

Bachelor-Thesis

Automatische Erkennung von leuchtenden Nachtwolken in
Kamerabeobachtungen

Eingereicht am: 28. Februar 2013

von: Daniel Schmidt
geboren am 13. Mai 1989
in Kreuztal

Zusammenfassung

Die vorliegende Arbeit behandelt die automatische Erkennung von leuchtenden Nachtwolken (im Englischen noctilucent clouds (NLC)) in Kamerabeobachtungen des NLC Kameranetzwerkes des Leibniz-Instituts für Atmosphärenphysik e.V. an der Universität Rostock. Bei NLC handelt es sich um Ansammlungen aus Eiskristallen in der Mesopause. Deren Vorkommen und Form können Aufschluss über den Zustand der Mesosphäre geben.

Während der NLC-Saison zwischen Juni und August werden mehrere GB an Bildern täglich aufgenommen. Da diese manuell auf die Vorkommen von NLC überprüft werden müssen, soll eine automatische Erkennung entwickelt werden. Die automatische Auswertung fällt in den Bereich des maschinellen Sehens und umfasst die Gebiete der Bildverarbeitung und des maschinellen Lernens.

Für die automatische Erkennung werden verschiedene Methoden auf ihre mögliche Einsatzfähigkeit geprüft. Als Lösung wird eine Klassifikation mittels verschiedener statistischer Merkmale und des k-Nearest-Neighbor-Algorithmus vorgestellt. Dabei wird neben der Entwicklung auch auf die Genauigkeit der Ergebnisse eingegangen.

Abstract

This thesis deals with the automatic detection of NLC in images of the camera network from the Leibniz-Institute of Atmospheric Physics e.V. at the University of Rostock for automated observation of NLC. NLC are accumulations of ice particles in the mesopause. The occurrence and form of the NLC can give indications on the current state of the mesosphere.

During the NLC season between June and August several GB pictures are recorded. These have to be classified manually. Therefore an automatic detection is desired. The automatic detection falls within the scope of computer vision, which itself covers the fields of image processing and machine learning.

In this thesis various methods have been tested. Presenting a solution using various statistical features and the k-nearest neighbor algorithm. Covering the development and the accuracy of the proposed method.

Inhaltsverzeichnis

1. Einleitung	5
2. Grundlagen	6
2.1. Die Erdatmosphäre	6
2.1.1. Aufbau	6
2.1.2. Reflexion und Streuung	7
2.1.3. Aerosole	8
2.2. Wolken	9
2.2.1. Wolken der Troposphäre	9
2.2.2. Leuchtende Nachtwolken	10
3. Vorüberlegungen	13
3.1. Auswahl der Bildverarbeitungsbibliothek	13
3.1.1. Vergleich	13
3.1.2. Auswahl	15
3.2. Automatische Detektion unscharfer Bilder	16
4. Lösungsmöglichkeiten	21
4.1. Beurteilung der Farbwerte	21
4.1.1. Trennung von Himmel und Wolken	21
4.1.2. Erkennung von NLC	21
4.2. Erkennung der Bewegung	21
4.2.1. Vordergrund/Hintergrund Erkennung	22
4.2.2. Bewertung der Bewegungsrichtung	22
4.3. Unterschiede in der Struktur	23
4.4. Simulation des Himmels	24
4.5. Klassifizierung mittels überwachten Lernens	25
4.6. Vergleich der Lösungsmöglichkeiten	25
4.7. Auswahl	27
5. Umsetzungen	28
5.1. Simulation des Himmels	28
5.1.1. Entwurf	28
5.1.2. Implementierung	32
5.1.3. Fazit	34
5.2. Klassifizierung mittels überwachten Lernens	36
5.2.1. Entwurf	36
5.2.2. Implementierung	41
5.2.3. Fazit	45

6. Schlussbemerkungen und Ausblick	47
Literaturverzeichnis	48
Abbildungsverzeichnis	51
Tabellenverzeichnis	53
A. Ergebnisse einzelner Merkmale	54
Selbstständigkeitserklärung	55

1. Einleitung

Die Erdatmosphäre hat einen großen Einfluss auf unser Leben. Sie enthält den nötigen Sauerstoff für die Atmung und schützt vor den UV-Strahlen der Sonne. Ebenso hat der Mensch einen großen Einfluss auf die Erdatmosphäre. Durch die Verbrennung fossiler Energieträger und den daraus frei werdenden Treibhausgasen verändert sich ihre Zusammensetzung. Da es sich bei der Atmosphäre um ein komplexes System handelt, können auch relativ kleine Veränderungen der Zusammensetzung zu großen Veränderungen innerhalb des Systems führen.

Um diese Wechselwirkungen besser verstehen zu können, müssen die Eigenschaften der Atmosphäre näher untersucht werden. Dabei gehören die mittleren Atmosphärenschichten zu den vergleichsweise wenig erforschten Gebieten der Atmosphäre. Diese lassen sich normalerweise nur sehr aufwendig untersuchen. Optisch beobachten lassen sich hingegen die sogenannten NLC. Dabei handelt es sich um Ansammlungen von Eiskristallen. Sie entstehen in der Mesopause und können Aufschluss auf deren Zustand geben.

Um diese zu untersuchen, wurde vom Leibniz-Institut für Atmosphärenphysik e.V. an der Universität Rostock ein Kameranetzwerk in Europa aufgebaut. Es umfasst insgesamt mehr als 10 Kameras und reicht von Andenes (69°N,16°E) in Norwegen bis Calar Alto (37.2°N,-2.6°E) in Spanien [1]. Dadurch können NLC im Bereich von 38°N bis fast 80°N beobachtet werden. In Verbindung mit den Daten der Light Detection And Ranging (LIDAR) Messungen in Kühlungsborn und auf ALOMAR soll eine Untersuchung näheren Aufschluss über die NLC geben.

In der NLC-Saison zwischen Juni und August fallen dabei mehr als 7GB an Bildmaterial pro Tag an. Diese müssen manuell auf NLC untersucht werden. Um dies zu automatisieren, soll ein Verfahren entwickelt werden, NLC automatisch in dem Bildmaterial zu detektieren. Dabei liegen bereits mehrere Jahre an manuell untersuchtem Bildmaterial vor.

2. Grundlagen

2.1. Die Erdatmosphäre

Als Erdatmosphäre wird die Gashölle bezeichnet, die die Erde umgibt. Ohne sie wäre ein Leben auf der Erde nicht möglich. Die Luft wird von den Organismen zum Leben benötigt und die Ozonschicht filtert einen Großteil der UV-Strahlung der Sonne, die bei Lebewesen zu Mutationen des Erbguts führen kann.

Die Atmosphäre ist im Vergleich zum Radius der Erde sehr dünn. So beträgt der Radius der Erde fast 6400km. Von der Atmosphäre befindet sich hingegen 99% der Masse innerhalb eines 30km Radius über der Erdoberfläche [2, S.13].

2.1.1. Aufbau

Die Erdatmosphäre wird in verschiedene atmosphärische Schichten unterteilt (Abbildung 2.1). Diese Unterteilung wird aufgrund unterschiedlicher Zusammensetzungen und Temperaturen vorgenommen.

Als Troposphäre wird die unterste Schicht bezeichnet. Der Boden absorbiert einen Großteil der Strahlung, die in die Troposphäre gelangt. Daher ist der Bereich am Boden am wärmsten und die Temperatur sinkt fast linear mit der Höhe [2, S.50]. Durch die Abgrenzung zu den oberen Schichten aufgrund der zunehmenden Kälte und der Tatsache, dass sich 90% der Luft und fast der gesamte Wasserdampf innerhalb der Troposphäre befinden, begrenzt sich das Wetter fast komplett auf die Troposphäre.

Die Stratosphäre wird von der Troposphäre durch die Tropopause abgegrenzt. Die Temperatur bleibt bis zu etwa 20 Kilometer über der Tropopause stabil und steigt danach stark an (Abbildung 2.1). Diese Erwärmung ist auf das Ozon zurückzuführen, welches die UV Strahlen absorbiert [2, S.27]. Trotz dieser Erwärmung ist es in der Stratosphäre zu kalt um Wasserdampf halten zu können. Das Wasser würde gefrieren und es gibt keine starken Luftströme, die die Eiskristalle in der Stratosphäre halten könnten.

In der darüber liegenden Schicht der Mesosphäre sinken die Temperaturen bis zur Mesopause, in der Temperaturen unter -100°C erreicht werden können.

Oberhalb der Mesopause beginnt die Thermosphäre, die durch die Absorption hoch energetischer Strahlen der Sonne bei steigender Höhe eine steigende Temperatur aufweist [2, S.28].




Bild 2.1.: Aufbau der Atmosphärenschichten und durchschnittlicher Temperaturverlauf in Kühlungsborn im Sommer

2.1.2. Reflexion und Streuung

Wie in Unterabschnitt 2.1.1 beschrieben, werden die Strahlen unterschiedlicher Wellenlängen unterschiedlich stark absorbiert. Die Absorption hängt dabei neben der Wellenlänge auch davon ab, auf welche Stoffe das Licht trifft.

Neben der Absorption kann das Licht auch reflektiert und gestreut werden. Bei der Reflexion werden die Strahlen mit dem selben Winkel und der selben Intensität zurück geworfen, mit der sie auf das reflektierende Material getroffen sind. Bei der Streuung wird das Licht hingegen in verschiedene Richtungen gelenkt.

Von der Erde werden rund 50% der Strahlung durch die Landmasse und die Meere absorbiert. Rund 20% werden von den Wolken und der Atmosphäre absorbiert. So

werden insgesamt etwa 70% der ankommenden Strahlung der Sonne absorbiert. Die restliche Strahlung wird zurück in das Weltall gestrahlt. Die Quellen teilen sich in 20% durch die Reflexion der Wolken, 5% durch die Reflexion an der Erdoberfläche und die weiteren 5% durch die Rückstreuung in der Atmosphäre auf [2, S.50]. Etwa die Hälfte der Erde erreichenden Strahlung ist gestreutes Licht [2, S.51].

Die unterschiedliche Streuung von unterschiedlichen Wellenlängen lässt sich auch direkt beobachten. So wird höherfrequentes blaues Licht in der Atmosphäre stärker gestreut als das niederfrequente rote Licht. Dadurch erscheint der Himmel die meiste Zeit des Tages blau. Das weniger gestreute Licht wird vor allem beim Sonnenauf- und -untergang deutlich sichtbar. Die Atmosphäre in der Nähe des Horizonts erscheint viel rötlicher, da der Blauanteil des Lichts durch die größere Streuung nicht mehr den direkten Weg in das Auge des Beobachters findet. Diese beobachtete Streuung nennt man Rayleigh-Streuung. Diese Streuung ist nur an im Vergleich zur Wellenlänge kleinen Teilchen zu beobachten. Bei größeren Partikeln, wie wir sie bei Nebel und Smog vorfinden, werden alle Wellenlängen gleichmäßiger gestreut, was auch das eher graue Licht erklärt [2, S.52].

2.1.3. Aerosole

Aerosole sind Gemische aus kleinsten Partikeln, die aus verschiedenen Quellen in die Atmosphäre gelangen können, und einem Gas. Diese können natürlichen Ursprungs als auch dem Menschen geschuldet sein. Dazu gehören Salz aus dem Meerwasser, Erde, die in die Luft gelangt ist, Pollen, Mikroorganismen sowie Asche und viele weitere [2, S.20]. Der Großteil der Aerosole befindet sich folglich auch im erdnahen Bereich der Atmosphäre. Durch Luftströmungen können sie jedoch auch in höhere Lagen gelangen.

Wie man an der Simulation in Abbildung 2.2 sieht, haben Aerosole einen großen Einfluss auf die Streuung des Lichts.

Durch die im Vergleich zu den Luftmolekülen relativ großen Partikeln werden unterschiedliche Wellenlängen gleichmäßiger gestreut.




Bild 2.2.: Simulation mit und ohne Aerosole für den 21.06.2012 in Wismar um 19:50 UTC

2.2. Wolken

2.2.1. Wolken der Troposphäre

Wolken in der Troposphäre bestehen aus sehr kleinen Wassertropfchen und/oder Eiskristallen. Zu den Voraussetzungen für die Bildung von Wolken gehören einerseits Kondensationskerne wie Staub und Aerosole. Andererseits muss die Luftfeuchtigkeit hoch genug sein. Sind keine Kondensationskerne vorhanden, muss die relative Luftfeuchtigkeit weit über 100% steigen und eine niedrige Temperatur herrschen, dass sich Wassertropfen bilden können [2, S.130].

Die entstehenden Wolken können dabei eine Vielzahl an unterschiedlichen Formen und Strukturen annehmen. Diese werden üblicherweise auf der Basis des Systems, welches Luke Howard 1803 entworfen hat, klassifiziert. Als grundlegende Eigenschaften werden die Form und die Höhe zur Klassifizierung verwendet. Aufgrund der Form werden die Wolken in drei Untergruppen unterteilt [2, S.131]. Cirrus-Wolken entstehen in großer Höhe. Sie sind sehr weiß und dünn. Durch die geringe Optische Dichte sind die Cirrus-Wolken sehr hell. Auch beim Sonnenauf- und -untergang stechen sie hervor, da sie durch die Höhe noch länger als die anderen Wolken beleuchtet werden. Cumulus-Wolken hingegen sind sehr dichte Wolken, die sich bei hoher Luftfeuchtigkeit im mittleren Bereich der Troposphäre bilden. Die Unterseite ist meist dunkel, wobei der obere Teil von der Sonne beschienen weiß leuchtet. Stratus-Wolken entstehen nahe der Erdoberfläche und sind strukturlos. Sie bilden meist eine durchgängige Schicht.

2.2.2. Leuchtende Nachtwolken

Leuchtende Nachtwolken (im Englischen NLC) bestehen aus Anhäufungen von Eiskristallen. Sie entstehen in der Mesopause oberhalb der Mesosphäre bei ungefähr 83km (Abbildung 2.1). Aufgrund ihrer Höhe werden sie noch von der Sonne beleuchtet, obwohl durch die Dämmerung die troposphärischen Wolken nicht mehr beleuchtet werden (Abbildung 2.3). Das Sonnenlicht wird reflektiert, sodass die NLC dem Beobachter als leuchtende Wolke nahe dem Horizont erscheint (Abbildung 2.4).




Bild 2.3.: NLC reflektiert Licht der Sonne zum Beobachter. Troposphärische Wolken sind im Schatten.



Bild 2.4.: Eine NLC am 10.7.2011 um 01:45:23 UTC in Wismar. Aufnahme durch automatisierte Kamera des IAP.

Leuchtende Nachtwolken wurden zuerst 1885 beschrieben [3]. Dort wurde die NLC als ein See silbern weiß glänzender wellenartiger Wolken beschrieben, die sich offensichtlich in großer Höhe befanden. Auch heute sind noch viele Fragen zu den NLC ungeklärt. Aufgrund der großen Höhe sind sie bei weitem schwerer zu untersuchen als die sehr bodennahen troposphärischen Wolken. Während für diese relativ wenig Aufwand zur Untersuchung aufgewendet werden muss, können genauere Untersuchungen der NLC nur mit teuren Messinstrumenten wie LIDAR und Raketen gewährleistet werden.

NLC können auf der Nordhemisphäre in den Monaten Juni bis August meistens bei solaren Winkeln (Abbildung 2.5) zwischen -5 und -17 Grad beobachtet werden. Die besten Beobachtungsbedingungen sind bei Längengraden von 51°N bis 54°N vorzufinden [1].

NLC können unterschiedliche Formen annehmen. Diese können in fünf Kategorien eingeordnet werden [4, S.9]. Schleier sind sehr dünne NLC ohne klare Struktur. Von der Form haben sie Ähnlichkeiten mit den Cirrus-Wolken. Bänder haben hingegen lange Schlieren, die meist parallel zu einander verlaufen. Wellen bestehen aus kurzen, eng und parallel verlaufenden Schlieren, die Ähnlichkeiten mit einer Feder haben. Wirbel verlaufen ringartig und haben oft ein dunkles Zentrum. Die restlichen Arten werden in die Kategorie Komplexe Strukturen zusammengefasst. Diese ist nochmals in vier Untergruppen aufgeteilt. In der ersten Subkategorie werden alle NLC zusammengefasst, die nicht in die vier vorigen Kategorien oder den drei folgenden Subkategorien eingeordnet werden können. Die zweite Subkategorie enthält NLC, die breite Knoten in der Struktur enthalten. Kreuzen sich NLC aus der Wirbel- und Wellen-Kategorie, so werden sie der dritten Subkategorie zugeordnet. Als letzte Subkategorie werden die NLC mit einer netzartigen Struktur zusammengefasst.

Erkennungsmerkmale

NLC sind immer heller als der Himmel und die troposphärischen Wolken. Eine Ausnahme besteht wenn die troposphärischen Wolken durch künstliches Licht beleuchtet werden und dadurch stark erhellt wirken. Dies lässt sich gut an dem Rauch der Schornsteine in Abbildung 2.4 beobachten. Eine Differenzierung über die Farbe und die Form ist dann nötig. Auch die Cirrus-Wolken können aufgrund ihrer Höhe noch länger beleuchtet werden als die übrigen troposphärischen Wolken. Dieser Zeitraum ist jedoch stark begrenzt und die Farbe ändert sich schnell zu Gelb- und Orange-




Bild 2.5.: Visualisierung des solaren Winkels. 90° bei Zenith, 0° bei Sonnenauf- und -untergang sowie negative Grade bei Nacht

tönen. Weiterhin lassen sich NLC auch über ihre Bewegungsrichtung erkennen. Sie bewegen sich üblicherweise von Nordost nach Südwest.

3. Vorüberlegungen

In diesem Kapitel sollen die Schritte geklärt werden, die vor der Hauptaufgabe bearbeitet werden müssen.

3.1. Auswahl der Bildverarbeitungsbibliothek

Um eine effiziente Entwicklung zu gewährleisten, ist die Benutzung einer Bildverarbeitungsbibliothek sinnvoll. Diese bietet abhängig von der Bibliothek eine gute Basis zur Verwendung und Erweiterung dieser Funktionalitäten.

Aufgrund der ständig wachsenden Verbreitung der Bildverarbeitung gibt es eine Vielzahl von kommerziellen als auch nicht kommerziellen Bildverarbeitungsbibliotheken. In diesem Kapitel sollen die gängigsten Bildverarbeitungsbibliotheken verglichen werden und mit den Vor- und Nachteilen für die Aufgabe bewertet werden.

3.1.1. Vergleich

Bei der Auswahl der näher zu betrachtenden Bildverarbeitungsbibliotheken wurde ein Schwerpunkt auf die frei verfügbaren *Open Source* Bibliotheken gelegt. Eine Übersicht über die untersuchten Bibliotheken, deren Lizenzen sowie den unterstützten Betriebssystemen und Programmiersprachen findet sich unter Tabelle 3.1.

OpenCV hat eine sehr große Unterstützung für verschiedene Betriebssysteme und Programmiersprachen. Neben den offiziellen Schnittstellen gibt es auch eine Vielzahl an Wrapper für verschiedene Programmiersprachen. Ebenfalls zeichnet sich *OpenCV* durch eine hohe Geschwindigkeit und einen großen Umfang von Funktionen aus. Diese reichen von Standard Bildverarbeitungsmethoden bis hin zu Funktionen des maschinellen Lernens und Sehens [5].

ImageJ ist eine im Bereich der Medizin entwickelte Bildverarbeitungsbibliothek. Daraus ist auch die weite Verbreitung in den Bereichen der Biologie und Medizin zu erklären. Es gibt eine große Unterstützung für medizinische Bilddaten und benötigte

Tabelle 3.1.: Vergleich gängiger Bildverarbeitungsbibliotheken

	Lizenz	Betriebssystem	Sprachen	URL
OpenCV	BSD	Windows, Linux, Mac, BSD, Android, iOS	C, C++, Python, Java	opencv.org
ImageJ	Public Domain	Windows, Linux, Mac OS X	Java	rsb.info.nih.gov/ij
VLFeat	BSD	Windows, Linux, Mac OS X	C, MATLAB, Python	vlfeat.org
SimpleCV	BSD	Windows, Linux, Mac OS X	Python	simplecv.org
skimage	BSD	Windows, Linux, Mac OS X	Python	scikit-image.org
Matlab	Kommerziell	Windows, Unix	MATLAB	mathworks.com
HALCON	Kommerziell	Windows, Linux, Mac OS X	C, C++, C#, VB.NET, Delphi	mvtec.com/halcon

Algorithmen [6]. Dies und die Möglichkeit einer Bedienung ohne Programmierkenntnisse sind ausschlaggebend für die weite Verbreitung, die sich auch in der Zahl der gefundenen wissenschaftlichen Dokumente von fast 50.000 bei *Google Scholar* niederschlägt.

VLFeat ist eine relativ kleine, auf die Erkennung von Merkmalen spezialisierte, Bibliothek. Zu den bekanntesten Implementierungen zählen Algorithmen wie HOG, SIFT und k-Means [7].

SimpleCV ist ein Framework, welches Gebrauch von den wissenschaftlichen *Python* Bibliotheken *NumPy* und *SciPy* [8], sowie von *OpenCV* macht. Dabei wird viel Wert auf die Einfachheit der Bedienung gelegt [9]. Durch die Einbindung der verschiedenen Bibliotheken hat *SimpleCV* auch einen sehr großen Funktionsumfang.

Skimage bzw. *scikit-image* ist eine Erweiterung für die *SciPy* [8] Bibliothek und benutzt zur Berechnung Funktionalitäten von *NumPy*. Der Funktionsumfang reicht dabei von Standardfunktionen wie Kantendetektion bis zu Segmentationsalgorithmen und Merkmalsextraktion. Bei einer Verwendung maschinellen Lernens kann die *SciPy* Erweiterung *scikit-learn* verwendet werden [10].

Matlab ist ein kommerzielles Programm, dessen Hauptaufgabe in der Berechnung mit Matrizen liegt. Zu einer Vielzahl an verfügbaren Erweiterungen zählt auch ei-

ne Bildverarbeitungsbibliothek. Diese bietet ähnlich wie *OpenCV* Funktionen der klassischen Bildverarbeitung als auch des maschinellen Lernens und Sehens [11]. Aufgrund der einfachen Bedienung wird *Matlab* oft bei der Herstellung von Prototypen benutzt.

Bei *HALCON* handelt es sich ebenfalls um ein kommerzielles Projekt. Es findet vor allem in der industriellen Bildverarbeitung Verwendung. Es gibt eine mit *OpenCV* und *Matlab* vergleichbare Breite an Funktionen [12].

3.1.2. Auswahl

Bei vielen Bibliotheken werden die Unterschiede erst bei näherer Betrachtung der implementierten Algorithmen deutlich.

Als Grundbibliothek wird *OpenCV* ausgewählt. *OpenCV* bietet unter einer offenen Lizenz eine große Auswahl an optimierten Funktionen an.

Als Programmiersprache wird *Python* ausgewählt. Ein Vorteil gegenüber den anderen Programmiersprachen liegt unter anderem in der Integration des *Python* Interface von *OpenCV* mit *NumPy* [8]. Die Bilder werden automatisch als *NumPy* Array zur Verfügung gestellt, sodass neben der Grundfunktionalität von *OpenCV* auch auf Funktionen von *NumPy* zurückgegriffen werden kann. Dadurch lassen sich auch einfacher eigene Algorithmen implementieren. Außerdem lassen sich die Bibliotheken *SciPy*, sowie deren Erweiterungen *scikit-image* und *scikit-learn* mit der Verwendung von *NumPy* Arrays einfach in das Programm integrieren. Zur Visualisierung der Ergebnisse bietet sich dadurch außerdem *Matplotlib* an [13].

3.2. Automatische Detektion unscharfer Bilder

Ein Problem, das gelegentlich bei der Aufnahme der Bilder im NLC-Kameranetzwerk vorkommt, ist dass die Kamera die Objekte im Blickfeld nicht richtig fokussieren kann. Dies führt zu unscharfen Aufnahmen (Abbildung 3.1). Bei einer Bewertung dieser Bilder könnte dies zu falschen Klassifizierungen führen.

Da der Erkennung von unscharfen Aufnahmen durch die immer weitere Verbreitung der digitalen Fotografie eine wichtige Bedeutung zukommt, wurden bereits eine Vielzahl von Algorithmen zur automatischen Erkennung entwickelt [14] [15]. Dabei werden oftmals die Schärfe und die Art der Kanten im Bild bewertet [16].

Im vorliegenden Fall besteht der Vorteil zur Erkennung von unscharfen Bildern darin, dass die Bilder in einer Zeitfolge aufgenommen wurden. In einer manuellen Untersuchung von etwa 1500 Bildern wurden 14 Bilder mit einer starken Unschärfe gefunden. Dies entspricht etwas unter 1% der Bilder. Dieses ungefähre Verhältnis bestätigt sich auch bei der Untersuchung weiterer Bilder. Aus diesen Voraussetzungen lässt sich eine Erkennung unscharfer Bilder anhand der negativen Änderung der vorliegenden Kanten in der Zeitfolge feststellen.

Zum ersten Test wurde eine Bildmenge mit einer außergewöhnlich hohen Anzahl an unscharfen Bildern ausgewählt. Diese wurden manuell sortiert und anhand der Kanten als auch der Dateigröße verglichen (Abbildung 3.2).



Bild 3.1.: Beispiel für ein unscharfes Bild

Für die Bewertung der Kanten wurde nur der untere Teil der Aufnahme mit dem Stadtbild verwendet. Dies soll verhindern, dass Veränderungen der Wolkendecke zu




Bild 3.2.: Vergleich Kantenpixel bzw. Dateigröße an einer vorsortierten Bildmenge

großen Änderungen der Kanten führt. Außerdem macht das Stadtbild mit den klar definierten Kanten nahezu den kompletten Anteil der Kanten im Bild aus. Zum einfachen Vergleich wurde die Summe aller Pixelwerte im Bild nach der Anwendung eines Kantenfilters verwendet.


Die Dateigröße wurde zur Beurteilung verwendet, da die Bilder als JPEG-Bilder gespeichert werden. Bei der Konvertierung in dieses Format werden Verfahren angewendet, die bei der Speicherung von Bildern mit niedrigeren Frequenzen eine geringere Dateigröße zufolge hat.

Bei dem Vergleich stellt sich heraus, dass sowohl bei der Verwendung des Kantenvergleichs als auch bei dem Vergleich der Dateigröße eine eindeutige Unterscheidung möglich ist.

Um die Effektivität zu testen, wurden beide Verfahren an zwei unterschiedlichen Tagen getestet. Einmal am 02.07.2012 (Abbildung 3.3) und am 03.07.2012.

Der größte Anteil der Falsch deklarierten Bilder liegt im Bereich wo der Sonnenstand größer als 1 Grad ist. Der Grund liegt in einer großen Veränderung der Kantenstärke innerhalb kurzer Zeit. Durch die Veränderung der Wolkendecke ändert sich auch die Intensität des Lichts, welches wiederum einen großen Einfluss auf die Kantenstärke hat. Dadurch werden negative Änderungen fälschlicherweise als Unschärfe erkannt. Da zu diesen Zeiten aufgrund der hohen Helligkeit jedoch kaum Probleme bei der Fokussierung herrschen, kann dieser Bereich in der Bewertung ignoriert werden.

Das Verfahren zur Klassifizierung besteht aus mehreren Teilen. Zuerst werden die Bilder nach den zuletzt beschriebenen Verfahren bewertet. Aus den drei vorigen und



(a) Automatische Erkennung durch Kantenpixel (b) Automatische Erkennung durch Dateigröße in Byte


Bild 3.3.: Bilder vom 02.07.2012 in Wismar

den drei nachfolgenden Werten wird der ungefähr zu erwartende Wert berechnet (Listing 3.1). Dies entspricht in etwa einem Tiefpass ohne die Einbeziehung des zu bewertenden Wertes.


```
1 kernel = np.array([3,5,7,7,5,3])
2 folge[i] = np.array([sY[i-3], sY[i-2], sY[i-1], sY[i+1], sY[i+2], sY[i+3]])
3 erwartet[i] = (folge*kernel).sum()/(kernel.sum())
```

Listing 3.1: Berechnung des zu erwartenden Wertes

Selbst wenn die durchschnittliche Abweichung sehr klein wäre, würden die Werte so gut wie nie genau dem berechneten Wert entsprechen. Daher werden mehrere Bewertungsgrundlagen festgesetzt. Zuerst muss die Abweichung zum erwarteten Wert negativ sein. Dies kann festgelegt werden, da die scharfen Bilder aufgrund ihrer Häufigkeit die Norm bilden. Die unscharfen Bilder haben im Vergleich einen niedrigeren Wert. Allein diese Bewertungsgrundlage würde ungefähr 50% der Bilder als unscharf bewerten. Zum weiteren wird festgelegt, welche Abweichung der reale Wert im Vergleich zum berechneten Wert haben darf. Als Ausgangslage wird die bisherige durchschnittliche Abweichung genommen. Da dies nur die durchschnittliche Abweichung ist, würden immer noch fast 25% der Bilder als unscharf bewertet werden. Um den optimalen Wert für die Abweichung zu berechnen, wurde die Präzision des Klassifikators mit verschiedenen Vielfachen der durchschnittlichen Abweichung getestet (Abbildung 3.4). Wie zu erwarten, sinkt der Anteil fälschlicherweise scharf und zurecht unscharf bewerteter Ergebnisse mit der Steigerung der Toleranz. Im gleichen Verhältnis erhöht sich der Anteil fälschlicherweise unscharf und zurecht scharf bewerteter Ergebnisse.



(a) 02.07.2012



(b) 03.07.2012



Bild 3.4.: Beurteilung des Klassifikators mit verschiedenen maximalen Abweichungen

Bei einer näheren Betrachtung der Ergebnisse fällt auf, dass ungefähr ab einer dreifachen durchschnittlichen Abweichung der Anteil komplett scharfer Bilder fälschlicherweise als unscharf bewertet gegen 0% geht. Dies ist im Graphen nicht erkennbar, da nur deutlich unscharfe Bilder als unscharf deklariert wurden. Die fälschlicherweise als unscharf bewerteten Bilder zeigen im Vergleich zu ihren Nachbarbildern jedoch auch Unschärfe. Am einfachsten sieht man dies bei einer verstärkten Differenz zweier Nachbarbilder, bei der ein Bild leicht unscharf und das andere scharf ist (Abbildung 3.5).


Bild 3.5.: Verstärkte Differenz eines Bildes mit mit einem leicht unscharfen Nachbarbild



Aus diesen Ergebnissen lässt sich schließen, dass durch die Auswahl des Koeffizienten eine angepasste Auswahl getätigt werden kann. Dadurch können die Verfahren so angepasst werden, dass nur die Bilder ignoriert werden, die bei der weiteren Verarbeitung zu Problemen führen könnten.

In Abbildung 3.6 und Abbildung 3.7 können die Ergebnisse bei einem Ausschluss der Bilder bei einem Sonnenstand größer 1 Grad und einer erlaubten Abweichung von vier mal der erlaubten Differenz betrachtet werden.



(a) Automatische Erkennung durch Kantenpixel (b) Automatische Erkennung durch Dateigröße

Bild 3.6.: Bilder vom 02.07.2012 in Wismar



(a) Automatische Erkennung durch Kantenpixel (b) Automatische Erkennung durch Dateigröße

Bild 3.7.: Bilder vom 03.07.2012 in Wismar

4. Lösungsmöglichkeiten

Die Hauptaufgabe dieser Thesis besteht in der Segmentierung und Klassifikation der Bilder in Himmel, troposphärische Wolken und nachleuchtende Wolken. Dazu werden im weiteren Verlauf verschiedene Methoden überprüft.

4.1. Beurteilung der Farbwerte

Durch die unterschiedlichen Streuungseigenschaften (Unterabschnitt 2.1.2) von Himmel und Wolken gibt es deutliche Unterschiede bei der Helligkeit und der Farbe. Hier sollen nun erste Ansätze zur Unterscheidung untersucht werden.

4.1.1. Trennung von Himmel und Wolken

Eine Trennung von Himmel und Wolken wird in [17] durch einen pixelweisen Vergleich der Rot- und Blauwerte erreicht. Eine Möglichkeit besteht in der Bewertung des Verhältnisses des Rotwertes zu dem Blauwert des Pixel. Eine zweite Möglichkeit besteht in dem Vergleich der Differenz beider Werte. Dabei wird beim Verhältnis ein Schwellwert von 0.8 und bei der Differenz ein Schwellwert von 30 empfohlen.

4.1.2. Erkennung von NLC

Die Farbe der NLC ist meist leicht bläulich, wobei näher am Horizont sichtbare NLC auch eine leicht rötliche Farbe annehmen können. Gemeinsam ist allen NLC, dass sie im Vergleich zu den Wolken und dem Himmel heller sind. Der deutlichste Kontrast zum Hintergrund ist bei den Blauwerten zu erkennen (Abbildung 4.1).

4.2. Erkennung der Bewegung

Eine weitere Herangehensweise besteht in der Verwendung von Informationen der Bildsequenz (Abbildung 4.2).




Bild 4.1.: Vergleich der Helligkeit unterschiedlicher Kanäle




Bild 4.2.: Veränderung zwischen zwei aufeinander folgenden Bildern Wismar 09.07.2011 (Uhrzeit in UTC)

4.2.1. Vordergrund/Hintergrund Erkennung

Um den Himmel von den Wolken zu trennen, besteht eine Möglichkeit darin, den Vordergrund und den Hintergrund zu erkennen. Da sich der Himmel abhängig von der Position der Sonne ändert, muss der Hintergrund in gewissen Abständen angepasst werden. Möglich wäre es, das Bild in bestimmte Bereiche zu unterteilen. Dann wird in einem bestimmten Zeitabschnitt der Bereich von den verschiedenen Bildern verglichen. Finden sich mehrere Abschnitte, die nur geringe Unterschiede aufweisen, ist es wahrscheinlich, dass diese Teile des Himmels darstellen.

4.2.2. Bewertung der Bewegungsrichtung

Eine weitere Möglichkeit, NLC von troposphärischen Wolken zu unterscheiden besteht darin, ihre Bewegungsrichtung und Geschwindigkeit zu bewerten. Während NLC sich meist mit geringer Geschwindigkeit von Nordosten in Richtung Südwest bewegen, ist die Geschwindigkeit der troposphärischen Wolken meist höher und häufiger in Ostrichtung. Um diese Daten bewerten zu können, müssen einzelne Wolken im Bild identifiziert werden und im Bildverlauf wiedererkannt werden. Dies wäre




Bild 4.3.: Hochpassfilter

zum Beispiel durch eine Segmentierung anhand der Farbe und der Verwendung eines Verfolgungs-Algorithmus möglich.

4.3. Unterschiede in der Struktur

Zwischen Wolken und dem Himmel gibt es große strukturelle Unterschiede. Wie in Unterabschnitt 2.2.1 beschrieben, haben unterschiedliche Wolkenarten jedoch auch sehr unterschiedliche Strukturen. Ziel ist es nun, die Unterschiede zwischen Himmel, troposphärischen Wolken und NLC zu nutzen, um die unterschiedlichen Bereiche im Bild zu identifizieren.

NLC haben eine sehr hochfrequente Struktur, die sich stark von dem niederfrequenten Himmel abgrenzt. Ein Ansatz wäre daher, einen Hochpassfilter anzuwenden. Eine Variation wäre die Differenz eines mit einem Gaußfilter (Gleichung 4.1) bearbeiteten Bilds mit dem Originalbild zu berechnen (Gleichung 4.2).

$$\frac{1}{16} \times \begin{bmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{bmatrix} \quad (4.1)$$

$$\frac{1}{16} \times \begin{bmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{bmatrix} - \begin{bmatrix} 0 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix} = \frac{1}{16} \times \begin{bmatrix} 1 & 2 & 1 \\ 2 & -12 & 2 \\ 1 & 2 & 1 \end{bmatrix} \quad (4.2)$$

Dadurch würden nur hochfrequente Änderungen innerhalb eines Bereichs sichtbar (Abbildung 4.3).

Wird ein Hochpassfilter bei einem Bild kurz vor/nach einem Sonnenauf- oder -untergang angewendet, fällt auf, dass in der Nähe des Horizonts der Übergang von Blau zu Rot als hochfrequent detektiert wird. Um dies zu verhindern, ist eine Änderung der Filter-Matrix nötig. Anstatt wie mit einer quadratischen Matrix die vertikalen und horizontalen Änderungen gleichmäßig zu gewichten, muss ein stärkeres Gewicht auf die horizontale Veränderung gelegt werden (Gleichung 4.3).

$$\frac{1}{40} \times \begin{bmatrix} 1 & 2 & 4 & 2 & 1 \\ 2 & 4 & 8 & 4 & 2 \\ 1 & 2 & 4 & 2 & 1 \end{bmatrix} - \begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix} = \frac{1}{40} \times \begin{bmatrix} 1 & 2 & 4 & 2 & 1 \\ 2 & 4 & -32 & 4 & 2 \\ 1 & 2 & 4 & 2 & 1 \end{bmatrix} \quad (4.3)$$

4.4. Simulation des Himmels

Eine weitere Möglichkeit, die bereits in [18] beschrieben wurde, besteht in der Simulation des Himmels. Dadurch ließen sich alle Bereiche, die nicht dem zu erwarteten Wert entsprechen, als Objekte im Vordergrund definieren. Dazu gehören die troposphärischen Wolken, NLC und andere Objekte wie Sterne. Auch der Aufwand zur Unterscheidung zwischen troposphärischen Wolken und NLC könnte stark reduziert werden, da die Zunahme der Helligkeit (NLC) und die Abnahme (troposphärische Wolken) zu bestimmten solaren Winkeln bereits bestimmende Merkmale sein können.

Um den Himmel zu simulieren, muss berechnet werden, mit welcher Intensität das Licht die Kamera theoretisch erreichen sollte. Dazu müssen die Position der Sonne, die Position und Richtung der Kamera sowie die Streuungseigenschaften der Atmosphäre bekannt sein.

LibRadtran [19] ist eine Sammlung von Funktionen und Programmen zur Berechnung der Streuung der Sonnenstrahlen in der Atmosphäre. Mit dem Hauptprogramm *uvspec* lassen sich die Strahlungstransferrechnungen im kompletten Spektrum der Sonne berechnen [20]. Es bietet eine weite Auswahl an Optionen für die Atmosphäre. Dazu gehören die Zusammensetzung, Aerosole, Wolken und weitere. Außerdem bietet *LibRadtran* eine Vielzahl an separaten Programmen zur Berechnung verwandter Aufgaben.

4.5. Klassifizierung mittels überwachten Lernens

Anstatt die Unterscheidungsmerkmale einzeln zu betrachten, wäre es sinnvoll, die Merkmale gemeinsam zu untersuchen und daraus die Entscheidung zu fällen, zu welcher Klasse ein Teil des Bildes gehört. Dazu wäre es sinnvoll, durch die Untersuchung bereits bekannter Beispiele auf die möglichen Unterscheidungsmerkmale zu schließen. Dazu wird von jeder Klasse eine Menge an Beispielen ausgesucht. Zu jedem dieser Beispiele wird eine Menge einfach vergleichbarer Merkmale berechnet. Aus diesen Daten kann nun mithilfe eines Algorithmus zum überwachten Lernen auf die Klasse eines unbekannten Bereichs geschlossen werden. Dieser Ansatz wurde bereits mehrfach erfolgreich für die Klassifizierung troposphärischer Wolken verwendet [21] [22] [23] [17].

4.6. Vergleich der Lösungsmöglichkeiten

Eine Trennung von Himmel und Wolken anhand des Vergleichs der Blau- und Rotwerte ist an den Beispielbildern Abbildung 4.4 und Abbildung 4.5 nicht erfolgreich. Eine Anwendung dieses Verfahrens ist nur bei einem begrenzten Bereich des solaren Winkels sinnvoll. Zur Verdeutlichung befinden sich unter Abbildung 4.6 zwei 2D Histogramme vom Rot- und Blauwert. Zum Vergleich wurde ein Bild aus der Nacht und ein Bild am Tag nebeneinander gestellt. Dabei lässt sich feststellen, dass bei beiden das Verhältnis vom Rot- zum Blauwert fast linear ist. Eine Grenze zur Klassifikation ist bei dem Nachtbild jedoch schwer zu setzen. Durch die geringe Helligkeit sind die Unterschiede in der Farbe von Himmel und troposphärischen Wolken marginal. Eine noch schwierigere Unterscheidung besteht hingegen bei Sonnenauf- und -untergängen (Abbildung 2.4). In der Nähe des Horizonts nimmt der Rotanteil stark zu und der Blauanteil ab. Dies ist den jeweiligen Streuungseigenschaften der unterschiedlichen Wellenlängen geschuldet (Unterabschnitt 2.1.2). Daher ist eine Trennung von Himmel und Wolken durch den Vergleich der Rot- und Blauwerte nur bei hohen solaren Winkeln einsetzbar. Da die Erkennung von NLC jedoch nur bei solaren Winkeln unter 0 Grad möglich ist, kann dieses Verfahren hier nicht eingesetzt werden.

Eine Erkennung von NLC anhand der Farbe ist vor allem durch die Verarbeitung der Blauwerte sinnvoll. Ein Schwellwert auf den Blaukanal zu setzen wäre somit eine offensichtliche Lösung. In einigen Fällen wäre dies bereits ein ausreichendes Kriterium. Abgesehen von den beleuchtetem Rauch des Schornsteins haben nur die




Bild 4.4.: Erkennung des Himmels durch Verhältnis Rot- zu Blauwert




Bild 4.5.: Erkennung des Himmels durch Differenz Rot- zu Blauwert




Bild 4.6.: Vergleich 2D Histogramm Rot- zu Blauwert eines wolkenlosen Himmels in der Nacht und am Tag

NLC bei einem niedrigen solaren Winkel einen hohen Blauwert. Bei höheren solaren Winkeln oder relativ schwachen NLC ist die Erkennung allein anhand der absoluten Helligkeit jedoch nicht möglich.

Eine Vordergrund / Hintergrund Erkennung anhand der Bewegung ist nicht grundsätzlich stabil. Es ist nicht gesichert, dass sich in einem bestimmten Zeitraum ein wolkenloser Himmel vorfindet. Außerdem lassen sich vor allem nachts nur geringe Strukturen in den troposphärischen Wolken erkennen, was dazu führen könnte, dass fälschlicherweise Wolken als Himmel deklariert werden.

Die Bewertung der Bewegungsrichtung stößt auf ähnliche Probleme. So sind die Geschwindigkeit und Bewegungsrichtung nicht ausreichende Bewertungsgrundlagen für die Klassifizierung.

Unterschiede in der Struktur lassen sich nur schwer alleine festsetzen. Besser wäre eine Verbindung mit der Klassifizierung durch überwachtes Lernen.

Die Simulation des Himmels ermöglicht eine einfache Unterscheidung zwischen Himmel, troposphärischen Wolken und NLC. Unterscheidet sich der zu erwartende Wert vom gemessenen Wert über ein bestimmtes Maß nicht, kann davon ausgegangen werden, dass es sich um ein Pixel des Himmels handelt. Zu den solaren Winkeln, bei denen eine NLC zu erwarten ist, lassen sich außerdem NLC durch die erhöhte Helligkeit von der niedrigeren Helligkeit der troposphärischen Wolken unterscheiden. Unklar ist jedoch, welche Genauigkeit bei der Simulation erreicht werden kann.

Eine Klassifizierung mittels überwachtem Lernen hat einige große Vorteile. So können verschiedene Merkmale berücksichtigt werden, ohne dass für jedes Merkmal selbstständig Grenzwerte und Bedingungen festgelegt werden müssen. Ein Nachteil besteht jedoch darin, dass das zu untersuchende Gebiet nur alleinstehend betrachtet wird. Somit werden die Eigenschaften, die erst aus dem Gesamtbild gewonnen werden, nicht berücksichtigt. Dazu gehören Eigenschaften wie die Geschwindigkeit, Bewegungsrichtung der Objekte und die Eigenschaften im Vergleich zum Gesamtbild.

4.7. Auswahl

Als Fazit lässt sich ziehen, dass sich sowohl eine Simulation des Himmels als auch das überwachte Lernen mögliche stabile Lösungsmöglichkeiten zur Erkennung aller drei Klassen darstellen.

5. Umsetzungen

5.1. Simulation des Himmels

5.1.1. Entwurf

Die Entwicklung kann grob in vier Abschnitte geteilt werden (Abbildung 5.1). Zuerst müssen die benötigten Parameter für die Simulation berechnet werden. Anhand dieser Parameter kann mit Hilfe von *uvspec* der Himmel simuliert werden. Die Ausgabe kann dann in ein RGB-Bild umgesetzt werden. Da nun das simulierte Bild vorliegt, kann die Differenz zum aufgenommenen Bild berechnet werden.




Bild 5.1.: Vorgehen zur Klassifizierung durch Simulation des Himmels

Berechnung der Parameter des Zielbildes

Die benötigten Parameter lassen sich in vier Untergruppen aufteilen. Die Position der Sonne, die durch die Zeit, den solaren Winkel und den Azimuth bestimmt wird. Die Position und Richtung der Kamera aus den Koordinaten, der Höhe sowie den aufgenommenen Bereich. Als dritte Untergruppe die atmosphärischen Eigenschaften und als letzte Gruppe die Eigenschaften der Strahlung. Aufgeteilt in die zu berechnende Wellenlänge und die Auswahl des Löser für die Strahlungstransferrechnungen.

Aus den Koordinaten und der Zeit lässt sich mithilfe des Programms *zenith*, welches Teil von *LibRadtran* ist, der solare Winkel und der Azimuth berechnen. Beachtet werden muss, dass *zenith* die geographische Länge mit Westen als Positiv interpretiert, *uvspec* den Nullpunkt des Azimuth als Süden definiert und den solaren Winkel bei Zenith auf 0 Grad sowie den Sonnenuntergang auf 90 Grad definiert.

Die Parameter der Kamera können durch die Anwendung eines Programms erhalten werden, welches diese anhand der Zeit, der Koordinaten und den im Bild sichtbaren Sternen berechnen kann. Eine Visualisierung der Parameter der Kamera findet sich unter Abbildung 5.2.

Die atmosphärischen Eigenschaften und die der Strahlung können nicht eindeutig definiert werden. Für die Atmosphäre kann die Datei *afglss* verwendet werden, welche vordefinierte Eigenschaften für den Sommer in der Nordhemisphäre bereitstellt. Damit lässt sich die Rayleighstreuung und die Absorption der Atmosphäre definieren. Außerdem können noch Aerosole hinzugefügt werden. Für die Strahlung können die gewünschten Wellenlängen ausgewählt werden. Diese liegen für den sichtbaren Bereich zwischen 380nm und 780nm. Der Standard Löser, der den gesamten Bereich des solaren Winkels abdeckt ist *sdisort*.

Simulation

Für die Simulation werden die einzelnen Eigenschaften in jeweils einer Zeile einer Textdatei geschrieben (Listing 5.1). Für spezifische Berechnungen gibt es noch eine Vielzahl an weiteren Optionen [20, S.20].

In [18] wird die Simulation mit einer monochromatischen Wellenlänge von 520nm berechnet. Um die korrekten RGB-Werte zu erhalten, müssen hingegen die Ergebnisse zu den verschiedenen Wellenlängen unterschiedlich gewichtet werden [24]. Dazu




Bild 5.2.: Visualisierung der Parameter der Kamera

gibt es in *uvspec* die Möglichkeit, als Ausgabe Intensitäten für die drei Kanäle Rot, Grün und Blau zu erhalten.

```

1 atmosphere_file ../data/atmmod/afglss.dat #Atmosphaerische Eigenschaften
2 solar_file ../data/solar_flux/atlas_plus_modtran #Eigenschaften der Strahlung
3 time 2011 6 27 21 46 48 #Zeit
4 latitude 53.89 #Geographische Breite
5 longitude 11.46 #Geographische Laenge
6 sza 86.945 #solare Winkel
7 rte_solver cdisort #Loeser der radiativen Transferegleichungen
8 zout 0.03 #Hoehe in km
9 wavelength 380 780 #Wellenlaengenbereich
10 output rgb #Ausgabe
11 phi0 126.8016 #Azimuth der Sonne
12 phi 317.85 321.42 325.00 328.57 332.14 ... #Benoetigten Azimuthwinkel
13 umu -0.59 -0.57 -0.56 -0.54 -0.52 ... #Benoetigten Hoehenwinkel

```

Listing 5.1: Inputdatei

Umsetzung der Ausgabe in ein RGB-Bild

Die Ausgabe von *uvspec* besteht aus drei Matrizen für die drei Farbkanäle mit den jeweiligen Intensitäten. Diese müssen in 8-Bit-Werte umgerechnet werden. Dazu bieten sich mehrere Vorgehensweisen an.

Die simpelste Anpassung besteht darin, alle Werte am Maximalwert der Intensitäten auszurichten. Der Maximalwert erhält eine Helligkeit von 255 und allen anderen Werten wird entsprechend ihrer Intensität ein Wert zwischen 0 und 255 zugewiesen.

Eine weitere Möglichkeit besteht darin, die einzelnen Kanäle an einer Beispielmenge von wolkenlosen Originalbildern anzupassen. Aus diesen Anpassungen kann mithilfe der Belichtungszeit, der Apertur sowie der Filmempfindlichkeitsangabe eine Formel zur Anpassung der Intensitäten berechnet werden.

Ebenfalls möglich wäre es, im Originalbild jeweils einen wolkenlosen Abschnitt zu finden, der für das simulierte Bild als Anpassung dient. Diese Möglichkeit ist jedoch nicht immer gegeben und setzt die Erkennung eines wolkenlosen Abschnitts voraus.

Differenz Originalbild zur Simulation berechnen

Für die Erkennung von NLC sollte die positive Differenz des Bildes zur Simulation ausreichen, um die Gebiete zu erkennen. Eine Erkennung der troposphärischen Wolken hingegen wird durch eine Bewertung der negativen Differenz erreicht.



Bild 5.3.: Originalbild und Simulation 02.07.2012 05:00:34 UTC in Wismar

5.1.2. Implementierung

Ergebnisse

In Abbildung 5.3 lässt sich ein Ergebnis der Simulation betrachten. Dabei wird klar, dass der untere rechte Bereich im Originalbild viel heller ist als der Rest. Dies ist wahrscheinlich den fehlenden Aerosolen geschuldet. Diese würden für eine gleichmäßigere Streuung der verschiedenen Wellenlängen sorgen (Unterabschnitt 2.1.3) und mehr Licht absorbieren. Die Helligkeit in der Simulation verringert sich nach oben jedoch nur sehr gering.

Überprüfungen

Um jedoch weitere Fehler auszuschließen, werden zuerst die wichtigsten Parameter überprüft.

Da es bei der Aufnahme der Bilder zu möglichen Unsicherheiten bei der gespeicherten Uhrzeit kommen kann, ist dies eine mögliche Fehlerquelle. Dafür wird die Belichtungszeit und Apertur eines Tagessatzes an Bildern mit der Gesamthelligkeit der Ausgabe von *uvspec* verglichen (Abbildung 5.4). Durch den Vergleich der Parameter wird deutlich, dass der erwartete Sonnenaufgang bei ungefähr 02:50 UTC, sowie der Sonnenuntergang um 19:50 UTC sowohl in der Simulation als auch in den Daten der Bilder nachgewiesen werden kann. Dadurch lässt sich zeigen, dass die Uhrzeit bis auf wenige Minuten mit der zu erwartenden Uhrzeit übereinstimmt. Dies kann somit die teilweise sehr großen Differenzen nicht erklären.




Bild 5.4.: Vergleich Belichtungszeit[s], Apertur[mm] und relative Gesamthelligkeit des Bildes der LibRadtran Simulation mit *cdisort* für den 03.07.2012 in Wismar

Um weiterhin einen Fehler bei der Umsetzung in die RGB-Werte auszuschließen, wird der Tageslauf eines bestimmten Winkels einer bestimmten Wellenlänge mit den Daten der Bilder verglichen (Abbildung 5.5). Dabei stellt sich ein ähnlicher Verlauf wie bei einer Simulation von RGB-Werten dar. Daher kann die Umsetzung in RGB-Werte ebenfalls als eine mögliche Fehlerquelle ausgeschlossen werden.

Es wird jedoch ein anderes Problem sichtbar. Bei einem solaren Winkel unter 0 Grad wird der Helligkeitswert nicht wie erwartet kleiner, sondern steigt an. Bei




Bild 5.5.: Vergleich Belichtungszeit, Apertur und Helligkeit für einen Ausschnitt des Bildes bei einer Wellenlänge von 450nm und Benutzung von *sdisort* für die LibRadtran Simulation für den 03.07.2012 in Wismar

einer Überprüfung der Ergebnisse der Löser für die Strahlungstransferrechnungen in Abbildung 5.7 bestätigt sich dieses Problem auch bei anderen Lösern. Aus [25, S.2262] wird klar, warum dieses Problem besteht. Bei *sdisort* wird nur eine Pseudo-sphärische Approximation berechnet und nicht eine korrekte dreidimensionale Lösung. Daher steigt die Ungenauigkeit ab 0 Grad stark an (Abbildung 5.8) und führt zu Ergebnissen wie Abbildung 5.6.




Bild 5.6.: Beispiel für unstabiles Ergebnis von *sdisort*

5.1.3. Fazit

Eine Erkennung von NLC durch eine Simulation des Himmels ist unter den gegebenen Umständen nicht realisierbar. Mit den untersuchten Lösern lassen sich nur




Bild 5.7.: Vergleich der Helligkeit der errechneten RGB-Bilder mit verschiedenen Solvern

Pseudo-sphärische Lösungen berechnen, die für solare Winkel unter 0 Grad nicht ausreichend sind. Außerdem sind eine Vielzahl an nicht näher bekannten Variablen für eine korrekte Simulation notwendig. Zum einen die Eigenschaften der Aerosole. Diese sind nicht immer gleich und müssten durch Vergleiche mit dem realen Bild in Erfahrung gebracht werden. Andererseits sind die Empfindlichkeiten des Kamerasensors auf bestimmte Wellenlängen nicht klar, sodass die berechnete Lösung nicht unbedingt mit der realen Lösung übereinstimmen muss.




Bild 5.8.: Vergleich *MYSTIC* zu *sdisort* solver aus [25]. Für 342nm in Abhängigkeit des solaren Winkels (oben). Relative Differenz zwischen *MYSTIC* und *sdisort* (unten).

5.2. Klassifizierung mittels überwachten Lernens

5.2.1. Entwurf

Allgemeines Vorgehen

Die allgemeine Vorgehensweise beim überwachten Lernen wird in [27, S.12] beschrieben. Zuerst wird eine Sammlung von bereits klassifizierten Daten benötigt. Diese müssen an das richtige Format angepasst werden und eventuelle Vorverarbeitungsschritte angewendet werden. Erst nachdem diese Daten auf ihre korrekte Klassifizierung überprüft wurden, können sie weiterverarbeitet werden. Aus den gegebenen Daten müssen nun aussagekräftige Merkmale extrahiert werden, die bei unklassifizierten Daten zur Klassifikation führen können. Mit diesen Daten wird ein gewählter Lernalgorithmus trainiert. Ein Teil der Daten wird jedoch nicht zum Trainieren verwendet, sondern im nächsten Schritt zum Testen des Algorithmus. Somit lässt sich die Präzision für diesen Teil bestimmen, der durch die breite Auswahl der klassifizierten Daten auch auf die allgemeine Präzision übertragbar sein soll. Nach einem erfolgreichen Test kann der Algorithmus in das Programm implementiert werden.

Sammlung der Daten

Bei der Auswahl der Trainingsdaten ist es wichtig, dass von den jeweiligen Klassen eine möglichst breit gefächerte Auswahl getroffen wird. Andernfalls kann dies dazu führen, dass nicht alle möglichen Formen einer Klasse erkannt werden können. Außerdem sollte die Anzahl der jeweiligen Bilder pro Kategorie nicht stark abweichen. Dies könnte dazu führen, dass allein aus der größeren Anzahl der Beispielsbilder einer Kategorie, die Testbilder mit höherer Wahrscheinlichkeit dieser Kategorie zugeordnet werden. Da das Verhältnis der Vorkommnisse jedoch stark unterschiedlich ist, kann eine gewisse Ungleichheit bei der Anzahl der Trainingsbilder nur schwer verhindert werden und kann unter Umständen auch zu einem besseren Ergebnis führen.

Fenstergröße

Die Wahl der Größe der zu untersuchenden Ausschnitte hängt von verschiedenen Faktoren ab. Zuerst sollte die gewünschte Auflösung der Ergebnisse betrachtet werden. Außerdem werden bei einer zu kleinen Fenstergröße Texturen nur schwer er-

kannt und das Rauschen kann die Ergebnisse der Farbwertuntersuchung verzerren. Ist die Fenstergröße jedoch zu groß, ist die Wahrscheinlichkeit größer, dass sich mehrere unterschiedliche Klassen in einem Ausschnitt befinden und die Menge der Bildteile zum trainieren sinkt.

Merkmale

Der Klassifizierungserfolg hängt zum größten Teil von der Auswahl der Merkmale ab. Dabei ist es wichtig, sowohl Merkmale der Farbe, als auch der Struktur in die Bewertung einzubeziehen. Zur Überprüfung wurden folgende Merkmale (Abschnitt 5.2.1) zur Klassifizierung ausgewählt, die teilweise von [17] übernommen wurden.

- Der solare Winkel zum Zeitpunkt der Aufnahme
- Die relative Höhe im Bild
- Arithmetischer Mittelwert von Rot, Blau und der Helligkeit (Maximum R,G,B)

$$MEAN = \frac{1}{N} \sum_{i=1}^N x_i \quad (5.1)$$

- Division vom Arithmetischen Mittelwert Rot/Grün, Rot/Blau und Grün/Blau
- Differenz vom Arithmetischen Mittelwert Rot-Grün, Rot-Blau und Grün-Blau
- Die Standardabweichung von Rot, Blau und der Helligkeit (Maximum R,G,B)

$$STD = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_i - MEAN)^2} \quad (5.2)$$

- Standardabweichung der Differenzen Rot-Grün, Rot-Blau und Grün-Blau
- Differenz der Standardabweichungen Rot-Grün, Rot-Blau und Grün-Blau
- Standardabweichung der Arithmetischen Mittelwerte von Rot, Grün und Blau
- Anzahl der erkannten Ecken mit Canny Operator an Kanälen Rot, Grün, Blau und der Helligkeit (Maximum R,G,B)

- Die Schiefe der Kanäle Rot, Grün, Blau und der Helligkeit (Maximum R,G,B)

$$SKEW = \frac{1}{n} \sum_{i=1}^n \left(\frac{x_i - MEAN}{STD} \right)^3 \quad (5.3)$$

- Kontrast

$$CON = \sum_{i,j=0}^{levels-1} P_{i,j} (i - j)^2 \quad (5.4)$$

- Unähnlichkeit

$$DIS = \sum_{i,j=0}^{levels-1} P_{i,j} |i - j| \quad (5.5)$$

- Gleichartigkeit

$$HOM = \sum_{i,j=0}^{levels-1} \frac{P_{i,j}}{1 + (i - j)^2} \quad (5.6)$$

- ASM

$$ASM = \sum_{i,j=0}^{levels-1} P_{i,j}^2 \quad (5.7)$$

- Energie

$$ENE = \sqrt{ASM} \quad (5.8)$$

- Korrelation

$$COR = \sum_{i,j=0}^{levels-1} P_{i,j} \left[\frac{(i - \mu_i)(j - \mu_j)}{\sqrt{(\sigma_i^2)(\sigma_j^2)}} \right] \quad (5.9)$$

Bei dem Kontrast, der Unähnlichkeit, der Gleichartigkeit, der ASM, der Energie und der Korrelation handelt es sich um Merkmale einer Grauwertematrix. Mit ihnen kann die Textur eines Bildes beschrieben werden. Es werden die Anzahl der Veränderungen eines bestimmten Pixelwertes eines Pixels zu einem anderen Pixelwert eines Nachbarpixels im Bild berechnet. Diese werden in eine Matrix mit der

Länge und Breite der Anzahl von möglichen Werten eines Pixels geschrieben. Bei einem 8-Bit-Wert pro Pixel wird folglich eine 255×255 (i,j) Matrix erstellt. Unter (0,0) würde stehen, wie oft im Bild ein Pixel mit dem Wert 0 einen Nachbarpixel mit dem Wert 0 hat und bei (255,0) ein Pixel mit dem Pixelwert von 255 einen Nachbarpixel mit dem Wert 0 hat.

Aus den absoluten Werten werden dann die Wahrscheinlichkeiten berechnet. Auf dieser Grundlage werden alle vorher genannten Merkmale berechnet. Der Kontrast gibt durch das $(i - j)^2$ am meisten Gewicht auf große Veränderungen der Pixelwerte. Die Unähnlichkeit gibt mit $|i - j|$ ähnlich wie der Kontrast eine große Gewichtung auf die Veränderung. Diese steigt jedoch nicht wie beim Kontrast exponentiell sondern linear. Die Gleichartigkeit kann als inverse des Kontrastes bezeichnet werden, da auf Werte mit geringerer Veränderung mehr Gewicht gelegt wird. Die ASM und die Energie geben durch die Formel $P_{i,j}^2$ ein größeres Gewicht, wenn eine Veränderung öfter vorkommt. Kommen die gleichen Veränderungen im Bild sehr oft vor, so sind die ASM und die Energie sehr hoch. Die Korrelation ist unabhängig von den anderen Merkmalen und bezeichnet die Beziehung zwischen den Häufigkeiten in der Grauwertematrix.

Klassifikationsverfahren

Für die Klassifikation wurde das k-Nearest-Neighbor Verfahren ausgewählt. Dieses wurde bereits mehrfach erfolgreich für eine Klassifikation troposphärischer Wolken verwendet [17] [22].

Für N Merkmale wird ein N -Dimensionaler Raum benutzt. Jedes Merkmal wird dabei in einer Dimension dargestellt. Zuerst werden alle Trainingsdaten anhand dieser Merkmale eine Position zugeordnet. Nun können für die Testdaten die selben Merkmale berechnet werden und daraus die Position. Um ein Testdatum nun einer Klasse zuzuordnen, werden durch die euklidische Distanz die k nächsten Nachbarn betrachtet. Im Falle einer gleichmäßigen Gewichtung wird die neue Klasse aus dem häufigst vorhandenen Nachbarn bestimmt. Eine weitere Möglichkeit besteht darin, die Nachbarn entsprechend ihrer inversen Entfernung ein Gewicht zu geben.

Gewichtung der Merkmale

Um verschiedenen Merkmalen unterschiedliche Gewichte zu geben, können die Ergebnisse der Merkmale gestaucht oder gestreckt werden. Dadurch würde die Distanz

in der Dimension zu- oder abnehmen. Für das Programm wurde eine gleichmäßige Gewichtung aller Merkmale ausgewählt.

5.2.2. Implementierung

Sammlung von Daten

Für die Sammlung von Daten wurde ein Programm zur effizienten Selektion und Klassifikation geschrieben. Zuerst wird eine Menge an Bildern zur Verarbeitung ausgewählt. Diese sollten möglichst Objekte aller Kategorien enthalten. Durch einen Tastendruck kann die jeweilige Kategorie ausgewählt werden. Mit einem darauf folgenden Mausklick kann dann der zutreffende Bereich ausgewählt werden. Diese Bereiche werden dann automatisch mit den Zeitdaten, und der Position im Gesamtbild sowie der ausgewählten Kategorie gespeichert. Für die Trainingsdaten gibt es bei einer Fenstergröße von 50×50 Pixeln 2980 NLC, 4082 Wolken und 8344 Beispiele für den Himmel. Die Testdaten haben 639 NLC, 1169 Wolken und 2788 Beispiele für den Himmel.

Um eine bessere Einschätzung der Präzision zu erhalten, wurden für die Testdaten Beispiele verschiedener anderer Tage verwendet. Dies verhindert eine Anpassung an die Ergebnisse des einen Tages. Eine Überanpassung an die Testdaten ist jedoch trotzdem möglich. Ein erster Ansatz ist die Anzahl der Testdaten möglichst groß und breit zu halten. Außerdem sollte die Anzahl der Variablen möglichst gering gehalten werden.

Ergebnisse der einzelnen Merkmale

Die einzelnen Ergebnisse der Merkmale zur alleinigen Anwendung bei der Klassifizierung finden sich unter Tabelle A.1. Da eine alleinige Verwendung des solaren Winkel und der Höhe keine brauchbaren Lösungen liefern kann, wurden diese Merkmale nicht berechnet. Die Ergebnisse dieser Berechnungen lassen sich gut visualisieren. Unter Abbildung 5.9 findet sich eine Bewertung nur durch das arithmetische Mittel vom Rotkanal und dem Blaukanal. Die Wolken und der Himmel bilden dabei klar getrennte Klassen. Im Bereich des NLC sind diese Merkmale jedoch nicht ausreichend zur Klassifizierung. Sowohl NLC als auch der Himmel haben überlappende Merkmale. Dies sieht man an den kleineren Himmel-Gruppen innerhalb des großen Bereichs der NLC.

Bei einem Vergleich der Differenz des Arithmetischen Mittels von Rot zu Grün und Rot zu Blau in Abbildung 5.10 wird eine klarere Trennung deutlich. Aber auch dort gibt es einige Überlappungen.




Bild 5.9.: Beispiel für kNN Klassifikation mit den Merkmalen Mean R und Mean B. Die Punkte sind die Trainingsdaten und die Flächen stellen dar, welcher Klasse ein Bildausschnitt mit diesen Merkmalen zugeordnet werden würde

Gesamtergebnis

Für $k = 5$, einer gleichen Gewichtung aller Merkmale und der Verwendung aller Merkmale wird ein Präzision von 93,1% erzielt. Eine Anwendung des Verfahrens auf ein komplettes Bild kann in Abbildung 5.11 betrachtet werden.

Verringerung der Merkmale

Um die Genauigkeit zu erhöhen und die Rechenzeit zu senken, können redundante und nicht aussagekräftige Merkmale ausgeschlossen werden. Die Auswahl dieser kann durch eine Faktorenanalyse erreicht werden. Für die Faktorenanalyse wurde ein *extremely randomized tree classifier* gewählt.

Aus der Faktorenanalyse wurden folgende 11 wichtigsten Merkmale erhalten.

- Arithmetische Mittel von Blau und Arithmetische Mittel der Helligkeit
- Differenz des arithmetischen Mittels von Grün zu dem arithmetischen Mittel von Blau




Bild 5.10.: Beispiel für kNN Klassifikation mit den Merkmalen Mean R - Mean G und Mean R - Mean B. Die Punkte sind die Trainingsdaten und die Flächen stellen dar, welcher Klasse ein Bild mit diesen Merkmalen zugeordnet werden würde

- Division des arithmetischen Mittels Rot mit arithmetischem Mittel Grün sowie arithmetische Mittel Rot zu Blau
- Arithmetische Mittel von der Differenz Rot - Grün, Rot - Blau und Grün - Blau
- Anzahl Kanten durch Canny Filter auf Blaukanal
- Energie
- Korrelation

Dabei lässt sich feststellen, dass die deutlich redundanten Ergebnisse ausgelassen wurden und die besseren Ergebnisse bevorzugt wurden. Entweder die Differenz oder die Division der Arithmetischen Mittel zweier Kanäle wurde verwendet. Die Korrelation ist das einzige Merkmal, welches nicht mit den anderen fünf Grauwertmatrixbewertungen korreliert. Außerdem wurde noch die Energie für die Bewertung benutzt. Dieses hat zusammen mit der ASM, welches das Quadrat der Energie ist, die höchste Präzision der Grauwertmatrixbewertungen für die Testdaten.



Bild 5.11.: Anwendung des Verfahrens auf ein komplettes Bild (Blau=Himmel, Grün=Wolken, Rot=NLC)

Änderung der Auflösung

Eine weitere Möglichkeit die Rechenzeit zu verkürzen besteht in der Senkung der Auflösung. Bei einer Änderung der Auflösung und entsprechender Anpassung der Fenstergröße wurden folgende Ergebnisse erzielt Abbildung 5.12. Dort lässt sich keine klare statistische Signifikanz in der Abhängigkeit der Auflösung feststellen. Dies ist vor allem der großen Gewichtung der Farbmerkmale zuzuordnen. Acht der elf Merkmale nehmen als Eingangswert eine Form des Arithmetischen Mittelwertes der Farbe. Auf diese hat eine Veränderung der Auflösung jedoch nur geringen oder gar keinen Einfluss.

Auswahl von k

Die Auswahl, wie viele Nachbarn betrachtet werden, hängt immer von den zu untersuchenden Daten ab. Ein kleines k macht das Verfahren anfälliger für Störungen in Trainingsdaten. Durch ein größeres k läuft man Gefahr nicht relevante Ergebnisse mit in die Entscheidung mit einzubeziehen. Die Auswirkung bei den Testdaten lässt sich unter Abbildung 5.13 beobachten. Daraus lassen sich einige Schlüsse ziehen.




Bild 5.12.: Auswirkung der gleichzeitigen Skalierung des Bildes und des darin untersuchten Bereichs. 0.1 entspricht 10% der Originalauflösung

Zum einen scheint der Anteil von Störungen in den Trainingsdaten relativ gering zu sein, da die größte Präzision bei zwei Nachbarn besteht. Der Abfall deutet darauf hin, dass die Anzahl der Trainingsdaten relativ gering ist bzw die Grenzen zwischen den Klassen nicht sehr stark sind. Ebenfalls fällt auf, dass für eine gerade Zahl von k eine höhere Präzision erreicht wird. Dies ist wahrscheinlich der Implementierung des kNN Verfahrens geschuldet. Bei einer geraden Anzahl von k ist die Wahrscheinlichkeit eine gleiche Anzahl von Klassen bei den k Nachbarn zu erhalten viel höher. Eine Auswahl einer Klasse ist dann jeweils Implementationsabhängig. Die Bewertung könnte dann eventuell durch eine Gewichtung durch die inverse euklidische Distanz der einzelnen k Nachbarn erfolgen, welche zu einem besseren Ergebnis führen kann.

5.2.3. Fazit

Durch das vorgestellte Verfahren lassen sich an den Testdaten Präzisionen bis zu fast 95% erzielen.




Bild 5.13.: Auswirkung der Änderung der Anzahl k untersuchten Nachbarn auf die Präzision der Ergebnisse

6. Schlussbemerkungen und Ausblick

Das Ergebnis der Arbeit zeigt, dass eine Erkennung von NLC in Bildern möglich ist. Eine Simulation des Himmels zur Erkennung erweist sich jedoch aus mehreren Gründen nicht als hilfreich. Zum einen müsste eine dreidimensionale Lösung der Strahlentransfergleichungen berechnet werden, die eine bei weitem erhöhte Rechenleistung erfordert. Außerdem sind eine Vielzahl von Variablen, die in die Berechnung eingehen nicht oder nur annähernd bekannt.

Eine Klassifikation mit Hilfe überwachten maschinellen Lernens erweist sich jedoch als gute Lösungsmöglichkeit. Dabei konnten Genauigkeiten von fast 95 Prozent erreicht werden.

Für die Verbesserung der Erkennungsrate gibt es eine Vielzahl an möglichen Optionen. Um das komplette Spektrum an Formen und Farben der einzelnen Klassen abzudecken, wäre es sinnvoll die Anzahl der Trainingsbilder zu erhöhen. Dadurch wäre es außerdem möglich den Höhenwinkel, den solaren Winkel und den Azimuth mit in die Klassifikation einzubeziehen. Dies ist mit den gegebenen Trainingsdaten nicht sinnvoll, da es nicht genügend Beispiele für die verschiedenen Variablen gibt.

Auch die verwendeten Merkmale bieten Raum zur Optimierung. Vor allem die Verwendung weiterer Merkmale zur Beschreibung von Texturen kann für die Erkennung von NLC sinnvoll sein. Ein weiteres Vorgehen bei den Merkmalen besteht darin, anstatt alle Merkmale gleich zu gewichten, eine Anpassung der Gewichtung einzelner Merkmale durchzuführen. Dadurch könnten die Merkmale entsprechend ihrer Wichtigkeit in die Bewertung der Entfernung zu den Nachbarpunkten eingehen. Diese Anpassung ist durch eine Verwendung evolutionärer Algorithmen möglich.

Auch die Verwendung eines anderen Klassifikators könnte zu besseren Ergebnissen führen. Um die Wolken komplett zu betrachten, wäre eine Segmentierung der Wolken ähnlich [22] sinnvoll. Dadurch kann der gesamte Bereich einer Wolke oder des Himmels untersucht werden, anstatt nur einen Ausschnitt dessen.

Literaturverzeichnis

- [1] BAUMGARTEN, G. ; GERDING, M. ; KAIFLER, B. ; MÜLLER, N.: A TRANS-EUROPEAN NETWORK OF CAMERAS FOR OBSERVATION OF NOCTILUCENT CLOUDS FROM 37° N TO 69° N. In: *Proceedings of the 19th ESA Symposium on European Rocket and Balloon Programmes and Related Research* Bd. 711, 2009, S. 129–134
- [2] LUTGENS, F.K. ; TARBUCK, E.J. ; TASA, Dennis: *The Atmosphere: An Introduction to Meteorology*. Prentice Hall, 2011 <http://books.google.de/books?id=C5pJYAAACAAJ>. – ISBN 9780321756312
- [3] LESLIE, Robt. C.: Nature, 1885 <http://adsabs.harvard.edu/abs/1885Natur..32..245L>
- [4] PARVIAINEN, P. ; GADSDEN, M.: *Observing Noctilucent Clouds*. International Association of Geomagnetism & Aeronomy, 2006 http://www.iugg.org/IAGA/iaga_pages/pdf/ONC_Sep06.pdf
- [5] BRADSKI, G. ; KAEHLER, A.: *Learning OpenCV: Computer Vision with the OpenCV Library*. O'Reilly Media, Incorporated, 2008 (Software that sees). <http://books.google.de/books?id=seAgi0fu2EIC>. – ISBN 9780596516130
- [6] ABRAMOFF, M. D. ; MAGELHAES, P. J. ; RAM, S. J.: Image processing with ImageJ. In: *Biophotonics Int* 11 (2004), Nr. 7, S. 36–42
- [7] VEDALDI, A. ; FULKERSON, B.: *VLFeat: An Open and Portable Library of Computer Vision Algorithms*. <http://www.vlfeat.org/>, 2008
- [8] OLIPHANT, Travis E.: Python for Scientific Computing. In: *Computing in Science & Engineering* 9 (2007), Nr. 3, 10-20. <http://link.aip.org/link/?CSX/9/10/1>
- [9] DEMAAGD, K. ; OLIVER, A. ; OOSTENDORP, N. ; SCOTT, K.: *Practical Computer Vision with SimpleCV: The Simple Way to Make Technology See*. O'Reilly Media, 2012 <http://books.google.de/books?id=4st9l6QlkpUC>. – ISBN 9781449343835

- [10] PEDREGOSA, F. ; VAROQUAUX, G. ; GRAMFORT, A. ; MICHEL, V. ; THIRION, B. ; GRISEL, O. ; BLONDEL, M. ; PRETTENHOFER, P. ; WEISS, R. ; DUBOURG, V. ; VANDERPLAS, J. ; PASSOS, A. ; COURNAPEAU, D. ; BRUCHER, M. ; PERROT, M. ; DUCHESNAY, E.: Scikit-learn: Machine Learning in Python. In: *Journal of Machine Learning Research* 12 (2011), S. 2825–2830
- [11] GONZALEZ, Rafael C. ; WOODS, Richard E. ; EDDINS, Steven L.: *Digital Image Processing Using MATLAB*. Prentice-Hall, Inc., 2003. – ISBN 0130085197
- [12] *HALCON/HDevelop Referenzhandbuch.* : *HALCON/HDevelop Referenzhandbuch*
- [13] HUNTER, John D.: Matplotlib: A 2D Graphics Environment. In: *Computing in Science & Engineering* 9 (2007), Nr. 3, 90-95. <http://link.aip.org/link/?CSX/9/90/1>
- [14] MARICHAL, X. ; MA, W.Y. ; ZHANG, H.J.: Blur determination in the compressed domain using DCT information. In: *Image Processing, 1999. ICIP 99. Proceedings. 1999 International Conference on* Bd. 2 IEEE, 1999, S. 386–390
- [15] LIU, R. ; LI, Z. ; JIA, J.: Image partial blur detection and classification. In: *Computer Vision and Pattern Recognition, 2008. CVPR 2008. IEEE Conference on* IEEE, 2008, S. 1–8
- [16] TONG, Hanghang: Blur detection for digital images using wavelet transform. In: *In Proceedings of IEEE International Conference on Multimedia & Expo*, 2004, S. 17–20
- [17] HEINLE, A. ; MACKE, A. ; SRIVASTAV, A.: Automatic cloud classification of whole sky images. In: *Atmospheric Measurement Techniques* 3 (2010), Nr. 3, 557–567. <http://dx.doi.org/10.5194/amt-3-557-2010>. – DOI 10.5194/amt-3-557-2010
- [18] KAIFLER, Natalie: Bestimmung des Rayleigh-Untergrunds für Bilder des NLC-Kameranetzwerkes. (2010)
- [19] MAYER, B. ; KYLLING, A.: Technical note: The libRadtran software package for radiative transfer calculations - description and examples of use. In: *Atmospheric Chemistry and Physics* 5 (2005), Nr. 7, 1855–1877. <http://dx.doi.org/10.5194/acp-5-1855-2005>. – DOI 10.5194/acp-5-1855-2005
- [20] MAYER, Bernhard ; KYLLING, Arve ; EMDE, Claudia ; HAMANN, Ulrich ; BURAS, Robert: *libRadtran users guide*

- [21] LONG, C.N. ; SABBURG, JM ; CALBÓ, J. ; PAGES, D.: Retrieving cloud characteristics from ground-based daytime color all-sky images. In: *Journal of Atmospheric and Oceanic Technology* 23 (2006), Nr. 5, S. 633–652
- [22] SINGH, M. ; GLENNEN, M.: Automated ground-based cloud recognition. In: *Pattern Analysis & Applications* 8 (2005), Nr. 3, S. 258–271
- [23] CALBO, J. ; SABBURG, J.: Feature extraction from whole-sky ground-based images for cloud-type recognition. In: *Journal of Atmospheric and Oceanic Technology* 25 (2008), Nr. 1, S. 3–14
- [24] WALKER, J.: *Colour rendering of spectra*. <http://www.fourmilab.ch/documents/specrend/>. Version: 2003
- [25] EMDE, C. ; MAYER, B. u. a.: Simulation of solar radiation during a total eclipse: a challenge for radiative transfer. In: *Atmospheric Chemistry and Physics* 7 (2007), Nr. 9, S. 2259–2270
- [26] MAYER, B.: Interactive comment on Atmospheric effects of volcanic eruptions as seen by famous artists and depicted in their paintings by CS Zerefos et al.
- [27] HARRINGTON, P.: *Machine Learning in Action*. O'Reilly Media, 2012 <http://books.google.de/books?id=2d7RXwAACAAJ>. – ISBN 9781617290183
- [28] PRINCE, S.J.D.: *Computer Vision: Models Learning and Inference*. Cambridge University Press, 2012
- [29] NISCHWITZ, A. ; FISCHER, M. ; HABERÄCKER, P. ; SOCHER, G.: *Computergrafik und Bildverarbeitung: Band II: Bildverarbeitung*. Vieweg+Teubner Verlag, 2011 (Vieweg + Teubner Studium). <http://books.google.de/books?id=LNCjfPfx7QkC>. – ISBN 9783834817129
- [30] FORSYTH, D.A. ; PONCE, J.: *Computer Vision: A Modern Approach*. Pearson, 2011 <http://books.google.de/books?id=gM63QQAACAAJ>. – ISBN 9780136085928
- [31] SZELISKI, R.: *Computer Vision: Algorithms and Applications*. Springer, 2010 (Texts in Computer Science). <http://books.google.de/books?id=bXzAlkODwa8C>. – ISBN 9781848829350
- [32] PÉREZ, Fernando ; GRANGER, Brian E.: IPython: a System for Interactive Scientific Computing. In: *Comput. Sci. Eng.* 9 (2007), Mai, Nr. 3, 21–29. <http://ipython.org>

Abbildungsverzeichnis

2.1.	Aufbau der Atmosphärenschichten und durchschnittlicher Temperaturverlauf in Kühlungsborn im Sommer	7
2.2.	Simulation mit und ohne Aerosole für den 21.06.2012 in Wismar um 19:50 UTC	9
2.3.	NLC reflektiert Licht der Sonne zum Beobachter. Troposphärische Wolken sind im Schatten.	10
2.4.	Eine NLC am 10.7.2011 um 01:45:23 UTC in Wismar. Aufnahme durch automatisierte Kamera des IAP.	10
2.5.	Visualisierung des solaren Winkels. 90° bei Zenith, 0° bei Sonnenauf- und -untergang sowie negative Grade bei Nacht	12
3.1.	Beispiel für ein unscharfes Bild	16
3.2.	Vergleich Kantenpixel bzw. Dateigröße an einer vorsortierten Bildmenge	17
3.3.	Bilder vom 02.07.2012 in Wismar	18
3.4.	Beurteilung des Klassifikators mit verschiedenen maximalen Abweichungen	19
3.5.	Verstärkte Differenz eines Bildes mit mit einem leicht unscharfen Nachbarbild	19
3.6.	Bilder vom 02.07.2012 in Wismar	20
3.7.	Bilder vom 03.07.2012 in Wismar	20
4.1.	Vergleich der Helligkeit unterschiedlicher Kanäle	22
4.2.	Veränderung zwischen zwei aufeinander folgenden Bildern Wismar 09.07.2011 (Uhrzeit in UTC)	22
4.3.	Hochpassfilter	23
4.4.	Erkennung des Himmels durch Verhältnis Rot- zu Blauwert	26
4.5.	Erkennung des Himmels durch Differenz Rot- zu Blauwert	26
4.6.	Vergleich 2D Histogramm Rot- zu Blauwert eines wolkenlosen Himmels in der Nacht und am Tag	26
5.1.	Vorgehen zur Klassifizierung durch Simulation des Himmels	28
5.2.	Visualisierung der Parameter der Kamera	30
5.3.	Originalbild und Simulation 02.07.2012 05:00:34 UTC in Wismar . . .	32
5.4.	Vergleich Belichtungszeit[s], Apertur[mm] und relative Gesamthelligkeit des Bildes der LibRadtran Simulation mit <i>cdisort</i> für den 03.07.2012 in Wismar	33
5.5.	Vergleich Belichtungszeit, Apertur und Helligkeit für einen Ausschnitt des Bildes bei einer Wellenlänge von 450nm und Benutzung von <i>sdi-sort</i> für die LibRadtran Simulation für den 03.07.2012 in Wismar . .	34

5.6.	Beispiel für instabiles Ergebnis von <i>sdisort</i>	34
5.7.	Vergleich der Helligkeit der errechneten RGB-Bilder mit verschiedenen Solvern	35
5.8.	Vergleich <i>MYSTIC</i> zu <i>sdisort</i> solver aus [25]. Für 342nm in Abhängigkeit des solaren Winkels (oben). Relative Differenz zwischen <i>MYSTIC</i> und <i>sdisort</i> (unten).	35
5.9.	Beispiel für kNN Klassifikation mit den Merkmalen Mean R und Mean B. Die Punkte sind die Trainingsdaten und die Flächen stellen dar, welcher Klasse ein Bildausschnitt mit diesen Merkmalen zugeordnet werden würde	42
5.10.	Beispiel für kNN Klassifikation mit den Merkmalen Mean R - Mean G und Mean R - Mean B. Die Punkte sind die Trainingsdaten und die Flächen stellen dar, welcher Klasse ein Bild mit diesen Merkmalen zugeordnet werden würde	43
5.11.	Anwendung des Verfahrens auf ein komplettes Bild (Blau=Himmel, Grün=Wolken, Rot=NLC)	44
5.12.	Auswirkung der gleichzeitigen Skalierung des Bildes und des darin untersuchten Bereichs. 0.1 entspricht 10% der Originalauflösung . . .	45
5.13.	Auswirkung der Änderung der Anzahl k untersuchten Nachbarn auf die Präzision der Ergebnisse	46

Tabellenverzeichnis

3.1. Vergleich gängiger Bildverarbeitungsbibliotheken	14
A.1. Korrektheit einzelner Merkmale	54

A. Ergebnisse einzelner Merkmale

Tabelle A.1.: Korrektheit einzelner Merkmale

Merkmal \ Ergebnis	Gesamt	NLC	Himmel	Wolken	Min	Max
Mean R	0.579	0.854	0.610	0.699	12.427	209.403
Mean G	0.528	0.856	0.532	0.669	15.793	220.576
Mean B	0.713	0.886	0.713	0.827	17.094	237.239
Mean V	0.853	0.905	0.863	0.965	3.814	103.814
Mean R / Mean G	0.739	0.817	0.774	0.896	44.967	144.967
Mean R / Mean B	0.746	0.818	0.819	0.873	13.584	113.584
Mean G / Mean B	0.675	0.800	0.830	0.768	51.482	151.482
Mean R - Mean G	0.860	0.938	0.862	0.934	-58.822	54.422
Mean R - Mean B	0.819	0.919	0.825	0.919	-113.411	91.754
Mean G - Mean B	0.770	0.867	0.789	0.922	-54.077	45.922
Mean (R-G)	0.869	0.938	0.872	0.942	-51.944	48.055
Mean (R-B)	0.833	0.911	0.839	0.946	-55.256	44.743
Mean (G-B)	0.788	0.870	0.807	0.937	-54.101	45.898
STD R	0.628	0.924	0.636	0.702	1.110	27.824
STD G	0.630	0.938	0.641	0.686	1.115	27.189
STD B	0.568	0.893	0.591	0.669	1.141	30.864
STD V	0.672	0.828	0.724	0.872	0.995	100.995
STD (R-G)	0.523	0.843	0.546	0.679	0.0	8.871
STD (R-B)	0.553	0.860	0.578	0.685	0.0	14.450
STD (G-B)	0.559	0.876	0.592	0.680	0.0	10.551
STD R - STD G	0.551	0.878	0.572	0.680	-51.398	48.601
STD R - STD B	0.534	0.866	0.560	0.680	-48.199	51.800
STD G - STD B	0.536	0.884	0.555	0.670	-36.563	63.436
STD(R,G,B)	0.820	0.916	0.831	0.925	0.0	46.310
Canny R	0.575	0.892	0.586	0.680	413.0	1005.0
Canny G	0.569	0.889	0.588	0.667	358.0	1021.0
Canny B	0.561	0.869	0.581	0.694	363.0	1005.0
Canny V	0.377	0.939	0.438	0.377	0.0	100.0
Skew R	0.525	0.862	0.563	0.679	-1.655	18.742
Skew G	0.531	0.877	0.562	0.671	-2.180	19.313
Skew B	0.515	0.853	0.564	0.678	-3.186	17.458
Skew V	0.799	0.834	0.835	0.936	-14.301	85.698
Dissimilarity	0.496	0.775	0.583	0.685	0.594	2.710
Homogeneity	0.492	0.782	0.574	0.683	0.299	0.721
ASM	0.627	0.923	0.640	0.694	0.013	0.258
Energy	0.627	0.923	0.640	0.693	0.115	0.508
Correlation	0.560	0.917	0.564	0.633	0.314	0.998

Selbstständigkeitserklärung

Hiermit erkläre ich, dass ich die hier vorliegende Arbeit selbstständig, ohne unerlaubte fremde Hilfe und nur unter Verwendung der aufgeführten Hilfsmittel angefertigt habe.

Ort, Datum

Unterschrift

Thesen

Bachelor-Thesis

Automatische Erkennung von leuchtenden Nachtwolken in Kamerabeobachtungen

Eingereicht am: 28. Februar 2013

von: Daniel Schmidt
geboren am 13. Mai 1989
in Kreuztal

Betreuer: Prof. Dr. rer. nat. Herbert Litschke
2. Prüfer: Dr. Gerd Baumgarten

1. Eine automatische Erkennung von NLC und troposphärischen Wolken in Kamerabeobachtungen ist möglich.
2. Eine genaue Simulation des Himmels ist nur unter sehr großem Aufwand möglich.
3. Die Verwendung von Algorithmen des überwachten Lernens sind für die Aufgabe geeignet.
4. Bereits die alleinige Verwendung der Farbinformationen kann zu einer hohen Präzision führen.
5. Durch eine größere Anzahl und Breite von Trainingsdaten kann eine höhere Präzision erreicht werden.