen soll. Mit Hilfe dieser Position wird im folgenden Schritt eine Zuordnung von Brennfleck zu Heliostat durchgeführt.

4.0.4 Heliostat und Brennfleck zuordnen

Im letzten Schritt müssen die segmentierten Brennflecken und die im ersten Schritt gewählten Heliostate zugeordnet werden. Dazu muss die vorhergesagten Positionen mit den ist Positionen der Heliostate im Feld miteinander verglichen und zugeordnet werden. Diese Zuordnung kann wiederum mit einem Machine Learning Ansatz gelöst werden oder im einfachsten Fall mit einer Threshold Operation, bei der ein Heliostat zu einem bestimmten Brennfleck zugeordnet wird, wenn die Vorhersage eine bestimmte Toleranz einhält. Des Weiteren können Brennflecken, wenn reale Spiegeloberflächen angenommen werden, zusätzlich Informationen über das zugehörige Heliostat enthalten.

4.1 Segmentierung der Brennflecke

4.1.1 Watershed

Die Segmentierung mit der 'Watershed' Methode ist ein analytisches Standardverfahren, welches zum Beispiel in dem Bereich der Mikrobiologie zur Segmentierung von Zellen und ähnlichen aneinander grenzenden Objekten genutzt wird. Bei komplexen Strukturen sinkt bei dieser Methode jedoch die Qualität der Segmentierungsmaske. Ursache dafür ist das zur Grundlage der Segmentierung bestimmte Schwellenwerte angenommen werden. Diese Parameter können bei komplexen Strukturen nicht alle Möglichkeiten abdecken. Mittlerweile werden analytische Methoden daher oft von Machine Learning Ansätzen abgelöst, da diese in der Praxis auf ein breiteres Spektrum ähnlicher Daten anwendbar sind. Analytische Verfahren haben jedoch den Vorteil, dass die Ergebnisse rechnerisch nachzuvollziehen sind und bieten sich somit als Grundlagenvergleich an. In dieser Arbeit wird das Watershed-Verfahren eingesetzt um das Problem grundlegend zu bewerten.

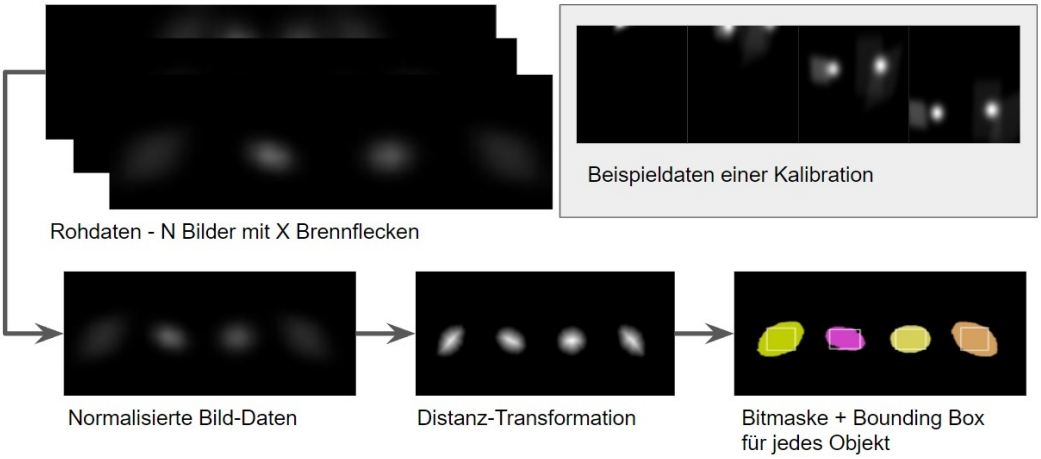

Abbildung 10: Der Ausgangszustand für die Watershed-Segmentation ist die Bildreihe eines Kalibrations-Durchlaufs. In dem Beispiel wurden vier Heliostate parallel auf das Target gerichtet. In Vorbereitung für die Segmentierung wird eine Distanz-Transformation auf die Bilddaten angewendet, um so den gewichteten Mittelpunkt der Brennflecken zu finden. Dazu werden mit einer Schwellenwertoperation die Mittelpunkte von dem restlichen Körper des Brennflecks getrennt. Die so entstehenden Flächen werden als Ausgangspunkte für das Watershed-Verfahren genutzt. Das letzte Bild zeigt die Segmentierten Brennflecken, beziehungsweise die Segmentations-Masken, in unterschiedlichen Farben.

Das verwendete Watershed Verfahren benutzt Marker, mit denen im Voraus zusätzliche Informationen zu Vordergrund- und Hintergrund-Objekten angegeben werden können. Da die vorverarbeiteten Bilddaten normalisiert sind, können für den Hintergrund Nullwerte angenommen werden. Vordergrundobjekte, beziehungsweise Brennflecken, können mit Hilfe von lokalen Maximalwerten angegeben werden (siehe Abbildung 10).

4.1.2 U-Net

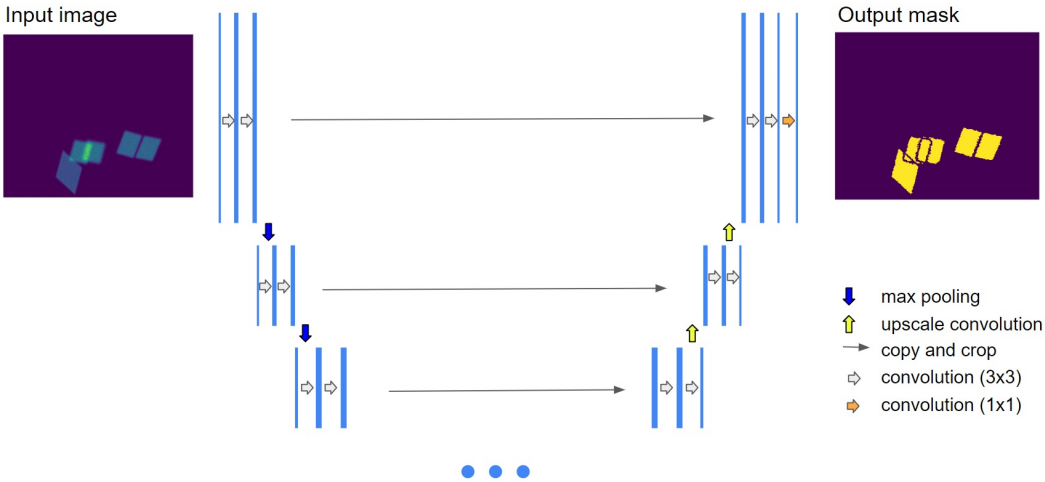

Abbildung 11: Schematischer Aufbau der 'U-Net' Architektur. Die blauen Balken bilden jeweils eine Feature Map ab. Auf der linken Seite ist zu sehen, wie das Eingangsbild Schrittweise auf verschieden große Feature Maps abgebildet wird. Die Eingangsfeature werden in einem zweiten Schritt, in umgekehrter Reihenfolge, wieder auf die Originalgröße hoch skaliert. Um die Segmentierungsmaske zu erhalten, wird am Ausgang zusätzlich eine 1x1 Convolution durchgeführt.

'U-Net' wurde entwickelt um biomedizinische Bilddaten zu segmentieren [25]. Die Architektur ist ein reines CNN, bei dem die Feature Map der Eingangsdaten mit verschieden großen CNN Layern abgebildet wird. Dabei werden die Eingangsdaten schrittweise auf kleinere Feature Maps skaliert. Die so erzeugten Feature Maps werden in einem weiteren Schritt, in umgekehrter Reihenfolge, wieder auf die Originalgröße hoch skaliert. Die erzeugte Segmentierungsmaske ordnet dabei jeden einzelnen Pixel eine Klasse zu. Im einfachsten Fall wird binär zwischen Vordergrund und Hintergrund unterschieden.

4.2 Versuchsaufbau

4.2.1 Datensätze

Für die Evaluation sind verschiedene Datensätze vorgesehen (siehe Kapitel 3.5) die mit dem Raytracer STRAL erzeugt werden. Die Auswertung sieht dabei sowohl homogene als auch reale Oberflächen vor. Aufgrund der Einschränkungen der genutzten Simulationssoftware können die realen Oberflächen nicht mit einem zusätzlichen Verfolgungsfehler versehen, wodurch diese ausschließlich für die Segmentierung berücksichtigt werden können.

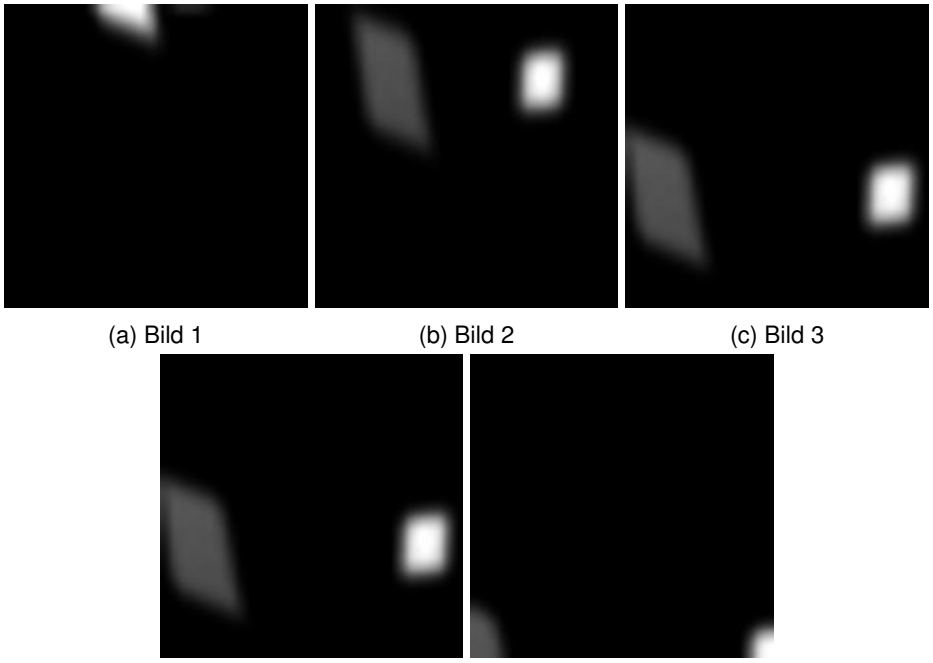

(a) Bild 1 (b) Bild 2 (c) Bild 3

(d) Bild 4 (e) Bild 5

Abbildung 12: Die Video- und Bild-Daten werden in Graustufen bereitgestellt. Die Werte der einzelnen Punkte bilden die relative Helligkeit, bezogen auf die höchst gemessene im Bild, ab. Die Ausmaße beider Heliostate sind gleich, daher ist die Größe und Helligkeit des Brennflecks direkt proportional zu dem Abstand von Heliostat zu Turm. Der kleinere Hellere Brennfleck ist von einem Heliostat weiter vorne im Feld. Dargestellt ist ein Kalibriervorgang mit fünf Einzelbildern, wobei zwei Heliostate parallel ausgewertet werden. Die beiden rechteckigen Objekte bilden jeweils die Spiegelung eines Heliostats auf dem Target ab. In diesem Fall wurden die Heliostate von dem Receiver, welche zuvor auf den Receiver gerichtet waren, auf jeweils eine der unteren Ecken des Targets ausgerichtet.

STRAL bietet eine TCP Schnittstelle, mit der verschiedene Funktionen des Raytracers

automatisiert durchgeführt werden können. Dazu gehört die Erzeugung einer Flussdichte-Datei, aus der die Bilddaten abgeleitet werden (siehe Abbildung 12). Diese Datei beinhaltet die bereits kombinierten Ergebnisse aller Brennflecken. Um den Zusammenhang der Brennflecken zu einem bestimmten Heliostat beibehalten zu können, muss die Simulation jedes Heliostaten einzeln durchgeführt werden.

Dazu wurde ein Programm erstellt, welches es ermöglicht, über die bereitgestellte Schnittstelle, MxN Heliostate nacheinander auf dem Feld zu platzieren. Für jedes platzierte Heliostat werden, für jeden zu simulierenden Sonnenstand, Serienbilder aufgenommen. Jedes Einzelbild in einer Serie gehört zu einer Zielposition auf dem Target (siehe Abbildung 12). In dem gezeigten Beispiel sind als Zielpunkte die untere linke und rechte Ecke des Targeets gewählt worden. Es wird bei der Simulation jede mögliche Zielposition sämtlicher Heliostate aufgenommen. Bei einer größeren Anzahl von Brennflecken, werden diese auf den unteren Rand des Targets gerichtet, wobei der Abstand aller benachbarten Zielpunkte einheitlich gewählt wird.

Um mit den so erstellten Flussdichtekarten einen Kalibriervorgang abbilden zu können, werden parallel zu kalibrierende Heliostate aus dem Feld gewählt. Für jedes Einzelbild werden die Fluxdaten aller gewählten Heliostate summiert. Die so entstandenen Einzebilder werden im letzte Schritt normalisiert und können anschließend im Training der Modelle oder zur Auswertung genutzt werden. Durch die Simulation der Fluxdaten jedes einzelnen Heliostaten ist es zum einen möglich alle Heliostate im Feld frei miteinander zu kombinieren, ohne eine neue Simulation durchführen zu müssen. Des Weiteren können die Flussdichtekarten eines einzelnen Heliostaten genutzt werden um die Genauigkeit der Segmentierung bewerten zu können.

4.2.2 Simulierter-Fehler

Die mit STRAL simulierten Datensatze basieren auf einem Monte Carlo Raytracing Verfahren, demnach sind auf den Ergebnisbilder die Brennflecken immer an dem zu erwartenden Zielpunkt. Damit der auftretende Verfolgungsfehler der Heliostate simuliert werden kann, muss eine Abweichung der ausgerichteten Spiegeloberfläche während der Simulation eingeführt werden. Dieser Fehler wird simuliert, indem die Ausrichtung der Achsen zufällig mit einen kleinem Fehler gestört wird.

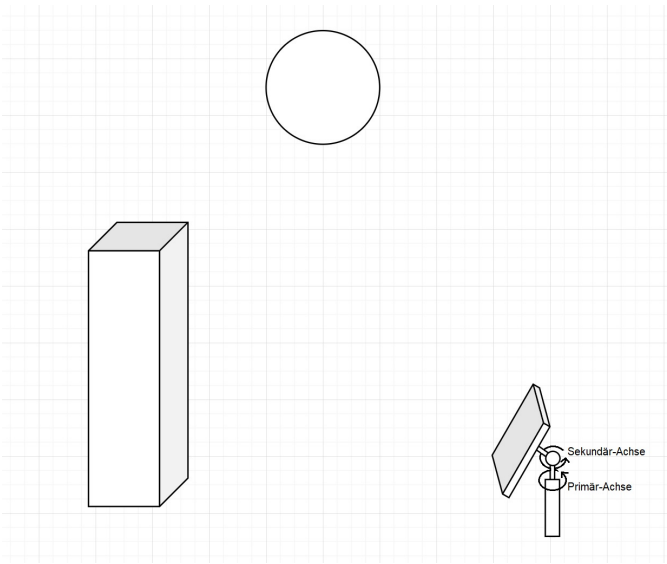

Abbildung 13: Um einzelne Heliostate ausrichten zu können sind die Spiegel an beweglichen Achsen befestigt.

Der in der Simulation eingeführte Fehler bezieht sich nicht auf eine bestimmte Fehlerquelle und bildet den größten Einfluss auf das Zielverhalten in der Praxis ab. Wie bereits in den Grundlagen beschrieben, können in der Praxis weitere Fehler auftreten, die dieses Verfahren beeinflussen. Dazu gehört unter anderem die fehlerhafte Fokussierung (canting) der einzelnen Facetten eines Heliostats.

Um diesen Fehler in der Simulation abzubilden wird in STRAL, mit Hilfe einer Transformationsmatrix, die Ausrichtung der Heliostate während der Simulation gestört. Die Größe der Abweichung der einzelnen Achsen wird dabei zufällig ausgewählt. Dazu wird bei dem Start der Simulation, für jede zu simulierende Position im Feld, ein spezifischer Fehler erzeugt. Die Achsen werden dabei von 0 bis 9 $mrad$ zueinander verkippt, ebenfalls wird die Oberfläche im Verhältnis zur Sekundär-Achse verkippt (siehe Abbildung 13). So wird jedes Heliostat mit einer individuellen Toleranz simuliert. Diese Anpassung bewirkt, dass auf dem Target der Mittelpunkt des simulierten Brennflecks eine andere Position trifft, als die angezielte Position. Alterung und damit eingehende Änderungen der Oberflächen können dabei nicht direkt berücksichtigt werden.

4.2.3 Homogene Oberfläche

Als Homogene Heliostaten-Oberfläche werden in dieser Arbeit Flächen mit einer perfekten Spiegeloberfläche bezeichnet. Die Heliostate haben trotzdem eine leicht konkave Form, damit die eintreffende Sonnenstrahlung auf einen Punkt konzentriert wird. Ein weiterer Vorteil dieser Krümmung ist der damit eingehende kleinere Brennfleck auf dem Target in Relation zur Größe der Spiegeloberfläche. Die Fehler der Motorstellungen wird wie oben beschrieben auch bei diesen Datensätzen angewendet. Bei Verwendung homogener Oberflächen gehen Features verloren, die während der Bildverarbeitung genutzt werden könnten (siehe Abbildung 14).

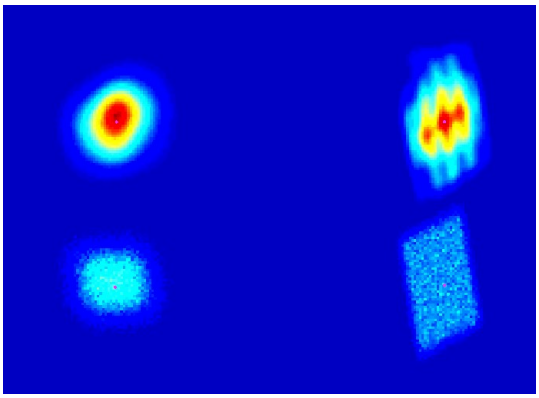

Abbildung 14: Verglichen werden verschiedene Brennflecken, die mit dem Raytracer STRAL erzeugt wurden. Die unteren Brennflecken wurden mit einer homogenen Spiegeloberfläche simuliert. Bei den oberen Brennflecken wurden vermessene Oberflächendaten von Heliostaten aus dem Turmkraftwerk in Jülich verwendet. Die Brennflecken auf der rechten Seite haben einen Abstand von 25m zu dem Turm, während die Heliostate auf der linken Seite mit einen Abstand von 171m aufgestellt wurden.

Bei den in dieser Arbeit dargestellten Bilddaten ist außerdem zu berücksichtigen, dass die Brennflecken der weiter entfernt stehenden Heliostate kleiner wirken können. Das liegt vor allem an den numerisch großen Unterschieden der einzelnen Fluxwerte. Abbildung 15 zeigt den Vergleich der Segmentationsmaske zu der bildlich dargestellten Flussdichteverteilung. Die Werte am Rand eines Brennflecks sind numerisch deutlich kleiner. Bei der Abbildung des Brennflecks, mit einer 8 Bit Farbtiefe, kommt es daher zu vielen Werten nahe null.

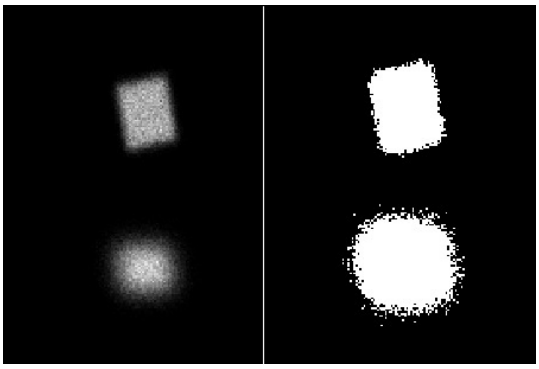

Abbildung 15: Links gezeigt wird die bildliche Darstellung der Brennflecken auf dem Target. Auf der rechten Seite werden die tatsächlichen Segmentationsmasken der Brennflecken gezeigt. Diese bilden alle Werte ab, welche größer Null sind.

4.2.4 Reale Oberfläche

Für die Simulation realer Oberflächen werden ausgemessene Oberflächendaten (Deflektometrie Daten) von Heliostaten aus dem Feld des Jülicher Solarturmkraftwerks genutzt. Die Position im Feld und die Deflektometrie Werte sind dabei genau wie im echten Feld in Jülich eingestellt. Die einzige Variable bei diesen Daten ist die sich ändernde Sonnenposition. Statt real aufgenommener Bilddaten werden diese simulierten Bilddaten eingesetzt, da der zeitliche Aufwand für die Aufnahme realer Daten zum Training der zu untersuchenden Methode zu hoch wäre. Ebenfalls können bei Simulationsdaten viele

Umwelteinflüsse wie Verschattung durch Wolken ausgeschlossen werden und somit eine bessere Vergleichbarkeit der verschiedenen Datensätze garantieren.

Datensatz	Beschreibung	Heliostate	Sonnenstände
Training / Validation	Homogene Oberfläche	1000	250
Evaluation 1	Homogene Oberfläche	200	50
Evaluation 2	Homogene Oberfläche	200	50

Tabelle 1: Tabellarische Dastellung der eingesetzten Simulationsdaten. Die Heliostate sind in allen Datensätzen mit unterschiedlichen Fehlern versehen. Die Evaluationsdatensätze unterscheiden sich durch die platzierung der Heliostate im Feld (unterschiedliche Positionen) und der Größer der Spiegeloberfläche.

4.3 Netzwerke zur Auswertung der Position

Um den Ursprung der Heliostate zu finden, der einen bestimmten Brennfleck auf dem Target verursacht, stehen verschiedene Daten zur Verfügung. In der Evaluation werden die Bilddaten (beziehungsweise Fluxdaten), Sonnenposition, Heliostatposition, Feldgröße, Zielpunkt, Treffpunkt und die Anzahl der Einzelbilder berücksichtigt. Der Treffpunkt bezieht sich hierbei auf den berechneten Mittelpunkt eines segmentierten Brennflecks.

Die verschiedenen Daten können in zwei Kategorien unterteilt werden. Die Bilddaten bilden die erste Kategorie und alle anderen Daten werden unter der Kategorie tabellarische Daten zusammengefasst. Diese beiden Kategorien unterscheiden sich vor allem in der quantitativen Anzahl der Werte. Würden beispielsweise Bildaten mit 512x512 Pixeln eingesetzt werden und 30 Werte für die tabellarischen Daten, so würden die tabellarischen Daten nicht einmal einen Prozent ausmachen.

In einem klassischen CNN würden aus allen gegebenen Daten zunächst die Feature extrahiert werden und danach anhand dieser eine Klassifikation beziehungsweise Regression vorgenommen werden. Der quantitative Unterschied der Inputdaten erzeugt in einem solchen Fall eine starke Bias zu Datensätzen mit der größten Datendichte. Um dieses Problem zu umgehen kann die Gewichtung der Daten angepasst werden. Dies hat den Nachteil, dass während des Trainings die Gewichtung statisch bleibt und diese iterativ angepasst werden muss um eine optimale Gewichtung zu finden. Es ist ebenfalls möglich durch eine Vorverarbeitung die Daten in eine alternative Form zu überführen. 'Data Fusion' wird in verschiedenen Teilbereichen angewendet und kann auch mit Hilfe von neuronalen Netzen abgebildet werden [26].

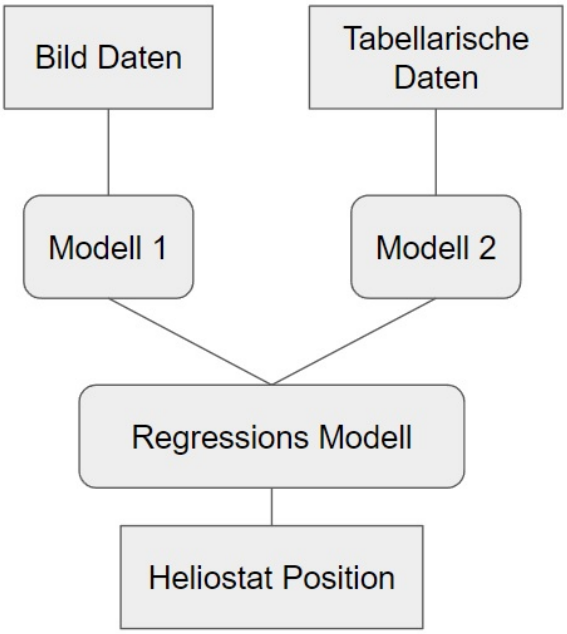

Abbildung 16: Schematische Darstellung der eingesetzten parallelen Architektur. Die Bild- und Tabellarischen-Daten werden parallel von zwei unterschiedlichen Modellen bewertet. Die Outputs der einzelnen Modelle werden im Anschluss von einem Regressionsmodell bewertet. Im letzten Schritt kann, über eine lineare Aktivierung, die Position des Heliostaten ausgegeben werden.

Um dieses Problem zu umgehen wurde in dieser Arbeit eine parallele Architektur gewählt. Bei diesem Ansatz wird für jedes zu lösende Problem ein Expertenmodell eingesetzt [27]. Ein Expertenmodell ist dabei nur auf ein bestimmtes Problem spezialisiert. Zusätzlich muss ein weiterer Schritt eingeführt werden, in dem die Outputs der einzelnen Expertenmodelle bewertet und dementsprechend ausgewählt werden. Ebenfalls ist es möglich die Outputs ohne weitere Bewertungen aneinander zu reihen. Für jede gegebene Daten-Kategorie wird ein eigenes Modell trainiert, wobei der Output der einzelnen Modelle zusammen an einen Klassifikator übergeben werden. Dadurch ist es möglich, dass die einzelnen Modelle nur eine spezielle Kategorie abbilden müssen. Jedoch können die Ergebnisse der einzelnen Modelle durch die Backpropagation während des Trainings auch Einfluss auf die anderen parallel agierenden Modelle haben. Die nachfolgenden Modelle werden zur Auswertung der Flussdichte-Daten genutzt. In Abbildung 16 steht 'Modell 1' analog für diese.

4.3.1 Einfaches CNN

Das erste genutzte Modell ist ein einfaches CNN welches hier als Grundlagenvergleich genutzt wird. Das Modelle besteht aus zwei einzelnen Netzwerken. Das erste ist für die Analyse der Bilddaten verantwortlich und das zweite verarbeitet die tabellarischen Daten wie Sonnenposition und Zielpunkt. Das Netzwerk zur Verarbeitung der Bilddaten besteht aus vier Convolutional Layern mit steigender Filtergröße, die für die Feature Extraction genutzt werden. Nach diesen folgt ein Max Pool Layer um die Datendichte zu verringern. Der Ouput des Max Pool Layers wird auf eine Dimension reduziert und final in ein Dense

Layer mit 256 Output Knoten übergeben.

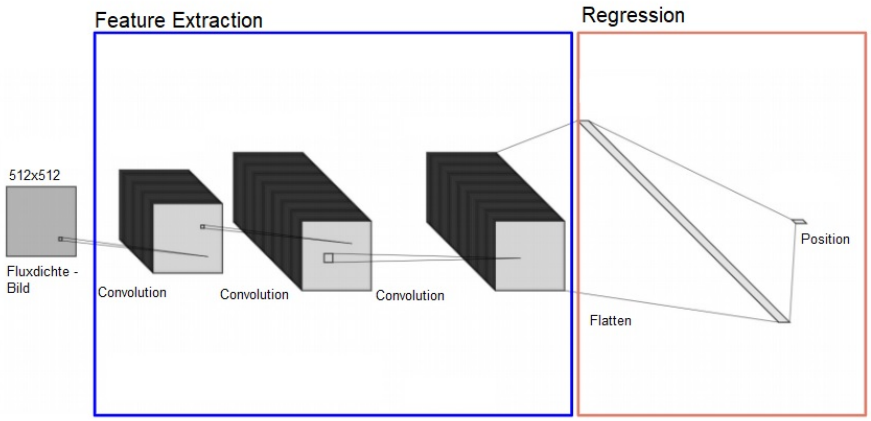

Abbildung 17: Schematische Darstellung des für die Evaluation genutzten einfachen CNN zur Auswertung der Bilddaten. Das Modell ist in zwei Bereiche aufgeteilt, zuerst werden die Features des Bildes extrahiert. Im zweiten Schritt werden die mehrdimensionalen Feature Maps auf eine Dimension verringert. Im letzten Schritt wird mit einer Regression die Position vorhergesagt.

Das Netzwerk zur Auswertung der tabellarischen Daten ist ein einzelnes Dense Layer mit 256 Output Knoten. Das Ergebnis beider Modelle wird in ein weiteres Dense Layer gespeist welches die Ergebnisse auf zwei Werte mit einer linearen Aktivierung reduziert bei dem der Input unmodifiziert an den Ausgang übergeben wird.

4.3.2 DenseNet

DenseNet ist Stand der Technik und wird hauptsächlich in der Bildverarbeitung eingesetzt [28]. Im Unterschied zu einfachen CNN Modellen, bei denen die Convolution Layer in Reihe geschaltet sind, werden die Convolution Layer bei DenseNet alle direkt mit einander verbunden. Dieser Ansatz soll vor allem Problem lösen, dass bei sehr tiefen CNN Modellen die originalen Input-Informationen verloren gehen beziehungsweise verwischt werden. Iandola et al. zeigte, dass so ein kleineres Modell erstellt werden kann, welches trotzdem mit den gängigen State of the Art Modellen mithalten kann [28]. In dieser Arbeit wird diese Architektur als Vertreter für moderne Feature Extraction Layer genutzt um so einen Einblick zu bekommen, wie das Problem von aktuell bestehenden Modellen Abgebildet wird.

4.3.3 Generator (StyleGAN)

'Generative Adversarial Network' (GAN) ist eine Architektur, bei der zwei verschiedene Modell zusammen arbeiten. Das erste Netzwerk (Generator) erstellt dafür zu bewertende Kandidaten [29]. Das zweite Modell (Discriminator) bewertet diese Kandidaten anhand der vorgegebenen Datensätze. Das Ziel des Generators ist es, Daten zu erzeugen, welche der Discriminator nicht mehr von den vorgegebenen Daten unterscheiden kann.

Für diese Arbeit wird nur der Generator von StyleGAN betrachtet [30]. Um zusätzliche Informationen beim generieren der Kandidaten berücksichtigten zu können, fließen zusätzliche Informationen bei jedem Convolution Layer erneut in die Berechnung des neuen Outputs mit ein. Bei den anderen Modellen, wie dem einfachen CNN, werden die Tabellarischen Daten und die extrahierten Features der Bilddaten mit Hilfe eines Dense Layers von dem Modell, während des Trainings bewertet und als neue kombinierte Feature Map an das Regressions Netz zur Auswertung der Position gegeben.

Anstatt diese Bewertung durch ein extra Layer am Ende des Modells durchzuführen, kann eine ähnlicher Ansatz wie beim StyleGan Generator genutzt werden, indem die tabellarischen Daten direkt bei der Feature Extraction der Bilddaten über die Inputs der einzelnen Convolution Layer eingebunden sind.

4.3.4 Recurrent Neural Network (RNN)

Die vorgestellten Modelle sind alle nur in der Lage ein einzelnes Bild zu verarbeiten. Um diese Netzwerke auch auf Bildreihen anwenden zu können wird eine Recurrent Neural Network (RNN) Architektur genutzt [31]. Bei dieser Architektur ist der Input direkt mit dem Output des vorherigen Knotens verknüpft und kann so das Ergebnis des vorherigen Knotens bei der Berechnung des nächsten Outputs mit einbeziehen. Hauptsächlich wird diese Technik bei Datensätzen angewendet, bei denen die einzelnen Datenpunkte über eine Zeitlinie miteinander verknüpft sind. Ein Beispiel dafür sind Probleme wie die Erzeugung von automatischen Übersetzungen, dabei ist jedes Wort von dem vorherigen abhängig und in Kontext zu setzen.

Auch auf Bildreihen kann diese Technik angewendet werden. Die in dieser Arbeit genutzten Datensätze bilden jeweils einzelne Kalibriervorgänge ab, bei denen die Heliostate von dem Receiver auf das Target gerichtet werden. Bei diesem Vorgang wird eine Bildreihe angefertigt. Auch hier sind die Bilder jeweils von dem vorherigen abhängig und der Bewegungsverlauf kann weitere Informationen über die Brennflecke enthalten.

Eingesetzt wird ein erweitertes RNN bei dem ein zusätzlich paar Gates eingeführt werden. Eine 'Gated recurrent unit' (GRU) nutze zwei Gates, welche für das übernehmen oder vergessen von Informationen zuständig sind [32]. Das erste Gate ist für Updates zuständig und entscheidet welche Informationen von dem Vorherigen Knoten zum nächsten weitergegeben werden sollen. Dadurch kann das Modell entscheiden ob nur ein Teil oder alle Daten des vorherigen Zustands beibehalten werden und versucht so zu verhindern, dass durch zu viele Zeitschritte die Informationen der ersten Schritte weniger stark priorisiert werden. Das zweite Gate entscheidet welche Informationen vom vorherigen Schritt ignoriert werden sollen, da diese zum Beispiel keinen Einfluss auf den kommenden Schritt haben.

4.4 Auswertung der Daten

Nachdem die Brennflecken segmentiert wurden und von dem nachfolgenden Modell eine Position vorhergesagt wurde, muss im letzten Schritt eine Zuordnung erfolgen. Dazu

wird die Ist Position der zu kalibrierenden Heliostate mit der vorhergesagten Position der Spiegelung des Brennflecks verglichen.
Für diesen Vergleich wird zunächst ein heuristisches Verfahren genutzt, bei dem die Zuordnung über die minimale euklidische Distanz der Ist-Position zur vorhergesagten Position abgebildet wird. Es werden keine weiteren Parameter während der Zuordnung berücksichtigt.

Bei der Zuordnung eines Kalibriervorgang werden die Abstände der vorhergesagten Positionen zu den Ist-Positionen der zu kalibrierenden Heliostate, zunächst sortiert. Dazu wird für jede Ist-Position eine Liste mit Abständen erstellt. Aus dieser Liste werden im zweiten Schritt alle Einträge aussortiert die einen vorgegebenen Schwellenwert überschreiten. Der Schwellenwert wird für jedes Modell anhand des durchschnittlichen Fehlers ermittelt, so soll statistisch die Wahrscheinlichkeit einer falschen Zuordnung gering gehalten werden.
Alle Listen, die nach Anwendung der Schwellenwertoperation nur noch einen Eintrag enthalten, werden als positive Zuordnung gewertet. Dazu wird das Heliostat dem Brennfleck, der zu dem vorhergesagten Wert in der Liste gehört, zugeordnet.
Listen bei denen kein Element übrig geblieben ist, oder mehr als ein Element gelistet ist, werden als nicht zuordenbar eingestuft. Das führt dazu, dass selbst wenn die Zuordnung eines Brennflecks zu einem Heliostat nach den obigen Regeln erfolgt, der selbe Brennfleck jedoch auch potentiell zu einem anderen Heliostat zugeordnet werden könnte. In diesem Fall werden beide Brennflecken/Heliostate als nicht zuordenbar eingestuft wird. Durch diese strenge Einschränkung sollen 'False Positives' verhindert werden, da diese bei der praktischen Anwendung des Verfahrens Fehler während der Kalibration verschleiern könnten. Die Methode tendiert damit zum klassifizieren von 'False Negatives', verhindert jedoch größtenteils 'False Positives'.

Das vorgestellte Verfahren wertet das Heliostatenfeld in zufälliger Reihenfolge aus. Die Auswahl der parallel zu kalibrierenden Heliostate hat einen großen Einfluss auf das Ergebnis des gesamten Verfahrens. Erfolgt die Auswahl zufällig könnten Heliostate gewählt werden, welche im Feld direkt nebeneinander aufgestellt sind. Die vorhergesagte Position des eingesetzten Modells muss dann eine Toleranz einhalten, die kleiner ist als der halbe Abstand zwischen zwei Heliostaten. Würden beispielhaft direkt benachbarte Heliostate 3m auseinander stehen, so müsste das Modell eine durchschnittliche Genauigkeit von unter 1.5m erreichen, damit eine eindeutige Zuordnung möglich wäre.

Wird zum Beispiel ein Feld mit 100 Heliostaten angenommen, bei dem jedes einen Abstand von 3m zu allen direkten Nachbarn hat, so würde, bei einer Kalibration mit fünf parallelen Heliostaten, der minimale Abstand zwischen zwei Heliostaten $3m * 5 = 15m$ betragen. Durch dieses heuristische Auswertungsverfahren muss das eingesetzte Modell eine durchschnittliche Genauigkeit von unter 7.5m erreichen, damit eine eindeutige Zuordnung möglich ist. In dem gezeigten Beispiel kann die Toleranz durch das angepasste Auswahlverfahren fünf mal größer sein.

4.5 Bewertungskriterien

Die Evaluation ist aufgeteilt in die Teilbereiche Segmentierung, Vorhersage der Spiegelposition eines Brennflecks und die Zuordnung eines Brennflecks zu einem der gegebenen Heliostate. Nachfolgend wird auf die primären Bewertungskriterien eingegangen, auf denen die gezeigten Ergebnisse aufbauen.

4.5.1 Segmentierung

Der erste Teilbereich umfasst die Segmentierung der Brennflecke auf dem Target. Dabei wird als Metrik die 'Intersection over Union' (IoU) mit den Groundtruth Daten als Hauptkriterium eingesetzt.

$$IoU = \frac{\text{area of overlap}}{\text{area of union}}$$

Die Abdeckung wird in Prozent angegeben, wobei 100% für eine perfekte Abdeckung der beiden Flächen steht.

Ein weiteres Kriterium für die Segmentation ist die Differenz der relativen Intensitätswerte des segmentierten Brennflecks und dessen Groundtruth Daten. Die von den Heliostaten reflektierte Strahlung wird auf einen Punkt fokussiert, dadurch ist auch die Intensität in der Mitte des Brennflecks am höchsten. Vor allem bei realen Spieloberflächen führt dazu, dass der Großteil der reflektierten Strahlung und damit auch die meiste Energie im Zentrum des Brennflecks konzentriert wird. Da diese Werte relativ im Bezug auf die hellste Stelle im Bild sind, kann so die IoU mit der Intensität abgeglichen werden. Diese Metrik soll zeigen wie viel Prozent der effektiven Strahlung nicht von der Segmentierungsmaske abgedeckt wird und somit auch nicht zu der Kalibrierung beitragen kann. Abbildung 18 zeigt die Fluxdichteverteilung eines simulierten Heliostaten aus dem Jülicher Feld. Eine Segmentationsmaske, bei der nur knapp ein drittel des eigentlichen Brennflecks segmentiert wurde bildet dabei, aufgrund der Strahlenveritelung, über zwei drittel der reflektierten Strahlung ab.

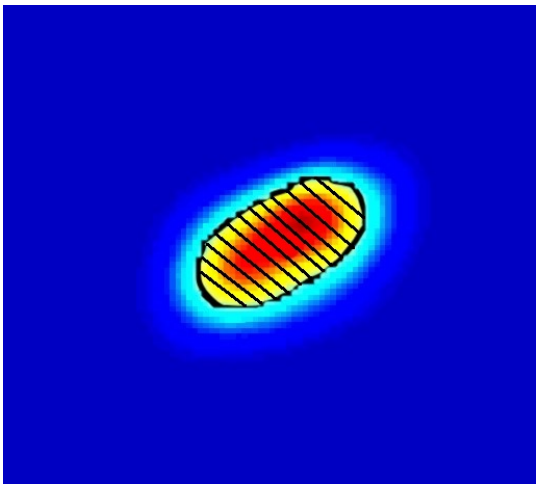

Abbildung 18: Darstellung eines Brennflecks, welcher durch ein Heliostat des Jülicher Felds auf dem Target hervorgerufen wurde. Die Intensität, beziehungsweise die Anzahl der eintreffenden Strahlung ist farbig dargestellt, wobei die höchst gemessenen Werte mit Rot abgebildet sind. Die Schwarze Markierung zeigt Beispielhaft den Rahmen einer möglichen Segmentationsmaske, welche circa 30% der Fläche des Brennflecks abdeckt.

4.5.2 Vorhersage der Position

Der zweite Teilbereich ist die Zuordnung des Brennflecks zu einem bestimmten Heliostat. Für diesen Schritt wird die Genauigkeit des Netzwerks angegeben, dass für die Abstandsvorhersage zuständig ist. Diese wird als Mean Squared Error (MSE) angegeben. Die Modelle sollen die Position, in Relation zum Turm, im Feld vorhersagen. Der MSE hat den Vorteil, dass größere Abweichungen zu einer quadratisch schlechteren Bewertung führen, wodurch hohe Ausreißer vermieden werden können. Dadurch, dass bei dieser Bewertung eine absolute Position vorhergesagt wird, kann die Wurzel aus dem MSE Rückschluss auf die durchschnittliche Abweichung in Metern geben. Der MSE wie folgt berechnet wird:

$$MSE = \sum_{i=1}^{n} (x_i - y_i)^2$$

Wird der MSE um eine Wurzel erweitert, kann die euklidische Distanz ermittelt werden:

$$d(x, y) = \sqrt{\sum_{i=1}^{n} (x_i - y_i)^2}$$

Zu beachten ist, dass bei veränderter Gewichtung in der Verlustfunktion während des Trainings die euklidische Distanz zwischen zwei Punkten nicht mehr mit dem MSE gleich zu setzen ist.

4.5.3 Zuordnung

Um die Genauigkeit des gesamten Verfahrens zu bewerten, werden 100 Kalibrationsvorgänge, mit jeweils fünf Heliostaten parallel, durchgeführt. Dazu werden 100 Kalibrationen simuliert, für die das gewählte Modell jeweils fünf Vorhersagen machen muss. Anhand dieser Vorhersage wird das Zuordnungsverfahren, wie in der Methodik beschrie-

ben, durchgeführt. Als Metrik wird dabei die Anzahl korrekt zugeordneter Brennflecke aufgenommen. Bei 100 Kalibrationsvorgängen mit jeweils drei Heliostaten würden 300 richtig zugeordnete Brennflecke eine Genauigkeit von 100% repräsentieren.

5 Ergebnisse

5.1 Segmentierung

5.1.1 Watershed

Datensatz	Durchschnittliche IoU	Gewichtete durchschnittliche IoU
Homogene Oberfläche	0.73	0.72
Reale Oberfläche	0.58	0.71

Tabelle 2: Qualitativer Vergleich der Segmentations-Maske beider gewählter Oberflächenbeschaffenheiten. Bei der gewichteten IoU wird die Fluxdichte, welche durch die Segmentationsmaske eingeschlossen werden, mit einbezogen.

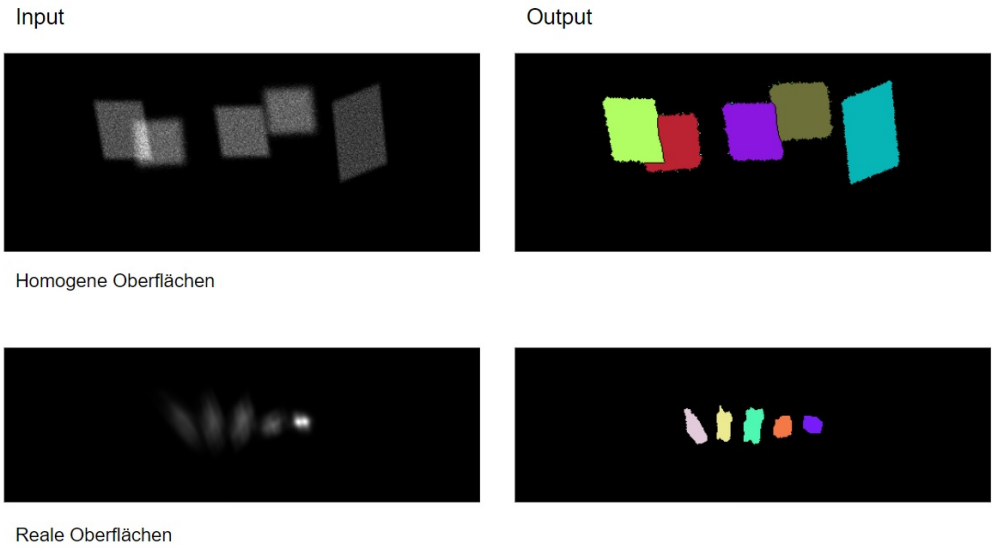

Abbildung 19: Beispielhafte Segmentierung von jeweils einem Bild mit realen und einem mit homogener Oberfläche.

Die Watershed Methode erzielte die angestrebte Genauigkeit für die Simulationsdaten mit homogener Spiegeloberfläche. Wie Tabelle 2 zu entnehmen ist, kommt die Methode auf eine IoU von über 70%. Wird das Verfahren auf den Datensatz mit realer Oberfläche angewendet ist die erreichte IoU im Durchschnitt 10% niedriger. Ebenfalls zeigt sich, dass durch die im Watershed Algorithmus vordefinierten Schwellenwerte, das Verfahren nicht gut auf neue Datensätze anzuwenden ist ohne dabei diese anzupassen. Für die in der Tabelle dargestellten Ergebnisse mussten die Schwellenwerte manuell optimiert werden, um die gezeigten Ergebnisse erreichen zu können.

Ein Problem, welches nicht durch die gezeigten Ergebnisse abgedeckt wird, ist der Fall wenn zwei Brennflecken überlappen und nach der Segmentierung als ein einzelner Brennfleck erkannt werden. Bei der Auswertung fehlt in diesem Fall ein Treffpunkt. Zusätzlich kann dieser dazu führen, dass dabei das falsche Heliostat mit dem Brennfleck in Verbindung gebracht wird. Dies kann im letzten Schritt der Zuordnung nicht nachvollzogen werden und führt zu einem False Positive.

5.2 Bildauflösung

Bildauflösung	Training MSE	Validation MSE	Evaluation MSE
512x512	50.83	67.29	81.86
256x256	85.15	105.83	110.82
128x128	87.21	140.31	181.33
64x64	137.10	149.09	188.29
32x32	179.19	218.15	270.99

Tabelle 3: Einfluss der Bildauflösung. Die Bildauflösung ist in Punkten angegeben.

Die Originalen Bilddaten aus der Simulation werden mit einer Auflösung von 512x512 Bildpunkten erzeugt. Um die Parameterdichte der Modelle zu reduzieren und damit auch die Trainingsdauer und die dafür benötigte Menge der Bilddaten zu verringern, kann die Auflösung runter skaliert werden. Durch die Komprimierung der Bilddaten entstehen Verluste, die sich ebenfalls auf die Feature-Dichte der CNN Layer auswirken kann. Die Bilddaten wurden für diesen Vergleich mit einem bilinearen Filter skaliert. In Tabelle 3 wurden die erzielte Genauigkeit im Bezug auf verschiedene Auflösungen getestet. Dazu wurden vier skalierte Größen mit der originalen Auflösung verglichen. Bei Reduzierung der Auflösung auf 128x128 Pixel und weniger, kann jedoch ein Qualitätsverlust der trainierten Modelle beobachtet werden. Der Trainingsverlauf spiegelt dies ebenfalls. Die Reduktion auf 25% der originalen Auflösung (256x256 Pixel) ist qualitativ vergleichbar, zeigt jedoch auch eine verringerte Genauigkeit des Modells. Diese ist proportional zu der Reduktion der originalen Auflösung.

5.3 Vorhersage der Position im Feld

Um die, in der Methodik vorgestellten, Modelle vergleichen zu können, wurde jedes mit 1024 Kalibriervorgänge trainiert. Es wurden jeweils fünf Heliostaten zur selben Zeit auf das Target gerichtet. Der Validationsdatensatz beinhaltet 128 Kalibriervorgänge, der Evaluationsdatensatz 256. Das für diese Auswertungen genutzte Heliostaten Feld wurde mit 2000 Heliostaten bestückt, die alle durch einen eigenen Verfolgungsfehler modifiziert wurden. Die Spiegeloberfläche ist homogen und hat eine Fläche von $5m^2$. Für diesen Vergleich wurde jeweils nur das letzte aufgenommene Bild genutzt. Dies entspricht der Zielposition auf dem Target. Die Auswahl der Heliostate für einen einzelnen Kalibriervorgang ist zufällig erfolgt. Die original Bildgröße der Trainigsdaten wurde dabei von 512x512 Pixel auf 128x128 Pixel reduziert um einen direkten Vergleich der Modelle zu ermöglichen. Bei der Größenreduktion gehen Informationen verloren, da dazu ein Komprimierungs-Alogrithmus auf die Bilddaten angewendet werden muss. Die Ergebnisse aus Tabelle 3 zeigen, dass die hier getesteten Modelle durch die höhere Informationsdichte der unkomprimierten Bilddaten mit weniger Trainingsepochen höhere Genauigkeiten erreichen können. Aufgrund der zu hohen Trainingsdauer konnten nicht alle Auflösungen für jedes Modell trainiert werden. Die Datensätze sind so aufgeteilt, dass die Validations- und Evaluations-Datensätze nicht die selben Sonnenpositionen enthalten wie die Trainingsdaten. Es können jedoch die gleichen Positionen und somit die selben Heliostate in allen drei Datensätzen vorkommen.

Modell	Training MSE	Validation MSE	Evaluation MSE
Einfaches CNN	87.15	140.32	181.33
DenseNet121	42.57	181.25	209.92
DenseNet121 + SPP	12.99	176.78	184.35
StyleGAN Generator	76.34	159.09	193.64

Tabelle 4: Vergleich der eingesetzten Modell mit 1024 Kalibrationen im Training.

Die getesteten Modelle erzielten auf den Evaluationsdatensatz alle eine ähnlichen MSE zwischen 180 und 210. Das entspricht einer durchschnittlichen Abweichung der euklidischen Distanz von 13.4m bis 14.5m. Unterschiede zeigen sich jedoch sowohl bei dem Trainings- als auch beim Validations-Datensatz. Diese haben beide direkte Auswirkung auf das Training der einzelnen Modelle. Ebenfalls weisen alle Modelle ein Overfitting des Trainingsdatensatzes auf. Sowohl das einfache CNN als auch der StyleGan Generator liegen bei einem Delta der euklidischen Distanz zwischen Training und Evaluation von circa 10m. DenseNet121 zeigt bei dieser Datensatzgröße ein stärkeres Overfitting auf den Trainingsdatensatz. Ein Grund dafür ist die, im Vergleich zu den anderen eingesetzten Modellen, deutlich größere Anzahl trainierbarer Parameter.

Modell	Training MSE	Validation MSE	Evaluation MSE
Einfaches CNN	15.34	23.87	24.58
DenseNet121	26.96	130.36	131.54
DenseNet121 + SPP	28.77	59.42	63.78
StyleGAN Generator	26.86	34.37	41.26

Tabelle 5: Vergleich der eingesetzten Modell mit 4096 Kalibrationen im Training.

Die Unsicherheit der Modelle kann auf die kleine Anzahl abgebildeter Sonnenstände während des Trainings zurück geführt werden. In Tabelle 4 wurden 1024 Trainingsdaten erzeugt wobei die Wahl des Sonnenstandes zufällig ermittelt wurde. Dadurch kommt es dazu, dass aus den 250 möglichen Sonnenständen nicht alle ausgewählt wurden.

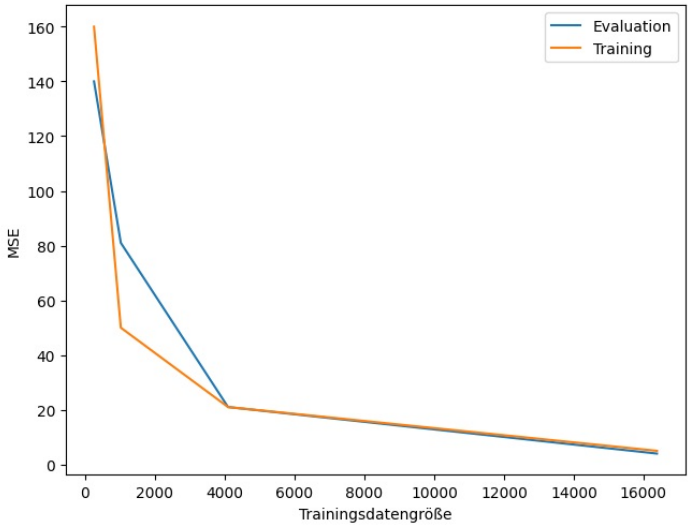

Abbildung 20: Trainings- und Evaluationsgenauigkeit in Relation zu der Trainingsdatensatzgröße. Aufgetragen ist der MSE im Training und der Evaluation von dem einfachen CNN.

Im Vergleich wurde in einer zweiten Auswertung (siehe Tabelle 5) die Anzahl der im Training verwendeten Kalibriervorgänge auf 4096 erhöht. Es ist ebenfalls ein Overfitting zu erkennen. Die Differenz der Genauigkeit der einzelnen Datensätze konnte durch die größeren Trainingsdatensätze reduziert werden. Abbildung 20 zeigt den MSE im Vergleich zu der Datensatzgröße, welche im Training genutzt wurde.

5.3.1 Bildserie

Die bisher vorgestellten Ergebnisse beziehen sich alle auf die Auswertung einzelner Bilder einer Bildserie. Das bedeutet, dass der Zusammenhang der Einzelbilder in einer Bildserie nicht betrachtet wird. Wie bereits in Kapitel 4.3.4 beschrieben, wird zur Analyse der Bildreihe das einfache CNN in Zusammenhang mit einer GRU Architektur eingesetzt. Dafür wurde das Modell mit einer Bildgröße von 128x128 Pixeln trainiert. Außerdem wurde sowohl ein Datensatz mit 1024 als auch mit 4096 Kalibriervorgänge vorgegeben.

Kalibriervorgänge (Training)	Training MSE	Validation MSE	Evaluation MSE
1024	112	193	136
4096	37	60	44

Tabelle 6: Auswertung der gesamten Bildserie. Die Ergebnisse wurden mit einer GRU Architektur in Zusammenhang mit dem einfachen CNN erzielt.

Durch die Auswertung der Bildserien konnte keine höhere Genauigkeit erzielt werden. Die große Anzahl zusätzlich zu bewertender Parameter führte zu einer höheren Unsicherheit des Modells. Auch in diesem Fall sinkt die Unsicherheit mit steigender Trainingsdatensatzgröße.

5.4 Data Augmentation

In den Vorherigen Ergebnistabellen konnte ein Overfitting des Modells auf den Trainingsdatensatz erkannt werden. Der Grund dafür könnten zum einen zu komplexe Modelle für die zu trainierende Problemstellung sein, aber auch ein nicht balancierter Datensatz. Wie in Kapitel 4.2.1 beschrieben, besteht ein einzelnes Element des Datensatzes aus einem Kalibriervorgang. Dieser beinhaltet alle Einzelbilder von den fünf zufällig ausgesuchten Heliostaten. Die untersuchten Modelle erwarten als Input die Bilddaten eines einzelnen Heliostats. Bei dem Training wurde dafür immer das erste Heliostat eines Kalibriervorgangs gewählt. Zum einen konnte gezeigt werden, dass das Overfitting durch den Einsatz größerer Datensätze reduziert werden konnte. Ein weiterer Faktor, welcher ein Overfitting auslösen kann, ist eine unabsichtlich eingeführte Bias durch den Trainingsdatensatz. Aus diesem Grund wurde das einfache CNN mit einem angepassten Trainingsvorgang trainiert.

Brennfleck aus Bildserie	Training MSE	Validation MSE	Evaluation MSE
Letzter	13.99	20.62	21.11
Zufällig	24.21	23.08	25.85

Tabelle 7: Vergleich einfaches CNN 4096 Kalibrationsvorgänge 512x512. Verglichen werden dabei zwei Modelle, bei denen nur die Auswahl der zu trainierenden Brennflecke verändert wurde.

Für die Ergebnisse in Tabelle 7 wurde diese Methode mit einer zufälligen Auswahl der Heliostaten, bei der außerdem das Bild aus der Serie zufällig gewählt wurde. Im Vergleich dazu wird in der ersten Zeile der Tabelle das einfache CNN ohne diese Anpassung gelistet. Der durchschnittliche Fehler bei 4096 Datensätzen wird durch die zufällige Wahl für die Trainingsdaten fast verdoppelt. Im Vergleich dazu verschlechterten sich die Ergebnisse des Evaluations und Trainings-Datensatz um 10%. Es kann jedoch anhand der durchschnittlichen Fehler und dem dazu gehörigen Trainingsvorgang kein Overfitting festgestellt werden. Der erhöhte Fehler in den Trainingsdaten ist auf die größere Variation der Zielpositionen auf dem Target zurück zu führen. Bei der zufälligen Wahl des Brennflecks aus der Bildserie können pro Brennfleck fünf verschiedene Positionen abgedeckt werden.

5.4.1 Verringerte IoU

Werden die Modelle im Gesamtverfahren eingesetzt, kann es vorkommen, dass durch die Segmentierung eine nicht perfekte Segmentationsmaske erstellt wird. Im Training der Modelle wurden jedoch, für die oben vorgestellten Ergebnisse, die Groundtruth Daten eingesetzt. Wird das einfache CNN auf den Evaluationsdatensatz angewendet, bei dem der Fehler durch die Segmentierung berücksichtigt wird, sinkt der MSE von 21.11 auf 141.93. Die Größe des Brennflecks und auch die Form werden durch die Feature Extraction als Bewertungskritiken des Modells genutzt. Die deutlich kleineren Segmentatsionsmasken haben dabei einen Einfluss auf die Größe und auch Form des auszuwertenden Brennflecks.

Um diesen Fehler auszugleichen wurde das einfache CNN ebenfalls mit einem ange-

Modell	Training MSE	Validation MSE	Evaluation MSE
Einfaches CNN	24.21	23.08	141.93
Einfaches CNN (Data Augmentation)	49.61	51.12	54.49

Tabelle 8: Vergleich einfaches CNN 4096 Kalibrationsvorgänge 512x512. Der Evaluationsdatensatz wurde mit dem Segmentationsfehler versehen. Das Modell in der ersten Zeile wurde ohne Berücksichtigung dieses Fehlers trainiert, während das zweite Modell schon im Training dem Segmentationsfehler ausgesetzt wurde.

passten Datensatz trainiert. Bei diesem wurde schon im Training der mögliche Segmentationsfehler berücksichtigt. Dadurch konnte der MSE des Evaluationsdatensatzes von 141.93 auf 54.49 gesenkt werden. Durch die größere Variation möglicher Eingangsdaten für das Modell wird auch hier die steigt Ungenauigkeit, bei selber Datensatzgröße.

5.4.2 Anwendung auf unbekanntes Feld

Datensatz Anpassungen	Training MSE	Validation MSE	Evaluation MSE
Fehler, Position	24.21	23.08	32.63
Fehler, Position, Größe	24.21	23.08	51.53

Tabelle 9: Vergleich einfaches CNN 4096 Kalibrationsvorgänge 512x512

Werden die trainierten Modelle auf ein fremdes Heliostatenfeld angewendet, zeigt sich (siehe Tablle 9), dass die Genauigkeiten bis zu 50% niedriger sind als auf das trainierte Feld. Für die Evaluation wurden hier sowohl die Positionen, Fehler, als auch die Größe der Heliostate angepasst. Der Trainingsdatensatz beinhalten nur eine Heliostat Variation. Die Größe des Brennflecks ist bei der Bildauswertung ein wichtiger Parameter und trägt in diesem Fall maßgeblich zu dem Ergebnis bei. Während durch Anpassungen der Position und des individuellen Fehlers der Heliostate eine Abweichung des MSE von 25.85 auf 32.63 zu beobachten ist, wird der Fehler durch Änderung der Spiegeloberflächen verdoppelt.

5.4.3 Transfer Learning

Das bereits trainierte Modell wurde in den vorherigen Vergleichen auf Felder angewendet bei denen nur die Position und der Fehler der einzelnen Heliostate geändert wurde. In Tabelle 9 wird das einfache CNN auf einen Evaluations-Datensatz angewendet bei dem zusätzlich die Größe der Spiegeloberflächen und die Abstände der Heliostate geändert wurden.

Modell	Training MSE	Validation MSE	Evaluation MSE
Einfaches CNN	24.21	23.08	31.30
Einfaches CNN (Transfer Learning)	27.46	26.82	26.24

Tabelle 10: Vergleich einfaches CNN mit und ohne Transfer Learning. 4096 Kalibriervorgänge mit 512x512 Punkten.

Die Anwendung eines trainierten Modells auf ein neues Heliostatenfeld zeigte eine ge-

ringere Genauigkeit. Um diese auszugleichen wurde der gleiche Test mit einem weiteren Modell durchgeführt, welches zusätzlich mit einem kleinen Ausschnitt des zu testenden Feldes trainiert wurde. Dabei kamen 128 Kalibrationsvorgänge zum Einsatz, welche nach den selben Regeln wie auch die normalen Trainingsdaten zufällig ausgewählt wurden. Wie in Tabelle 10 zu sehen, kann mit einem kleinen Transfer Learning Datensatz die Genauigkeit des bereits trainierten Modells um bis zu 15% gesteigert werden und erreicht damit eine ähnlich hohe Genauigkeit wie auf das ursprüngliche Heliostatenfeld.

Das Transfer Learning wirkt sich ebenfalls auf die Ergebnisse des ursprünglichen Datensatzes aus, bei dem der MSE im Durchschnitt 8% niedriger ist als vor dem Transfer Learning.

5.5 Heliostat Zuordnung

Modell	TP	FN	TN	FP
Einfaches CNN	480	14	6	0
Einfaches CNN (Random Frame)	478	14	8	0
DensetNet	392	65	31	12
DensetNet + SPP	431	34	33	2
CNN + GRU	432	47	21	0

Tabelle 11: Die Zuordnung wurde erstellt ohne den Fehler der Segmentierung mit zu berücksichtigen.

Tabelle 11 zeigt die Ergebnisse einer Kalibration mit 100 Kalibriervorgängen und jeweils fünf Heliostaten. Um eine Zuordnung zu Treffen wurde aus den von dem jeweiligen Modell, vorhergesagten Positionen, der Abstand zu der gewichteten Mitte der Brennflecken gebildet. Für die eigentliche Zuordnung von Brennfleck zum Heliostat wurde dabei der geringste Abstand zwischen Vorhersage und dem eigentlichen Treffpunkt gewählt. Zuordnungen wurden in diesem Fall nur zurückgewiesen, falls der geringste Abstand zwischen den Punkten über $10m$ beträgt. Der Segmentierungsfehler wurde bei diesem Datensatz nicht berücksichtigt.

Modell	TP	FN	TN	FP
Einfaches CNN	371	71	55	3
Einfaches CNN (Data Augmentation)	401	60	38	1
Einfaches CNN (Data Augmentation + Heuristische Auswahl)	437	47	16	0

Tabelle 12: Die Zuordnung wurde erstellt mit Berücksichtigung des Fehlers der Segmentierung. Das erste Modell wurde mit den Groundtruth-Daten trainiert, während das zweite Modell mit modifizierten Trainingsdaten trainiert wurden. Es wurde während des Trainings ein IoU von 70% angenommen um den Ergebnissen der Segmentierung näher zu kommen. Die letzte Zeile der Tabelle zeigt Ergebnisse, bei denen zusätzlich die heuristische Heliostatauswahl eingesetzt wurde.

Um eine realistischere Repräsentation der Ergebnisse abbilden zu können, wurde in Tabelle 12 das gesamte Verfahren getestet. Hierbei wurde ebenfalls der Segmentationsfehler berücksichtigt. Für die Zuordnung wurde das, wie in der Methoden beschriebene Verfahren, angewendet.

Bei Betrachtung des gesamten Verfahren wurden deutlich mehr Brennflecken falsch oder gar nicht zugeordnet. Das liegt an der strikteren Beurteilung der Ergebnisse aus der Positionsvorhersage. Die erhöhte Anzahl Flase Negatives hängt vor allem mit der geringeren Genauigkeit der Segmentierung zusammen. Wie bereits gezeigt, beeinflusst eine schlechte Segmentierungsmaske auch die Vorhersage der Position eines Brennflecks.

6 Diskussion

6.1 Segmentierung

6.1.1 Watershed

Die Segmentierung muss eine minimale IoU erreichen können damit die nachfolgende Zuordnung des Brennflecks zu einer Position zu ermöglichen. Die Ergebnisse des Watershed Verfahrens zeigten jedoch, dass die analytische Auswertung der Brennflecken schlechtere IoU erzielt wenn reale Heliostaten Oberflächen angenommen werden. Dafür sind vor allem die nicht homogene Verteilung der Strahlung auf dem Target verantwortlich.

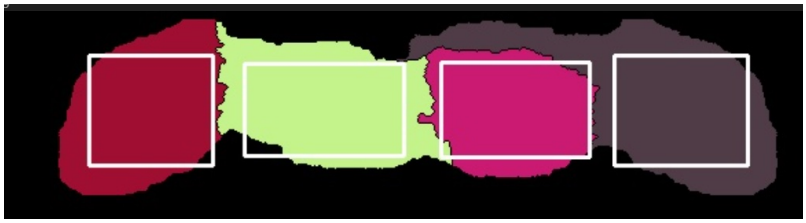

Abbildung 21: Gezeigt wird die Segmentaktionsmaske von realen Oberflächen, welche mit dem Watershed-Algorithmus erzeugt wurden. Vor allem die Maske rechts außen weist einen großen Überlauf-Anteil auf.

Damit die Segmentierung überlappender Lichtflecken mit dem Watershed-Algorithmus für die realen Oberflächen möglich ist, müssen die Schwellenwerte an die höheren Intensitäten, die im Zentrum des Brennflecks auftreten, angepasst werden. Wird keine Anpassung der Schwellenwerte durchgeführt, kommt es zum Überlauf von der Maske eines Brennflecks zum nächstgelegenen (siehe Abbildung 21). Das führt dazu, dass bei der Segmentierung mehr Fläche am Rand eines Brennflecks nicht mit berücksichtigt wird und erklärt so die geringere IoU, die das Verfahren bei den realen Oberflächen erzielt.

Die Fehler der Watershed-Methode können auf zwei Hauptfehler eingegrenzt werden. Zum einen kann ein Fehler entstehen, wenn zwei Brennflecke überlappen, bei denen die relativen Intensitäts-Werte ähnlich groß sind. Das kann dazu führen, dass bei der Findung der Grenze zwischen zwei Objekten, kein numerischer Höhenunterschied erkennbar ist. Somit ist die entstehende Grenze zufällig und kann dazu führen, dass wie in Abbildung 22 zu sehen ist, die Segmentationsmaske von einem Brennfleck einen Teil des benachbarten Brennflecks mit abdeckt.

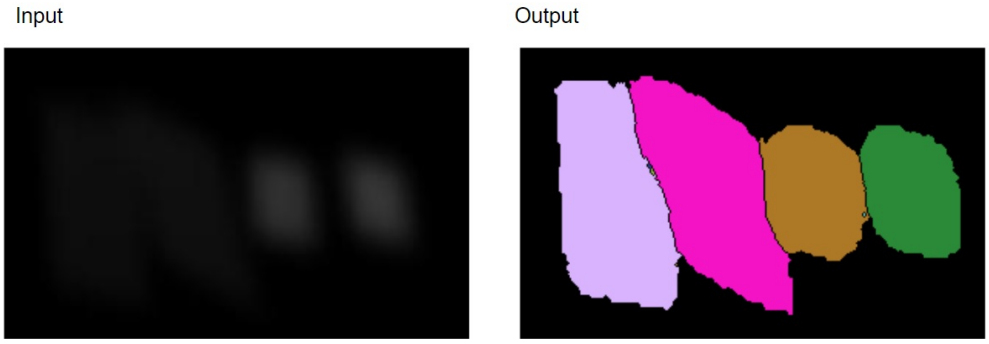

Abbildung 22: Gezeigt wird die Segmentaktionsmaske von homogenen Oberflächen, welche mit dem Watershed-Algorithmus erzeugt wurden. Die Grenze der ersten beiden Brennflecken wurde falsch detektiert, in diesem Fall ist die Maske des zweiten Brennflecks deutlich zu groß.

Der Anteil dieses Fehlers kann mit weiteren Annahmen, wie der Größe des durchschnittlichen Brennflecks und der dazu gehörigen Intensität, mit Hilfe von Nachverarbeitung verringert werden. Diese Annahmen sind sehr spezifisch für bestimmte Datensätze und wurde daher nicht in der Auswertung berücksichtigt.

Das hier eingesetzte Watershed-Verfahren nutzt Marker um schon bei der Initialisierung des Algorithmus festzulegen, welche Teile des Bildes Vordergrund, in diesem Fall Brennflecken, oder Hintergrund sind. Für den Vordergrund werden die lokalen Maxima der Brennflecken genutzt. Die Heliostate sind konkav, sodass angenommen werden kann, dass sich die höchste Intensität eines Brennflecks in der Mitte befindet. Wenn zwei Brennflecken stark überlappen, können diese lokalen Maxima nicht mehr verlässlich ermitteln. Das kann dazu führen, dass ein Brennfleck zu wenig segmentiert wird, da durch die Überlappung von dem Algorithmus die überlappende Region zweier Brennflecken als ein einzelner segmentiert wird. Zum anderen kann es vorkommen, dass für die überlappende Region zwei Segmentationsmasken gefunden werden, welche beide die gleiche überlappende Region abbilden. In diesem Fall würden zwei identische Masken für zwei unterschiedliche Brennflecken gefunden werden.
Ebenfalls kann eine überlappende Region ein lokales Maximum bilden und so mit einem Brennfleck verwechselt werden. Die entstehende Segmentationsmaske kann dadurch verzerrt oder verschoben sein. Das kann bei der späteren Vorhersage der Position dazu führen, dass der Mittelpunkt des Brennflecks Falsch bestimmt wird und dadurch auch die Kalibrierung nicht richtig durchgeführt werden kann.

Das Zuordnungsverfahren kann Fehler abfangen bei denen die Segmentation einen Brennfleck zu wenig segmentiert oder einen Brennfleck doppelt erkennt. Jedoch ist es nicht möglich den eigentlichen Segmentationsfehler zu erkennen, das bedeutet wenn durch die Segmentierung eines Brennflecks ein falscher Mittelpunkt ermittelt wird, kann das Verfahren diesen Fehler nicht erkennen. Dieser Fehler wird also bei der Anpassung der Ist- und Soll-Position mit in das System eingebracht. Das ist ein Nachteil gegenüber der einfachen Kamera-Target Methode. Dort wird ein solcher Fehler ausgeschlossen indem nur ein ein-

zelner Brennfleck auf dem Target betrachtet wird. Es wird ebenfalls ein Fehler durch die Segmentierung in das System eingeführt, wenn die Region zweier überlappender Brennflecken als neuer Brennfleck angesehen werden. Dieser kann, falls der neu entstandene Mittelpunkt innerhalb der Toleranz liegt, eine große Abweichung der Zielposition eines Heliostaten zur Folge haben.

6.1.2 U-Net

Für die Segmentierung der Brennflecken wurde außerdem ein Machine Learning Ansatz untersucht. Es wurde U-Net zur Segmentierung von Vordergrund- und Hintergrundobjekten eingesetzt. Mit den gegebenen Testdaten konnte jedoch keine ausreichend hohen Genauigkeiten erreicht werden und wurden deshalb nicht in den Ergebnissen berücksichtigt. Es stellte sich heraus, dass es nicht ausreichend ist nur die Bilddaten ohne weitere Informationen zu betrachten.

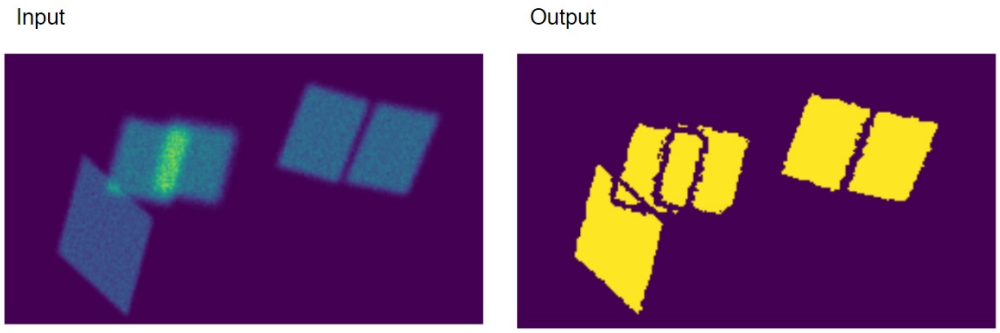

Abbildung 23: Beispiel einer Segmentierung mit U-Net. Die Masken, auf der rechten Seite, zeigen ein Problem dieses Ansatzes auf. Die Segmentierung trennt korrekt Flächen mit verschiedener Intensität. Jedoch ist es nicht möglich diese Masken zu verwenden ohne diese weiter zu verarbeiten, da die Masken bei Überlappungen fragmentiert werden. Diese Fragmente müssten in einem weiteren Schritt rekonstituiert werden.

Wie in Abbildung 23 zu sehen ist, werden bei einer Segmentierung mit U-Net, die Vordergrundobjekte fragmentiert. Diese Fragmentierung entsteht durch die höheren Intensitätswerte bei überlappenden Regionen der Brennflecken. Um dieses Problem zu beheben müssten die so entstandenen Fragmente in einem weiteren Bearbeitungsschritt wieder kombiniert werden. Eine weitere Möglichkeit wäre die Betrachtung weiterer Parameter während der Segmentierung.

6.2 Vorhersage der Position

Die eingesetzten Modelle konnten alle eine ausreichende Genauigkeit erreichen um eine Zuordnung der Position mit dem untersuchten Verfahren möglich zu machen, wenn eine perfekte Segmentaktionsmaske vorausgesetzt wird. Im Trainingsdatensatz wurde ein Feld mit 2000 Heliostaten genutzt. Somit wurden aus Sicht der Modelle lediglich 2000 verschiedene Relationen von Brennfleck zu Position trainiert. Die Variablen in dem Datensatz sind die Sonnenposition und die dadurch entstehende Verzerrung beziehungsweise

Verschiebung der Brennflecken auf dem Target.

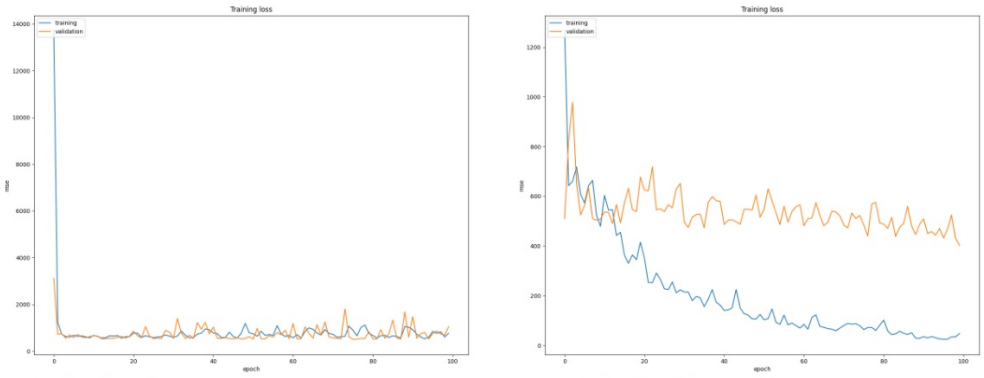

Trained on X Trained on Y

Abbildung 24: Gezeigt wird der Trainingsverlauf des einfachen CNN, bei dem auf der linken Seite nur der Abstand in X Richtung vorhergesagt wird. Auf der reichten Seite ist der Trainingsverlauf nur unter Berücksichtigung der Y Koordinate aufgetragen, beziehungsweise die Verzerrung des Brennflecks.

Die ausgewertete Position ist abhängig von der X- und Y-Koordinate, welche in Relation zu dem Turm angegeben wurden. Es konnte gezeigt werden, dass der Abstand in X-Richtung vom Turm einen größeren Einfluss bei dem Training der Modelle hat, als die Verschiebung auf der Y-Achse. Wie in Abbildung 24 zu sehen ist, kann das einfache CNN bei der angepassten Aufgabe, nur die X-Position vorhersagen und ebenfalls hohe Genauigkeiten erzielen. Auch der Trainingsvorgang zeigt eine, bezogen auf die Anzahl benötigter Epochen, schnelle Konvergenz der vorgegebenen Optimierungsfunktion.
Im Vergleich dazu kann das selbe Modell nur einen deutlich niedrigeren MSE erreichen, wenn nur die Y-Achse für das Training betrachtet wird. Auch die Unsicherheit während des Trainings kann mit dieser Erkenntnis erklärt werden.

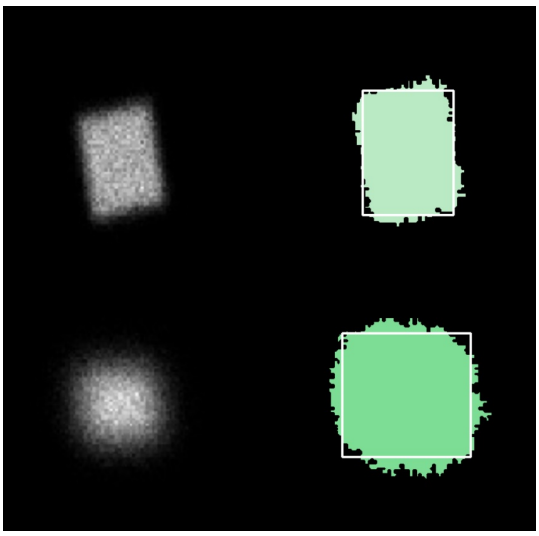

Abbildung 25: Beispiel analytische Auswertung zweier Heliostat Positionen. Die gezeigten Heliostate wurden mit homogener Oberfläche simuliert. Für die analytische Auswertung können die Größe des Brennflecks und die Form genutzt werden.

Aus analytischer Sicht betrachtet, ist für den Abstand in X-Richtung vor allem ein Zusammenhang zur Größe des Brennfleckes auf dem Target erkennbar (siehe Abbildung 25). Dies beruht auf der physikalischen Grundlage, dass bei einer größeren Entfernung von Heliostat zu dem Turm auch der Lichtfleck auf dem Target, bei gleicher Maße der Spiegeloberfläche, proportional größer wird. Zusätzlich kann bei der Annahme von rechteckigen Heliostaten die Form als Bewertungskriterium genutzt werden. Heliostate die sehr nah an dem Turm stehen, haben eine eher rechteckige Form während mit steigendem Abstand, aufgrund von Canting und Focusing, der Brennfleck runder wird.

Wird nun die Y-Achse isoliert betrachtet, kann die Verzerrung des Brennfleckes Aufschluss auf die Verschiebung des Heliostaten auf der Y-Achse bringen. Auch hier kann mit Hilfe einer analytischen Auswertung die Y-Position des Heliostaten im Feld abgeschätzt werden. Auch der Sonnenstand hat dabei einen Einfluss auf die Verzerrung des Brennflecks.

Der erhöhte Abstand beeinflusst auch die Verteilung der Strahlung auf dem Target und führt zu einer geringeren Strahlungsdichte für den Lichtfleck. Die Auswertung verwendet, normalisierte Intensitätswerte. Der Abstand in X-Richtung ist ebenfalls von den Intensitätswerten des Lichtflecks abhängig. Bei Annahme von zwei Brennflecken auf dem Target, bei dem das zugehörige Heliostat des ersten Brennflecks im vorderen Teil des Feldes und dem des zweiten im hinteren Teil des Feldes steht, wirkt sich der Abstand auf die relativen Intensitätswerte des Brennflecks aus. In diesem Beispiel würden die Intensitätswerte des Brennflecks, der zum vorderen Heliostaten gehört, größer ausfallen. Auch dieses Feature wird sowohl von einer analytischen Auswertung genutzt werden, als auch während des Trainings von dem jeweiligen CNN Modell.
Für die Intensitätswerte zweier Heliostate, die jeweils auf der selben Höhe stehen aber auf der Y-Achse verschoben sind, ist der absolute Abstand zwischen den Heliostaten und dem Turm fast gleich groß und führt daher auch zu vergleichbar hohen relativen Intensität in den Bilddaten. Die Intensität liefert daher zusätzliche Informationen zu dem Abstand in X-Position aber nicht zur Verschiebung auf der Y-Achse.

Grundsätzlich kann daher jedoch angenommen werden, dass die Modelle ebenfalls durch diese Hauptmerkmale beeinflusst wurden. Das trainierte Modell liefert bei gleichen Trainingsbedingungen unterschiedliche Genauigkeiten, wenn X und Y Positionen separiert trainiert werden. Die analytische Auswertung der Position kann, im Vergleich zu den Machine Learning Verfahren, jedoch nicht Verallgemeinert werden und muss speziell an die Heliostat Größe und Oberfläche angepasst werden.

6.2.1 Vergleich eingesetzter Modelle

Wie bereits anfangs erwähnt wurde, konnten alle getesteten Modelle bei der Zuordnung eine ausreichende Genauigkeit erreiche um für die Positionsvorhersage genutzt werden zu können. Dabei stellte sich heraus, dass die komplexeren Architekturen in diesem Vergleich schlechtere Ergebnisse erzielen konnten (siehe Tabelle 5). Bei Betrachtung des Trainingsverlaufs kann davon ausgegangen werden, dass die komplexeren Modelle, wie

DenseNet121 und die Auswertung der Bildreihen mit GRU, zu viele Parameter haben. Diese Modelle können den gegebenen Datensatz komplett abbilden, da die auszuwertenden Features, wie oben angedeutet, begrenzt sind. Es ist zu beachten, dass beim Einsatz der Modelle mit realen Daten weitere Features berücksichtigt werden können. Dazu gehört vor allem die Strahlungsverteilung. Diese ist bei realen Daten für jedes Heliostat einzigartig und kann so als weiteres Feature ausgewertet werden.

Aufgrund dieser Ergebnisse wurde für alle weiteren Vergleiche das einfache CNN als Stellvertreter der Machine Learning Ansätze gewählt. Auch das einfache CNN wies nach dem Training ein leichtes Overfitting auf. Die Ursache dieses Overfittings konnte auf die Methode zurück geführt werden, mit dem die Trainingsdaten vorverarbeitet wurden. Wenn wie in Tabelle 7 die Auswahl und Reihenfolge der Brennflecken während des Trainings zufällig erfolgt, kann das Overfitting auf die Trainingsdaten verhindert werden. Das erste Heliostat wurde zwar zufällig aus dem Feld ausgewählt, ist aber an die für diese Auswahl genutzte Zufallsreihe gebunden. Für die Evaluationsdaten wurde eine andere Zufallsreihe genutzt, um so Überschneidungen mit dem Trainingsdatensatz zu vermeiden. Die Zufallsreihe hatte also direkte Auswirkungen auf das Training. Um das Overfitting zu verhindern und die Datenvielfalt eines einzelnen Heliostaten zu erhöhen, wurden deshalb alle Einzelbilder berücksichtigt. Für jeden Trainingsschritt wurde zusätzlich die Auswahl des zu untersuchenden Brennflecks per Zufall bestimmt. Wie in Tabelle 7 gezeigt, führt dies zu einem ausgeglichenen Trainings- beziehungsweise Evaluations-Fehler.

Die oben besprochenen Ergebnisse beziehen sich auf Datensätze, bei denen eine perfekte Segmentaktionsmaske angenommen wurde. Wie die Ergebnisse in Tabelle 2 zeigen konnte mit dem Watershed Verfahren eine niedrigere IoU von 70% erreicht werden. Da sich die Größe der Brennflecken, wie oben beschrieben, als eines der Hauptfeatures erwiesen hat, wirkt sich auch die schlechtere IoU auf die Vorhersage der Heliostat Position aus. Wird das einfache CNN mit einem Datensatz trainiert, bei dem eine IoU von 100% vorgegeben ist und dieser auf einen Evaluationsdatensatz angewendet wird bei dem realistische IoU von 70% eingesetzt wurden, so steigt auch der Fehler des Modells um bis zu 10% (siehe 8).

Um diesen Fehler schon beim Training zu berücksichtigen, wurde das gleiche Modell ebenfalls mit einem Datensatz trainiert, bei dem mit Hilfe von Korrosion ein Fehler während der Segmentation berücksichtigt wurde. Die Ergebnisse aus Tabelle 8 zeigen, dass die Anpassung auf den Segmentatinosfehler auch die Ergebnisse des Evaluationsdatensatzes verbessern.

Wie bereits gezeigt wurde, konnte ein analytisches Verfahren, welches anhand von Größe und relativen Intensitätswerten, eingesetzt werden um die Zuordnung von Brennfleck zu Heliostat durchzuführen. Voraussetzung dafür ist, dass alle parallel zu kalibrierenden Heliostate einen unterschiedlich großen Abstand zu dem Turm haben. Die heuristische Methode, die zur Zuordnung eingesetzt wurde, berücksichtigt jedoch nicht den Abstand von Turm zu Heliostat, sondern den Abstand der Heliostate zueinander. Aus diesem Grund kann das analytische Verfahren keine hohen Genauigkeiten in Zusammenhang mit dieser

Methode zur Auswahl der Heliostate erzielen.

Die Auswahl der parallel zu kalibrierenden Heliostate müsste dazu mit einer Funktion abgebildet werden, die versucht alle Heliostate N in Gruppen aufzuteilen. Die Auswahl der Elemente jeder Gruppe würde dabei von dem Abstand d_n des Heliostaten zum Turm abhängen. Jede Gruppe G würde P Elemente umfassen, wobei P für die Anzahl parallel zu kalibrierender Heliostate steht. Die Gruppen müssten dabei so gewählt werden, dass die minimale Differenz aller Abstände innerhalb einer Gruppe maximiert werden.

Die reine Auswertung des relativen Abstands von Heliostat Turm anhand des gegebenen Brennflecks hat ebenfalls den Vorteil, dass die Segmentation einen geringeren Beitrag am Gesamtfehler hat. Es werden hauptsächlich die Intensitätswerte der Brennflecken verglichen, weshalb die Form der Segmentationsmaske weniger Auswirkung auf die Vorhersage des passenden Heliostaten hat. Die Größe der Maske wird auch bei der Auswertung genutzt, jedoch mit einer geringeren Gewichtung als die Intensitätswerte. Das ist nur möglich wenn die parallel auszuwertenden Heliostate wie oben beschrieben gewählt werden.

Es ist möglich dieses Verfahren weiter zu optimieren und damit auch zu verallgemeinern, indem bei der Auswertung nur die relativen Werte des aktuell vorliegenden Bildes berücksichtigt werden. Das beschriebene Verfahren ist nur unter der Annahme möglich, dass alle Heliostate eines Feldes die gleichen Maße und ähnliche Brennweiten haben. Es ist möglich dieses Problem zu umgehen, indem bei der Wahl der Heliostate auch diese Zusatzinformationen mit bei der Auswertung berücksichtigt werden. In der Evaluation wurden jedoch nur Heliostate mit gleicher Brennweite berücksichtigt, weshalb dazu weitere Untersuchungen nötig sind.

6.2.2 Bildreihen

Die Auswertung der Bildreihen wurde in der Evaluation genutzt um die Zuordnung der Brennflecken zu einer Position zu bestimmen. Die Ergebnisse im Vergleich zu den Modellen, die nur ein einzelnes Bild auswerten sind jedoch aufgrund der höheren Anzahl auszuwertender Parameter größer. Im Vergleich zu dem einfachen CNN ist die Anzahl der zu trainierenden Parameter 100 mal größer. Ebenfalls wurde der zeitliche Aspekt bei dieser Simulation nicht berücksichtigt, da es mit STRAL nicht möglich ist die Motorenstellungen zu simulieren. Diese würden weiter hinten liegende Heliostate deutlich schneller über das Target fahren als solche, die weiter vorne im Feld stehen. In der Simulation sind die Einzelbilder jedoch immer auf die Endposition bezogen, somit geht der zeitliche Zusammenhang zur Motorstellung verloren, da jedes Bild in der Zeitreihe den gleichen Abstand zum vorherigen hat.

6.3 Zuordnung der Brennflecken

Die eigentliche Zuordnung von Brennfleck zu Heliostat wurde mit einem analytischen Verfahren umgesetzt. Dieses wurde so angepasst, dass die physikalischen Eigenschaften eines Turmkraftwerks genutzt werden, um so die Fehlertoleranz des Verfahrens möglichst

groß halten zu können. Die größeren Toleranzen erlauben den Einsatz von nicht speziell auf die Problemstellung angepassten Methoden. Wie in Tabelle 5 zu sehen, erreichten die kleineren Netzwerk Architekturen Ergebnisse, die ohne weitere Anpassungen direkt zur Auswertung der Position, beziehungsweise des Abstands, genutzt werden können.

Die Ergebnisse (siehe Tabelle 11) bestätigten außerdem die Annahme, dass durch eine Gewichtung des Verfahrens hin zu False Negatives, die Anzahl False Positives vernachlässigbar wird. Diese treten auch in den Evaluationsdaten nur auf, wenn das trainierte Modell einen hohen Fehler aufweist. Das bietet bei der Kalibrierung den Vorteil frühzeitig abbrechen zu können, falls ein Fehler erkannt wird. So besteht die Möglichkeit manuell einzugreifen oder die Kalibrierung ungültig zu machen. So kann sichergestellt werden, dass durch dieses Kalibriervorgang die Effizienz des Systems nicht verschlechtert wird. Das bedeutet, dass dieses Verfahren nur in dem Fall von False Positives selbst weitere Fehler in das Gesamtsystem einführt. Davon ausgenommen ist die Genauigkeit der Segmentation, denn anhand dieser muss der gewichtete Mittelpunkt ermittelt werden, damit im späteren Verlauf die Differenz dieses Mittelpunkts und des angezielten Punktes genutzt werden kann um die Abweichung zu bestimmen. Das bedeutet auch, dass die Anpassung des Verfolgungsfehlers durch unzureichende Segmentations-Ergebnisse negativ beeinflusst werden kann.

Ein Nachteil den die höhere Gewichtung auf False Negatives mit sich bringt, ist ein höherer Gesamtfehler. Wie in Tabelle 11 zu sehen ist, erzeugt ein True Negative fast immer einen False Negative, da das Verfahren wie hier angewendet eine Zuordnung als Negativ annimmt, wenn mehr als ein Kandidat pro Brennfleck vorgeschlagen wird. Für diese Ergebnisse wurden die parallel zu kalibrierenden Heliostate zufällig aus dem Feld gewählt. Dadurch kann es vorkommen, dass zwei Heliostate gewählt wurden, welche sich entweder an einer ähnlichen Position im Feld befinden oder aber weit voneinander entfernt stehen, jedoch einen ähnlichen Abstand zu dem Target haben.

Es wurde aus diesem Grund ein weiteres Auswahlverfahren der zu kalibrierenden Heliostate getestet. Bei diesem wurde der Abstand der parallel zu kalibrierenden Heliostate im Feld maximiert. Die Ergebnisse aus Tabelle 12 zeigt, dass so der Fehler bei den simulierten Datensätzen, mit Einsatz des einfachen CNN, verringert werden konnte.

Ein Ursache dafür können die idealen Bedingungen der Simulation sein. Wie bereits beschrieben, baut das Auswahlverfahren auf dem durchschnittlichen Fehler des genutzten Modells auf. Das bedeutet speziell für das einfache CNN, dass ein Abstand zwischen zwei Heliostaten von über 10m rechnerisch schon ausreicht um Falschzuordnungen komplett zu vermeiden. Der Fehler, der hier trotzdem noch auftreten kann, ist ein True Positive bei dem die vom Netzwerk vorhergesagte Position eine größere Abweichung aufweist als der angenommene Schwellenwert. Der Schwellenwert für das einfache CNN wurde anhand des mittleren Fehlers ermittelt, mit einer zusätzlichen Toleranz von 30%. Für dieses Modell bedeutet das 5m mit einer Toleranz von 1.5m. Dieser Toleranzradius erklärt auch die Fehler der zufälligen Auswahl der zu kalibrierenden Heliostate. Wenn wie hier ein Toleranz-Radius von 5m, beziehungsweise 6.5m eingeschlossen der Toleranz, ange-

nommen wird, so ist es für dieses Verfahren nicht möglich Heliostate zuzuordnen, bei denen sich diese Toleranzbereiche schneiden. Aus diesem Grund ist es wichtig, die richtige Auswahl der parallel zu kalibrierenden Heliostate zu treffen. Der Fehler des angepassten Verfahrens ist niedriger, da bei dem Angenommenen Heliostatenfeld 200 Heliostate mit jeweils $5m$ Abstand platziert wurden. Es mussten nur, wie oben beschrieben, jeweils fünf Heliostate gewählt werden, bei denen sich dieser Radius nicht schneidet.

6.4 Anwendung in der Praxis

Die Anwendung dieser Methode im realen Feld wird weitere Probleme mit sich bringen, die mit den simulierten Daten nicht aufgetreten sind. Bei dem eigentlichen Kalibriervorgang müssen alle Heliostate das Target auch treffen. In der Praxis kann es je nach Abweichung des einzelnen Heliostaten dazu kommen, dass ein oder mehrere Heliostate einen so großen Verfolgungsfehler haben, dass diese nur teilweise auf das Target reflektieren oder sogar gar keine Reflektion auf dem Target verursachen.

Falls das Target ganz verfehlt wird, kann der Brennfleck nicht segmentiert werden und somit auch keine Zuordnung zu einem Heliostat durchgeführt werden. Falls beim Auftreten eines solchen Fehlers alle anderen Heliostate richtig zugeordnet werden konnten, ist es trotzdem möglich festzustellen, welches Heliostat einen so großen Fehler aufweist. Dieser muss dann gegebenenfalls Manuell behoben werden.

Wenn jedoch nur ein Teil des Brennflecks auf das Target trifft, kann dies mit dem vorgestellten Verfahren nicht erkannt werden. Durch die leicht konvexe Form der Spiegeloberflächen ist die Strahlung im Idealfall in der Mitte am dichtesten. Wenn nur der Rand des Brennflecks auf dem Target abgebildet ist, wird eventuell eine Falschzuordnung durchgeführt, da die geringere Strahlungsdichte auf ein weiter entferntes Heliostat schließen lassen könnte. Dieser Fehler ist auch bei der Auswertung nicht automatisch detektierbar und könnte im schlimmsten Fall einen falschen Mittelpunkt an die nachfolgende Kalibration liefern.

Ebenfalls konnten in der Simulation maximale Fehler für die Überlappung der Brennflecke angenommen werden. In der Praxis sind diese Fehler spezifisch und können nicht im Voraus berechnet werden. Das kann dazu führen, dass die durchschnittliche Überlappung selbst bei dem heuristischen Auswertungsverfahren niedriger ausfallen.

Um dem entgegen zu wirken könnten, wie oben beschrieben, die Bildreihen auch für die Segmentierung genutzt werden, um so die durchschnittliche Überlappung möglichst hoch zu halten, da diese ausschlaggebend für eine hohe Zuordnungsgenauigkeit für die hier untersuchte Methode ist.

7 Fazit

Damit solarthermische Turmkraftwerke betrieben werden können müssen die einzelnen Heliostate, aufgrund des Verfolgungsfehlers, in regelmäßigen Abständen Kalibriert werden. In der Praxis hat sich die Kamera-Target Methode durchgesetzt, da diese bei vollständiger Automatisierung eine ausreichende Genauigkeit erzielt. Die Kamera-Target Methode hat jedoch den Nachteil, dass jedes Heliostat einzeln kalibriert werden muss. Das führt bei großen Kraftwerken dazu, dass zu einem Zeitpunkt immer nur eine Teilmenge der Heliostate optimal kalibriert sind.

In Kapitel 4 wurde ein Verfahren vorgestellt, welches auf der Kamera-Target Methode aufbaut und es ermöglicht, mit Hilfe von Bildverarbeitung, mehrere Heliostate zur selben Zeit auswerten zu können. Das beschriebene Verfahren hat, abgesehen von der Software, keine zusätzlichen Anforderungen und kann somit bei jedem Kraftwerk genutzt werden, welches bereits die Kamera-Target Methode einsetzt. Das Verfahren ist so konzipiert, dass bei Zuordnungsunsicherheiten die verbleibenden Heliostate einzeln mit der Kamera-Target Methode kalibriert werden können.

Die Ergebnisse in Kapitel 5.5 zeigen, dass eine Zuordnung, bei Annahme von homogenen Spiegeloberflächen, mit einer Genauigkeit von bis zu 87% möglich ist, selbst wenn ein Segmentierungsfehler von 30% angenommen wird. Bei einer optimalen Segmentierung steigt die Zuordnungsgenauigkeit auf bis zu 96%. In diesem Beispiel wurden 500 Heliostate kalibriert, wobei jeweils fünf parallel ausgewertet wurden. Die Kamera-Target Methode würde, bei einer Kalibrierdauer von 20 Sekunden, 2.8 Stunden benötigen um das gesamte Feld zu kalibrieren. Das vorgestellte Verfahren konnte bei diesem Beispiel zwei Stunden einsparen und verringerte die Gesamtdauer auf ca. 48 Minuten.

Der Gesamtfehler des Verfahrens wurde größtenteils von der Segmentierung beeinflusst, diese wurde mit der Watershed-Methode umgesetzt. Vor allem bei den realen Spiegeloberflächen zeigten sich die Limitationen dieser Methode. Die Segmentierungsgenauigkeit sank bei Einsatz realer Spiegeloberflächen um bis zu 20%.

Grundsätzlich zeigen die erzielten Ergebnisse, dass das vorgestellte Verfahren, selbst mit einer niedrigen Segmentierungsgenauigkeit, eine hohe Zeitersparnis im direkten Vergleich zur Kamera-Target Methode erzielen kann. In einer weiteren Unteruschung sollte das vorgestellte Verfahren praktisch angewendet werden um die erzielten Ergebnisse in der Praxis bestätigen.

7.1 Ausblick

Die erzielten Ergebnisse zeigen, dass die Segmentierung den größten Anteil des gesamten Fehlers ausmacht. Es wurde ein Machine Learning Verfahren (U-Net) eingesetzt, jedoch konnten dieses nicht mit in die Evaluation einbezogen werden. Das Modell erzeugte fragmentierte Masken, diese waren daher nicht direkt nutzbar. Grundsätzlich können Machine Learning Ansätze höhere Genauigkeiten bei ähnlichen Problemstellungen erzielen. Mit den in dieser Arbeit erzielten Genauigkeiten bei der Zuordnung von Brennflecken zu

Heliostaten, wäre es sinnvoll, die Segmentierung der Brennflecken mit Machine Learning genauer zu Untersuchen.

Die Simulation der Bilddaten wurde hauptsächlich mit dem Raytracer STRAL durchgeführt. Dieser ist jedoch für einen anderen Anwendungszweck konzipiert und ermöglicht es Beispielsweise nicht, die Verschiebung des Zielpunktes der einzelnen Heliostate, über die Motorstellungen abzubilden. Der Abstand der Brennflecke bei einer Bildserie ist damit für alle Heliostate gleich, auch wenn der Abstand zu dem Turm sich stark unterscheidet. Ein Heliostat im hinteren Teil des Feldes sollte jedoch zeitlich schneller den Endpunkt erreichen als ein Heliostat welches sich im vorderen befindet. Die Geschwindigkeit mit der die jeweiligen Brennflecken bewegt werden kann ebenfalls als Parameter zur Bestimmung der Position beitragen. Auch die Simulation der realen Oberflächen und des Verfolgungsfehlers sind nicht einfach abzubilden und verhindern die Erstellung größerer Datensätze mit mehr Heliostaten-Vielfalt.

Es wäre von Vorteil ein Simulationsprogramm einzusetzen, bei dem diese Parameter frei wählbar sind. So wäre es möglich eine größere Variation verschiedener Datensätze zu vergleichen und es würde bessere Rückschlüsse auf die eingesetzten Methoden erlauben. Ebenfalls können so Modelle spezifisch auf ein bestimmtes Kraftwerk vorbereitet werden und so die benötigte Trainingsdatensatzgröße deutlich verringern.

Literatur

1. *IEA (2021), World Energy Outlook 2021, IEA, Paris* URL: https://www.iea.org/reports/world-energy-outlook-2021. Zugriff: 2022-1-07.
2. Hinkley, J. *u. a.* Concentrating solar power – drivers and opportunities for cost-competitive electricity (März 2011).
3. Roeb, M. *u. a.* Test operation of a 100kW pilot plant for solar hydrogen production from water on a solar tower. *Solar Energy* **85.** SolarPACES 2009, 634–644. ISSN: 0038-092X. https://www.sciencedirect.com/science/article/pii/S0038092X10001623 (2011).
4. *DLR, Synthetische Kraftstoffe, Institut für Future Fuels* URL: https://www.dlr.de/ff/desktopdefault.aspx/tabid-18130/28794_read-77440/. Zugriff: 2022-1-07.
5. Sattler, J. C. *u. a.* Review of heliostat calibration and tracking control methods. *Solar Energy* **207,** 110–132. ISSN: 0038-092X. https://www.sciencedirect.com/science/article/pii/S0038092X20306447 (2020).
6. Montserrat, D. M., Lin, Q., Allebach, J. & Delp, E. Training Object Detection And Recognition CNN Models Using Data Augmentation. *Electronic Imaging* **2017,** 27–36. ISSN: 2470-1173 (2017).
7. Yellowhair, J. & Ho, C. K. Heliostat canting and focusing methods: an overview and comparison. *Energy Sustainability* **43956,** 609–615 (2010).
8. Díaz-Félix, L., Escobar-Toledo, M., Waissman, J., Pitalúa-Díaz, N. & Arancibia-Bulnes, C. Evaluation of Heliostat Field Global Tracking Error Distributions by Monte Carlo Simulations. *Energy Procedia* **49.** Proceedings of the SolarPACES 2013 International Conference, 1308–1317. ISSN: 1876-6102. https://www.sciencedirect.com/science/article/pii/S1876610214005943 (2014).
9. Gross, F. & Balz, M. Potentially confusing coordinate systems for solar tower plants. *AIP Conference Proceedings* **2303,** 030017. eprint: https://aip.scitation.org/doi/pdf/10.1063/5.0028942. https://aip.scitation.org/doi/abs/10.1063/5.0028942 (2020).
10. Glassner, A. S. *An introduction to ray tracing* (Morgan Kaufmann, 1989).
11. Ahlbrink, N. *u. a. STRAL: Fast Ray Tracing Software With Tool Coupling Capabilities for High-Precision Simulations of Solar Thermal Power Plants* in *SolarPACES 2012* (2012). https://elib.dlr.de/78440/.
12. Belhomme, B., Ahlbrink, N., Pitz-Paal, R., Schwarzbözl, P. & Ulmer, S. *STRAL–Hochgenaue Strahlungsflussdichte-Simulation von Heliostatfeldern* 2009.
13. Bern, G., Schöttl, P., Heimsath, A. & Nitz, P. Novel imaging closed loop control strategy for heliostats. *AIP Conference Proceedings* **1850,** 030005. https://aip.scitation.org/doi/abs/10.1063/1.4984348 (2017).
14. Flesch, R., Ahlbrink, N., Pitz-Paal, R. & Belhomme, B. Automatic determination of heliostat orientation using an auxiliary mirror. *SolarPACES* (2012).
15. Prahl, C., Röger, M. & Kiewitt, W. Advances in optical measurement techniques for solar concentrators (2009).
16. Jessen, W., Prahl C., R. & M. Pitz-Paal, R. Airborne photogrammetric heliostat pre-calibration [Unpublished] (2020).

17. Kelleher, J. D. *Deep learning* (MIT press, 2019).
18. Lin, T.-Y. *u. a.* Microsoft coco: Common objects in context, 740–755 (2014).
19. Deng, J. *u. a.* ImageNet: A large-scale hierarchical image database, 248–255 (2009).
20. Wahab, N., Khan, A. & Lee, Y. S. Transfer learning based deep CNN for segmentation and detection of mitoses in breast cancer histopathological images. *Microscopy (Oxford, England)* **68,** 216–233 (2019).
21. Marques, B. A., Drumond, R. R., Vasconcelos, C. N. & Clua, E. *Deep Light Source Estimation for Mixed Reality.* in *Visigrapp (1: grapp)* (2018), 303–311.
22. Chugh, S., Brousseau, B., Rose, J. & Eizenman, M. *Detection and Correspondence Matching of Corneal Reflections for Eye Tracking Using Deep Learning* 2210–2217 (2021).
23. Funahashi, I., Yamashita, N., Yoshida, T. & Ikehara, M. High Reflection Removal Using CNN with Detection and Estimation, 1381–1385 (2021).
24. Haseeb, M. A., Guan, J., Ristic-Durrant, D. & Gräser, A. DisNet: a novel method for distance estimation from monocular camera. *10th Planning, Perception and Navigation for Intelligent Vehicles (PPNIV18), IROS* (2018).
25. Ronneberger, O., Fischer, P. & Brox, T. U-net: Convolutional networks for biomedical image segmentation, 234–241 (2015).
26. Bleiholder, J. & Naumann, F. Data Fusion. **41.** ISSN: 0360-0300. https://doi.org/10.1145/1456650.1456651 (2009).
27. Masoudnia, S. & Ebrahimpour, R. Mixture of experts: a literature survey. *Artificial Intelligence Review* **42,** 275–293 (2014).
28. Iandola, F. *u. a.* Densenet: Implementing efficient convnet descriptor pyramids. *arXiv preprint arXiv:1404.1869* (2014).
29. Creswell, A. *u. a.* Generative adversarial networks: An overview. *IEEE signal processing magazine* **35,** 53–65 (2018).
30. Karras, T., Laine, S. & Aila, T. *A style-based generator architecture for generative adversarial networks* in *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (2019), 4401–4410.
31. Medsker, L. R. & Jain, L. Recurrent neural networks. *Design and Applications* **5,** 64–67 (2001).
32. Che, Z., Purushotham, S., Cho, K., Sontag, D. & Liu, Y. Recurrent neural networks for multivariate time series with missing values. *Scientific reports* **8,** 1–12 (2018).