




(Semi-) automatische Klassifizierung mit ADS40 Bilddaten

Bachelorarbeit FS2008

Felix Rohrbach

ETH

Eidgenössische Technische Hochschule Zürich
Swiss Federal Institute of Technology Zurich

Photogrammetry
pf
Remote Sensing

(Semi-) automatische Klassifizierung mit ADS40 Daten

Bachelorarbeit im Studiengang Geomatik und Planung BSc
Frühjahrssemester 2008

Autor:

Felix Rohrbach
Bülachhof 3-22
8057 Zürich

felixroh@ethz.ch
+41 79 776 4947

Leitung:

Prof. Dr. Armin Grün

Betreuung:

Thomas Hanusch

ETH Zürich
Institut für Geodäsie und Photogrammetrie
Professur für Photogrammetrie und Fernerkundung – Prof. Dr. A. Grün
Wolfgang-Pauli-Str. 15
8093 Zürich

Vorwort

Dieser Bericht ist Teil der Bachelorarbeit „(Semi-) automatische Klassifizierung mit ADS40 Daten“. Die Bachelorarbeit dient als Abschluss des Bachelorstudiengangs Geomatik und Planung an der ETH Zürich. Die Arbeit entstand im Frühlingssemester 2008 am Institut für Geodäsie und Photogrammetrie unter der Leitung von Prof. Dr. Armin Grün. Das Institut gehört zum Departement BAUG (Bau, Umwelt und Geomatik) der ETH Zürich.

Danksagung:

- Prof. Dr. Armin Grün für das Ermöglichen dieser Arbeit
- Thomas Hanusch für die Betreuung
- Meinen externen Kontaktpersonen für alle notwendigen Informationen und Daten:

Leica Geosystems: Udo Tempelmann, Tauno Saks, Don Marsh und Suqin Lu

Swisstopo: Stéphane Bovet

ITT VIS: Rolf Schächli, Bérangère Casson

Uni Zürich, RSL: Dr. Tobias Kellenberger

WSL: Christian Ginzler, Lars Waser

Revierförster: Daniel Hungerbühler

- Allen anderen Personen die mich bei der Arbeit unterstützt haben

Der Verfasser

Zürich, 6. Juni 2008

Felix Rohrbach

Zusammenfassung

Dieser Bericht dient zur Dokumentation der Bachelorarbeit mit dem Thema „(Semi-) automatische Klassifizierung mit ADS40 Bilddaten“.

Er hält das Vorgehen, die Erkenntnisse sowie auch die Erfahrungen fest, welche ich während der Arbeit gewonnen habe.

Die ADS40 dient schon seit einigen Jahren als effizientes Werkzeug bei der Aufnahmen von Luftbildern. Die totale Längsüberdeckung und die damit verbundene Stereofähigkeit der Bilder, sowie auch die Registrierung von multispektralen und panchromatischen Bildern mit gleich hoher Auflösung sind nur zwei der vielen Gründe, weshalb diese Kamera so erfolgreich ist.

Die hohe radiometrische Auflösung und Integrität lassen erahnen, dass das Bildmaterial für Computer unterstützte Klassifizierungen gut geeignet sein könnte. Auch wenn im Agrarbereich hier schon gute Resultate erzielt wurden, schien die Analyse von Wäldern anspruchsvoller zu sein und hatte noch nicht die erwartete Verbreitung.

Während dieser Arbeit wurde versucht, mit einfachen Mitteln gute Resultate zu erzielen. Dabei sollte der Grundgedanke gelten, dass Kunden diese Art von Analyse stets effizient, das heisst mit minimalem Aufwand betreiben wollen.

Als Softwarepaket wird *ENVI* von ITT VIS verwendet, welches alle grundlegenden Funktion zur Bildbearbeitung und Klassifizierung enthält.

Abstract

This report serves as a documentation for the bachelor thesis „(Semi-) automatic classification with ADS40 Data“.

It shows the procedure, cognitions as well as the experiences made during the process.

The ADS40 has now been used for a number of years as an efficient sensor for acquiring aerial imagery. The full forward overlap and the resulting stereo viewing capability, as well as the co-registration of multispectral and panchromatic images with the same high resolution are just two of many reasons behind the success of this camera.

The high radiometric resolution and spectral integrity let us assume that the imagery would also be well suited for computer assisted classification. Even if good results were confirmed in agricultural applications, classifications in forestry seemed to be more challenging.

The present study aimed at achieving good results with simple work tools. This was done always keeping in mind, that customers, who carry out such classifications wish performing them most efficiently and at minimum costs.

ITT VIS' *ENVI* software package was used as offering all basic tools and functions for such image processing and classifications.

Inhaltsverzeichnis

Vorwort	iii
Zusammenfassung	iv
Abstract	v
Inhaltsverzeichnis	vi
Abbildungsverzeichnis	viii
1 Einleitung	1
1.1 Zielsetzung	1
1.2 Aufbau der Arbeit.....	1
2 Theoretische Grundlagen	2
2.1 Airborne Digital Sensor ADS40	2
2.2 Vegetationsindizes	3
2.2.1 Ratio Vegetation Index (RVI).....	3
2.2.2 Normalized Differenced Vegetation Index (NDVI)	3
2.2.3 Weitere Indizes.....	4
2.3 Klassifizierung	4
2.3.1 Unüberwachte Klassifizierung	4
2.3.2 Überwachte Klassifizierung	5
3 Daten	7
3.1 Romanshorn Testdaten	7
3.2 LiDAR	7
3.3 Ground Truth	7
3.4 Generierung von zusätzlichen Informationen	8
4 Klassifizierung	9

4.1	Auswahl des Testgebietes.....	9
4.2	Klassifizierungstiefe	9
4.3	Wald – Nichtwald.....	9
4.3.1	Definition Wald	10
4.3.2	Waldgrenze	10
4.3.3	DSM Generierung.....	10
4.3.4	LiDAR DSM	11
4.3.5	Einbezug der NDVI-Werte	12
4.4	Laubbäume – Nadelbäume	13
4.4.1	Unüberwachte Klassifizierung	14
4.4.2	Überwachte Klassifizierung	15
4.4.3	Feature Extraction Workflow	17
4.4.4	Resultate	21
4.4.5	Anwendung auf ein weiteres Waldstück	23
5	Erfahrungen	24
5.1	Baumkrone	24
5.2	Schatten	25
5.2.1	Teilklassifizierung	25
5.3	Doppelbäume	26
5.3.1	Multitemporale Aufnahmen.....	26
5.3.2	Full Waveform LiDAR Daten	26
6	Diskussion	27
7	Glossar	28
8	Quellenverzeichnis	29
9	Anhang	30
9.1	Aufgabenstellung.....	30

Abbildungsverzeichnis

Abbildung 1: ADS40	2
Abbildung 2: Konfiguration des Sensorkopfs SH52	3
Abbildung 3: Datenfusion von Originaldaten und zusätzlichen Informationen ..	8
Abbildung 4: Klassifizierungstiefe	9
Abbildung 5: Generiertes DSM mit sichtbarer Pixelgrösse	11
Abbildung 6: Höhenfehler bei Waldwegen	12
Abbildung 7: Histogramm des NDVI	12
Abbildung 8: Waldgebiet	13
Abbildung 9: Klassifizierungsmethoden	13
Abbildung 10: ISODATA Parameter	14
Abbildung 11: Klassifikation mit dem ISODATA Algorithmus	15
Abbildung 12: Parallelepiped Parameter	15
Abbildung 13: Klassifikation mit dem Parallelepiped Algorithmus	16
Abbildung 14: Endmember Collection Spectra der beiden Baumarten	16
Abbildung 15: Klassifikation mit dem SAM Algorithmus	17
Abbildung 16: Feature Extraction Workflow	17
Abbildung 17: Verschiedene Einstellungen zur Segmentierung	18
Abbildung 18: Verschiedene Einstellungen zur Fusionierung	18
Abbildung 19: Beispiele von Objekteigenschaften	19
Abbildung 20: Scatter Plot mit einzelnen Features	20
Abbildung 21: Komplettes Ruleset	21
Abbildung 22: Erreichte Resultate	22
Abbildung 23: DSM mit Punkten auf dem Waldboden	24
Abbildung 24: Gut erkennbare Kirschbäume	26

1 Einleitung

Die Fernerkundung beschäftigt sich schon seit geraumer Zeit mit der Extraktion von Informationen aus Luftbildern. Mit Hilfe der Klassifizierung wird nun versucht, diese Analyse zu automatisieren. Die ADS40 von Leica Geosystems bietet mit ihren vier Kanälen (Rot, Grün, Blau und nahes Infrarot) ein gutes Instrument für Bilddaten, welche für die Klassifikation verwendet werden können. Im Bereich der Landwirtschaft konnten bei früheren Arbeiten schon gute Resultate erzielt werden. Das Waldgebiet jedoch stellte die bisherige Software vor verschiedenste Probleme.

1.1 Zielsetzung

Ziel meiner Arbeit ist es, mit möglichst einfachen Mitteln die Klassifizierung im Waldgebiet durchzuführen. Dabei sollen verschiedene Klassifikationstechniken verwendet und die speziellen Vorteile der ADS40 berücksichtigt werden.

1.2 Aufbau der Arbeit

Zu Beginn möchte ich auf die theoretischen Grundlagen eingehen und auch ein paar Merkmale der ADS40 darstellen. Danach werden kurz die Daten präsentiert, welche mir zur Verfügung standen. Anschliessend folgen die Auswertungen der einzelnen Klassifizierungen. Bevor dann schlussendlich die Resultate diskutiert werden, gibt es noch eine Übersicht über die Erfahrungen, Ideen und Probleme, welche während der Arbeit aufgetaucht sind.

2 Theoretische Grundlagen

2.1 Airborne Digital Sensor ADS40

Der ADS40-Sensor ist als Zeilensensor aufgebaut und enthält zwölf CCD-Zeilen (SH52) mit je 12'000 Pixel der Grösse $6,5\mu\text{m} \times 6,5\mu\text{m}$. Zwei Tetrachroide spalten das Licht auf die entsprechenden Sensoren auf, wobei Farbfilter die gleichzeitige Registrierung in verschiedenen Wellenlängen ermöglichen. Da die multispektralen Bilder mit Hilfe dieser Technologie die gleiche Auflösung aufweisen wie die panchromatischen, ist deshalb kein zusätzliches Pan-sharpening mehr notwendig.

Der Aufbau als Zeilensensor liefert keine Bilder in konventioneller Form, sondern so genannte „Pixelteppiche“. Die ADS40 Fokalebene enthält verschiedene Gruppen von CCD-Zeilen, die alle – zeitgleich – Bilder registrieren.

Die Anordnung der CCD-Zeilen ergibt somit simultan sowohl senkrechte Bilder als auch Bildstreifen, die schräg nach vorne bzw. nach hinten blicken.

Ein grosser Vorteil dieser Lösung liegt deshalb auch in der möglichen Stereobetrachtung der Bildstreifen und dies in allen vier Spektralkanälen.



Abbildung 1: ADS40




Abbildung 2: Konfiguration des Sensorkopfs SH52

2.2 Vegetationsindizes

Vegetationsindizes werden zur Analyse der Bodenoberfläche in Luftbildern verwendet. Meist bestehen diese aus einer Kombination der Informationen des roten und des infraroten Spektralbereichs. Grund dafür ist das Chlorophyll, welches im Infrarot ungefähr sechsmal stärker reflektiert als im sichtbaren Bereich, und der dadurch entstehende starke Anstieg zwischen diesen Bereichen im Reflektionsgrad.

2.2.1 Ratio Vegetation Index (RVI)

Der RVI war der erste Index, welcher von Jordan 1969 beschrieben wurde. Es handelt sich dabei um die Differenz zwischen Infrarot und Rot. Die Werte reichen dabei von 0 bis über 30, wobei sich die grüne Vegetation vor allem im Bereich zwischen 2 und 8 befinden.

Der RVI lässt sich wie folgt berechnen:

$$RVI = \frac{NIR}{RED}$$

2.2.2 Normalized Differenced Vegetation Index (NDVI)

Dieser Index ist der gebräuchteste zur Bestimmung von Vegetation. Der Vorteil liegt hier in der Normalisierung, welche den Wertebereich auf -1 bis 1 limitiert.

Da auch der NDVI aus den Rot- und Infrarotwerten berechnet wird, entsteht folgender Zusammenhang zwischen NDVI und RVI:

$$NDVI = \frac{RVI - 1}{RVI + 1}$$

Der NDVI selber berechnet sich folgendermassen:

$$NDVI = \frac{NIR - RED}{NIR + RED}$$

2.2.3 Weitere Indizes

Zusätzlich zu den oben erwähnten Indizes gibt es noch viele weitere, welche jeweils noch zusätzliche Informationen einbinden und teilweise auch versuchen, die atmosphärischen Einflüsse in Satellitenbildern zu eliminieren. Für die Auswertung der Daten dieser Arbeit werden jedoch nur die oben erwähnten Berechnungen verwendet.

2.3 Klassifizierung

Die Klassifizierung versucht, mittels verschiedener Algorithmen die Luftbilder in verschiedene Klassen aufzuteilen. Die dazu verwendeten Methoden können eingeteilt werden in unüberwachte und überwachte Klassifizierung.

2.3.1 Unüberwachte Klassifizierung

Die unüberwachte Klassifizierung zeichnet sich dadurch aus, dass kein Wissen über die tatsächliche Beschaffenheit am Boden vorhanden sein muss. Die Einteilung der einzelnen Pixel in die verschiedenen Klassen geschieht nach rein systematischen Kriterien. Die eigentlichen Attribute der generierten Klassen werden dabei nicht erfasst, sondern müssen später zugeteilt werden.

K-Means

Diese Technik basiert darauf, zufällig eine Anzahl k Klassenmittelpunkte zu wählen, und diese während den Berechnungen anzupassen. Dabei werden die Klassenmittelpunkte bei jedem Schritt in das Zentrum ihrer Klassen verschoben. Diese Schritte werden wiederholt, bis ein zuvor bestimmter Grenzwert überschritten oder die angegebene Anzahl Schritte erreicht wird.

ISODATA

Die ISODATA Klassifizierung basiert auf der K-Means Methode. Doch wenn in der zuvor erwähnten Methode immer k Klassen resultierten, werden hier Klassen mit zu wenig Einheiten zusammengelegt oder entfernt.

2.3.2 Überwachte Klassifizierung

Basierend auf Testgebieten, von denen die tatsächlichen Eigenschaften bekannt sind, werden bei der überwachten Klassifizierung die Parameter bestimmt und ähnliche Elemente im Bild gesucht.

Ground Truth

Die Bestimmung der Testgebiete und die Aufnahme der erforderlichen Attribute geschieht meist durch eine Begehung vor Ort (Ground Truth). Ist das nötige Fachwissen vorhanden, wäre dank der totalen Längsüberlappung der Bildstreifen aus verschiedenen Blickrichtungen auch eine Bestimmung der Testgebiete mittels Stereoblick (Stereo Truth) denkbar. Auf diese Weise könnte der immense Zeitaufwand, welcher bei der Aufnahme vor Ort entsteht, eingeschränkt werden.

Parallelepiped

Die Parallelepiped-Klassifizierung verwendet eine einfache Entscheidungsregel. Aus den Werten jedes Testgebietes wird ein Raum aufgespannt, wobei die Ausdehnung der Seitenlängen durch den zuvor festgelegten Grenzwert, basierend auf der Standardabweichung, definiert ist. Liegt ein zu klassifizierendes Element innerhalb dieses Raumes, wird es der entsprechenden Klasse zugeteilt. Elemente welche durch diese Zuteilung zu mehreren Klassen gehören würden, werden in eine Überlappungsklasse eingeteilt. Alles was sich ausserhalb der Klassenräume befindet gilt als unklassifiziert.

Spectral Angle Mapper

Der Spectral Angle Mapper (SAM) verwendet einen n -dimensionalen Winkel, um die Elemente den einzelnen Referenzdaten zuzuordnen. Der Algorithmus bestimmt den räumlichen Winkel zwischen dem Spektrum des Testgebietes und des zu untersuchenden Elements in einem n -dimensionalen Raum, wobei

n die Anzahl Bänder des Bildes ist. Liegt dieser Winkel innerhalb des definierten Grenzwertes, wird das Pixel der entsprechenden Klasse zugeordnet.

Regelbasierte Klassifizierung

Bei der regelbasierten Klassifizierung handelt es sich um einen Versuch, mathematische Methoden mit menschlichem Wissen zu verknüpfen. Zu diesem Zweck werden Regeln definiert, welche die Testgebiete so gut wie möglich definieren. Neben den mathematischen können auch geometrische Eigenschaften zur Erstellung dieser Regeln verwendet werden.

3 Daten

3.1 Romanshorn Testdaten

Die Daten, welche zur Verfügung standen, stammen aus einem Flug über dem Gebiet Amriswil – Romanshorn vom 19. April 2007. Aufgenommen wurden die Bilder in vier Streifen, alle von West nach Ost, mit einer Bodenauflösung von 20cm und einer seitlichen Überlappung von 30%. Verwendet wurde dabei der zu Beginn schon erwähnte Sensorkopf SH52.

Für die Klassifizierung wurden Multiband (NRGB) Level 2 Bilder verwendet, welche von Leica Geosystems zur Verfügung gestellt wurden.

Im Datensatz vorhanden ist auch ein DTM, welches aus dem LiDAR-Scan abgeleitet wurde.

3.2 LiDAR

Neben den Bilddaten der ADS40 wurde während des Fluges mit einem ALS50 ein LiDAR-Scan durchgeführt. Um den vollen Funktionsumfang der Daten zu nutzen, wurden die ungefilterten Daten im LAS-Format verwendet.

3.3 Ground Truth

Sowohl für die überwachten Klassifizierungsalgorithmen, als auch zur Kontrolle der Ergebnisse war die Aufnahme einer Ground Truth notwendig. Zu diesem Zweck wurde zusammen mit dem lokalen Förster eine Waldbegehung durchgeführt. Für die Protokollierung der aufgenommenen Bäume wurde je ein RGB- und ein FCIR-Bild im Format A0 ausgedruckt.

Da die Lokalisierung der einzelnen Bäume im Wald sehr schwierig ist, wurden vor allem Bäume am Waldrand, bzw. am Rand von Waldlichtungen bestimmt. Die ausgedruckten Luftbilder zeigten dabei, welche Bäume sich auch später am Computer unterscheiden liessen.

3.4 Generierung von zusätzlichen Informationen

Aus den verschiedenen Bändern der Bilddaten wurde mit Hilfe der Funktion *Band Math* ein NDVI und ein SR Bild generiert. Aus dem DTM und dem DSM, welches aus den LiDAR-Daten generiert wurde, liess sich ein Höhenbild generieren. Diese zusätzlichen Informationen wurden als weitere Layer in das Bild eingefügt.




Abbildung 3: Datenfusion von Originaldaten und zusätzlichen Informationen

4 Klassifizierung

4.1 Auswahl des Testgebietes

Damit die resultierenden Klassifikationen auch genügend überprüft werden können, ist ein Waldstück grösserer Fläche notwendig. Um die Unterscheidung zwischen mehreren Klassen testen zu können, ist zudem auch noch eine hohe Diversität der Baumarten wünschenswert.

Da die Luftbilder vor allem über landwirtschaftlichem Gebiet geflogen wurden, ist nur eine kleine Anzahl von Waldstücken vorhanden, welche diese Kriterien erfüllen.

Ausgewählt wurde schlussendlich der Laametwald östlich von Amriswil mit einer Fläche von ca. 50 Hektaren.

4.2 Klassifizierungstiefe

Im Rahmen dieser Bachelorarbeit sollen folgende Klassifizierungsstufen unterschieden werden:




Abbildung 4: Klassifizierungstiefe

4.3 Wald – Nichtwald

Der erste Schritt ist, den Wald von den umliegenden Gebieten zu trennen. Zu diesem Zweck gilt es zunächst, zu wissen, wie das Waldgebiet definiert ist.

4.3.1 Definition Wald

Eine allgemein gültige Definition, was Wald ist, gibt es nicht. Die Grenzen zwischen Wald und Feld sind meist fließend.

Für diese Arbeit wurde daher die Definition vom Schweizerischen Landesforstinventar (LFI) verwendet. Ob eine Fläche als Wald oder Nichtwald gezählt wird, hängt dabei von der Breite, dem Bedeckungsgrad und der Baumhöhe der Bestockung ab. Die Baumhöhe muss immer grösser als drei Meter sein, der Bedeckungsgrad hängt jedoch von der Breite des Waldes ab.

4.3.2 Waldgrenze

Da vom Laametswald schon bekannt ist, dass er die Bedingungen für einen Wald erfüllt, kann nun rückwärts bestimmt werden, welches Gebiet zum Wald dazugehört. Da die Breite und der Bedeckungsgrad auf den ganzen Wald betrachtet werden, bestimmt nur die Baumhöhe die Grenze des Waldgebietes.

4.3.3 DSM Generierung

Damit Höheninformationen aus dem Bild generiert werden können, ist neben dem vorhandenen DTM auch noch ein DSM nötig. Da in den Testdaten auch die Projektdatei für die *Leica Photogrammetry Suite* (LPS) enthalten ist, wurde die DSM Generierung mit Hilfe dieses Softwarepakets durchgeführt. Nach mehreren Versuchen, in denen die Rechenleistung des Computers überfordert war, gelang es ein DSM mit 2m Auflösung zu generieren. Da Baumkronen jedoch viel feinere Strukturen aufweisen, und das Ergebnis allgemein unzufriedenstellend war, wurde dieses Modell nicht weiter verwendet.




Abbildung 5: Generiertes DSM mit sichtbarer Pixelgrösse

4.3.4 LiDAR DSM

Da die Bilder und der LiDAR-Scan parallel aufgenommen wurden, ist kein Zeitsprung zwischen diesen Datenquellen vorhanden. Wäre dies der Fall, müsste man beachten, dass der Wald stetig weiter wächst und gelegentlich auch abgeholzt wird. Eine vertiefte Analyse der Daten wäre daher notwendig. In diesem Falle jedoch repräsentieren die Daten des LiDAR die Höhen der Bäume auf dem Luftbild.

Damit die Daten in die Software eingelesen werden können, müssen diese zuerst in ein kompatibles Datenformat konvertiert werden. *ITT* bietet für den Umgang mit LiDAR-Daten ein Toolkit als Erweiterung zu *ENVI* an, welches unter anderem diese Konvertierungsfunktion enthält.

Aus der Differenz zwischen dem mitgelieferten DTM und dem erstellten DSM erhält man ein Bild mit den Höhenangaben zu den einzelnen Punkten.

Extrahiert man nun die Bereiche, welche eine Höhe von 3 Meter überschreiten, erhält man ein erstes Resultat für das Waldgebiet.




Abbildung 6: Höhenfehler bei Waldwegen

4.3.5 Einbezug der NDVI-Werte

Äste, welche über die Waldwege reichen, führen dazu, dass diese fälschlicherweise als Wald klassifiziert werden. Um diese Gebiete für die weitere Klassifizierung zu entfernen, wird das zuvor generierte Waldgebiet mit Hilfe des NDVI weiter eingeschränkt.




Abbildung 7: Histogramm des NDVI

Bereiche mit grüner Vegetation liegen im NDVI zwischen 0.2 und 0.8. Setzt man diese Werte als Bedingung ein, werden aus dem ursprünglichen Gebiet Waldwege, Strassen und auch Gebäude herausgefiltert.

Da das Resultat jetzt nur noch Gebiete enthält, welche einerseits eine Höhe von über 3 Metern aufweisen und auf Grund des NDVI grüne Vegetationsflächen beinhalten, kann man davon ausgehen, dass dies die Fläche des Waldes ziemlich gut beschreibt.




Abbildung 8: Waldgebiet

4.4 Laubbäume – Nadelbäume

Die Unterscheidung zwischen Laubbäumen und Nadelbäumen geschieht nicht nur wie zuvor über die berechneten Höhen, sondern auch durch Analyse der einzelnen Farbbilder. Im Verlauf dieser Arbeit wurden dazu verschiedene Algorithmen verwendet, wobei jeder wiederum andere Resultate erzielte.




Abbildung 9: Klassifizierungsmethoden

4.4.1 Unüberwachte Klassifizierung

Mit dem Hintergedanken, dass ein Kunde möglichst wenig Aufwand betreiben möchte, um seine Daten zu klassifizieren, wurden auch Algorithmen zur unüberwachten Klassifizierung untersucht. Im Gegensatz zur überwachten Klassifizierung wird hier keine Ground Truth benötigt. Die Daten können direkt mit dem Algorithmus verwendet werden.

ISODATA

Für die unüberwachte Klassifizierung wird das Luftbild mit einer Maske der Waldfläche versehen, so dass nur Punkte in diesem Gebiet analysiert werden.

Folgende Einstellungen wurden für die Klassifizierung verwendet:




Abbildung 10: ISODATA Parameter

Nach der Berechnung der Resultate, müssen die generierten Klassen noch untersucht werden. Ähnliche Klassen können zur besseren Übersicht zusammengefasst werden.

In der untenstehenden Klassifikation sieht man schön die Baumkronen, welche der Algorithmus erkannt hat.




Abbildung 11: Klassifikation mit dem ISODATA Algorithmus

4.4.2 Überwachte Klassifizierung

Für die überwachte Klassifizierung wurden die bestimmten Bäume der Waldbegehung in Vektoren digitalisiert. Auf diese Art können sie für die verschiedenen Algorithmen weiterverwendet werden.

Parallelepiped

Auch für die überwachte Klassifizierung wird das Waldgebiet durch eine Maske vom restlichen Umfeld getrennt. Zusätzlich werden die Testgebiete importiert. Für die einzelnen Baumarten könnten individuelle Werte für die maximale Abweichung vom Mittelwert angegeben werden, was in diesem Beispiel jedoch nicht angewendet wurde.




Abbildung 12: Parallelepiped Parameter

In den resultierenden Bildern sieht man, dass auch hier die Eichen sehr gut erkannt wurden. Jedoch zeigt sich schon, dass die Schattenseiten der Tannen Probleme bereiten.




Abbildung 13: Klassifikation mit dem Parallelepiped Algorithmus

Spectral Angle Mapper

Für den Spectral Angle Mapper müssen die Testregionen in eine *Endmember Class Collection* eingelesen werden. Dieses Tool generiert dann später die Referenzspektren, welche zur Klassifizierung verwendet werden. Die folgende Grafik zeigt die Trennung der beiden Baumarten in den verschiedenen Bändern des Bildmaterials.




Abbildung 14: Endmember Collection Spectra der beiden Baumarten

Nachdem die Gebiete eingelesen und analysiert wurden, kann für die Bereiche der Grenzwert für die Abweichung definiert werden. Je kleiner der Wert gewählt wird, desto kleiner wird die Fläche der klassifizierten Gebiete. Die Resultate liegen dann jedoch näher beim Referenzspektrum.




Abbildung 15: Klassifikation mit dem SAM Algorithmus

4.4.3 Feature Extraction Workflow

Der *Feature Extraction* Workflow ist ein Teil von *ENVI Zoom*. Das übersichtliche Interface mit vielen Vorschaufunktionen ermöglicht es, Elemente auf einfachste Art und Weise zu extrahieren.




Abbildung 16: Feature Extraction Workflow

Segmentierung

Die Segmentierung gruppiert benachbarte Pixel, welche ähnliche Eigenschaften haben. Dabei wird ein kanten-orientierter Algorithmus verwendet, welcher nur einen Parameter, nämlich die Segmentgrösse, benötigt. Ziel ist es dabei, die Grösse der Segmente so zu wählen, dass die Grenzen der gewünschten Features gerade noch erkannt werden. Da im Wald die einzelnen Bereiche oft sehr stark texturiert sind, führt dieser Algorithmus schnell zu einer Übersegmentierung.




Abbildung 17: Verschiedene Einstellungen zur Segmentierung

Fusionierung

Mit der Fusionierung wird versucht, den Effekt der Übersegmentierung zu bekämpfen. Auch hier ist wieder nur ein Parameter erforderlich, welcher über den Schieberegler kontrolliert werden kann.




Abbildung 18: Verschiedene Einstellungen zur Fusionierung

Definieren der Regeln

Die jetzt vorhandenen Flächen sollten die Baumkronen so gut wie möglich repräsentieren. Beim Berechnen der Attribute unterscheidet *ENVI* zwischen räumlichen, spektralen, Textur- und Farbeigenschaften. Mit Hilfe dieser Angaben können nun Regeln definiert werden, welche die einzelnen Objekte beschreiben.

Kombinationen

Da ein Objekt meist nicht nur aus einer Eigenschaft besteht, bietet *ENVI* die Möglichkeit, einzelne Regeln zu verknüpfen. Dabei stehen die logischen Operatoren AND und OR zur Verfügung.

Zusätzlich kann bei der Regelerstellung ein Wert für die Fuzzy Logic definiert werden. Dies passt die Klassifizierung noch mehr an das menschliche Wissen an, da dann Definitionen wie „ein bisschen“, „ziemlich“ und „stark“ auch verarbeitet werden können, da ja nicht nur binäre Zustände (ja und nein) bestehen.

Ableiten von Regeln

Der Mensch nimmt unbewusst Eigenschaften aus der Umgebung auf, welche er dann zu Informationen weiterverarbeitet. Er führt sozusagen unbewusst eine Klassifizierung durch. Es gilt nun, diese Klassifizierung in Form einer Regel zu beschreiben.

	Laubbäume	Nadelbäume
Farbe	Hell	Dunkel
Baumkrone	Flach	Spitz
Form	Oben breit	Unten breit
Etc.	...	...

Abbildung 19: Beispiele von Objekteigenschaften

Scatter Plot

Eine Möglichkeit, solche Regeln zu finden, sind 2D Scatter Plots. Diese stellen die Verteilung zweier Bänder für den ausgewählten Bildausschnitt dar. Wählt man in diesem Plot Pixel aus, sieht man die entsprechenden Bereiche im Bild markiert. So können für verschiedene Elemente einzelne Regionen im

Plot beobachtet werden, aus welchen sich dann wiederum Regeln ableiten lassen.




Abbildung 20: Scatter Plot mit einzelnen Features

Vorschau der einzelnen Attribute

ENVI funktioniert sehr nach dem WYSIWYG (What you see is what you get) Prinzip. Zu diesem Zweck steht immer eine Vorschau zur Verfügung. Sei dies nun bei der Auswahl der Attribute, welche man zur Klassifizierung verwenden möchte, wo eine Vorschau der entsprechenden Werte eingeblendet wird, oder aber auch bei der Festlegung der Grenzwerte, bei der die resultierende Klassifikation angezeigt wird.

Ruleset

Sind schlussendlich alle Features durch die entsprechenden Regeln definiert, ist es möglich, das gesamte Ruleset für zukünftige Analysen zu speichern. Dies bietet sich an, wenn noch andere Waldgebiete klassifiziert werden, oder später Anpassungen an die einzelnen Regeln gemacht werden wollen.




Abbildung 21: Komplettes Ruleset

4.4.4 Resultate

Zur Analyse der Ergebnisse wurden die im Feld bestimmten Testgebiete mit den klassifizierten Resultaten verglichen. *ENVI* bietet dazu keine eigene Funktion, es konnten jedoch die Berechnung der Change Detection Statistiken verwendet werden.

Als „Vorher“-Daten wurden die Testgebiete eingegeben werden, als „Nachher“-Daten konnten die Klassifikationen in denselben Bereichen verwendet werden.

Folgende Grafik stellt die mit den verschiedenen Algorithmen erreichten Resultate dar. Sie zeigt, welcher Teil der ursprünglichen Referenzfläche als gleiche Baumart klassifiziert wurde.




Abbildung 22: Erreichte Resultate

Die Übersicht zeigt, dass vor allem Laubbäume gut erkannt wurden. Dies erklärt sich unter anderem durch den grossen Schattenanteil, welcher bei Nadelbäumen durch die spitze Kronenform fast die Hälfte der Baumfläche einnimmt. Solche Schattenflächen wurden von allen Algorithmen schlecht klassifiziert.

Grundsätzlich ist das Resultat zufrieden stellend, da die Zuordnung der Pixel, welche durch den Algorithmus einer Klasse zugewiesen wurden, mit den Baumarten der Ground Truth übereinstimmen.

Ein grosser Teil wurde bei allen Methoden nicht klassifiziert. Hier könnte man nun versuchen durch feinere Abstufung der verschiedenen Regeln oder durch Anpassung der Parameter noch bessere Resultate zu erzielen.

Eine Klassifikation mit weniger klassifizierten Pixeln und genauerer Zuordnung ist jedoch besser als eine komplette Klassifikation mit vielen Falschzuordnungen.

4.4.5 Anwendung auf ein weiteres Waldstück

Nach der Klassifizierung des Laametwald wurde nun die Regelsammlung des *Feature Extraction* Workflows auf ein zweites Waldgebiet angewendet.

Das erste Resultat war hierbei jedoch sehr enttäuschend, da sowohl Wald als auch umliegende Felder als Laub- und Nadelbäume klassifiziert wurden. Auf der Suche nach dem Fehler konnte jedoch schnell festgestellt werden, dass das Höhenbild in diesem Bereich Fehler aufwies. So hatten nur schon die landwirtschaftlichen Felder eine Höhe von mehr als 35 Metern, was dazu führte, dass diese Bereiche auch zum Waldgebiet gezählt wurden.

Nach Anpassung der Höhenregel, fiel das Resultat schon viel besser aus. Natürlich wurden die einzelnen Bäume nicht so schön erfasst wie im Laametwald, jedoch wären hier durch kleinere Anpassungen mit Sicherheit noch bessere Resultate zu erreichen.

5 Erfahrungen

Bei der Ausarbeitung der Klassifizierungen und auch auf der Suche nach mehr Möglichkeiten, Regeln für die *Feature Extraction* aufzustellen, kamen immer wieder verschiedene Ideen auf, welche bei der Umsetzung dann aber mehr Probleme bereiteten als erwartet. In diesem Abschnitt sollen diese verschiedenen Ideen und Probleme näher erläutert werden.

5.1 Baumkrone

Ein Gedanke zur Unterscheidung der Nadelbäume von den Laubbäumen war, dass Nadelbäume ja generell eine spitze Baumkrone besitzen. Daraus folgend sollte die Standardabweichung der Höhe im Gebiet, welches den einzelnen Baum beschreibt, bei einem Nadelbaum grösser sein als beim Laubbaum.

Bei der Auswertung wurde aber festgestellt, dass die Standardabweichung der Höhe bei beiden Baumarten ähnlich gross ist. Die Erklärung dafür wurde schlussendlich im Oberflächenmodell gefunden. Auch wenn hierbei nur der erste Return des LiDAR Datensatzes verwendet wurde, sind Punkte auf Bodenhöhe vorhanden. Solche Punkte entstanden wahrscheinlich durch Strahlen, welche durch das Blätterdach hindurch drangen und erst am Boden zurückgeworfen wurden.




Abbildung 23: DSM mit Punkten auf dem Waldboden

Hier wäre eine Nachbearbeitung des Oberflächenmodells notwendig, welche solche Punkte eliminiert. Dies könnte wahrscheinlich am Besten mit LiDAR-Anwendungen wie zum Beispiel Terrasolid durchgeführt werden. Auch könnte man hier noch die Möglichkeit untersuchen andere Softwarepakete für das Stereo Matching zu verwenden, welche vielleicht bessere Resultate für ein DSM generieren würden.

In *ENVI* ist eine Funktion zur Generierung von Oberflächenmodellen vorhanden, jedoch konnte auf Grund fehlender Daten diese nicht genutzt werden.

Will man weiterhin die Daten vom LiDAR verwenden, sollte man darauf achten, dass der Öffnungswinkel eng (zwischen 30 und 40 Grad) gewählt wird und jeweils mit höchst möglicher Pulsrate geflogen wird

5.2 Schatten

Grosse Teile des Waldes konnten nicht klassifiziert werden, da sie sich im Schatten eines Baumes befanden. Da die ADS40 Bilder mit einer radiometrischen Auflösung von 16bit liefert, sind in solchen Gebieten sicherlich noch Informationen enthalten. Man müsste diese Bereiche jedoch durch verschiedenste Vorgehensweisen aufbessern.

Zusätzlich sollte man die Flugplanung auf die Bedürfnisse der Klassifizierung anpassen. So würde wahrscheinlich ein Nord-Süd Flug über die Mittagszeit bessere Resultate bringen.

Im Rahmen dieser Arbeit wurden diese Bereiche nicht näher untersucht.

5.2.1 Teilklassifizierung

Eine Idee jedoch, wie man das genannte Schattenproblem umgehen könnte wäre, dass man nur die besonnte Seite des Baums klassifiziert. Die Klassifikation des hellen Teils könnte dann auf die gesamte Fläche des Baumes übertragen werden. Die Herausforderung hierbei bestände darin, die Baumflächen zu generieren. Vielleicht würde hier ein verbessertes Oberflächenmodell die Abtrennung vereinzelter Bäume aufzeigen und so zu besseren Resultaten führen.

5.3 Doppelbäume

Während der Waldbegehung für die Testgebiete konnte ein weiteres Problem für die Klassifizierung beobachtet werden. Da in einem Wald Bäume nicht nur nebeneinander, sondern auch übereinander wachsen, gibt es Stellen, wo sich Bäume überdecken. Welcher Baum im Luftbild sichtbar ist, lässt sich nur schwer feststellen.

5.3.1 Multitemporale Aufnahmen

Auf dem Bildmaterial, welches für die Auswertung zur Verfügung stand, sind weisse Bäume sichtbar. Laut Auskunft des Revierförster handelt es sich dabei um Kirschbäume, welche zum Zeitpunkt der Aufnahme ihre Blütezeit hatten. Aus dieser Beobachtung abgeleitet, lässt sich vermuten, dass, wenn man Bilder zu verschiedenen Zeitpunkten aufnehmen würde, sich Bäume leichter bestimmen liessen. Dies wäre einerseits in kurzen Abständen – zur Analyse des Wachstums – oder auch in grösseren Abständen – zum Unterscheiden zwischen Laub- und Nadelbäumen – denkbar.




Abbildung 24: Gut erkennbare Kirschbäume

5.3.2 Full Waveform LiDAR Daten

Neue Technologien, wie die Analyse des gesamten zurückgeworfenen Signals, lassen die Trennung zwischen Objekten auf verschiedenen Ebenen zu. Auf diese Weise wäre auch möglich, verschiedene Durscheineffekte von verdeckten Bäumen mit in die Klassifizierung einzubeziehen.

6 Diskussion

Die Klassifizierung ist ein effizientes Werkzeug der Photogrammetrie. Auch wenn nur wenige Vorkenntnisse zu diesem Thema vorhanden waren, konnten im Rahmen dieser Bachelorarbeit anschauliche Resultate erzielt werden.

Eine besondere Herausforderung bot der Umgang mit den verschiedenen Datenformaten. Neben der Tatsache, dass auch die heutige Generation von Computern immer noch Mühe haben, die riesigen Datenmengen zu verarbeiten, war auch der Austausch der Dateien zwischen verschiedenen Anwendungen oft nur über Umwege zu erreichen.

ENVI erwies sich als recht gutes und leistungsfähiges Softwarepaket. Das LiDAR Toolkit erweitert *ENVI* zudem um eine Reihe wichtiger Funktionen für den Umgang mit LAS-Dateien. Jedoch sind auch hier noch weitere Entwicklungen zum Datenaustausch notwendig. Angenehm wäre zudem, wenn die Funktionalitäten von *ENVI* mit denen von *ENVI Zoom* erweitert würden.

Neben den üblichen Algorithmen bietet vor allem der *Feature Extraction* Workflow Potential für eine einfache Klassifizierung. Durch Hinzufügen von mehreren Regeln bestehen viel mehr Möglichkeiten, die Klassifikation zu beeinflussen, als nur durch ein paar wenige Parameter.

Das Erstellen der Regeln benötigt verhältnismässig viel Zeit, da dies vor allem durch Austesten und Beobachten der einzelnen Änderungen geschieht. Hierbei ist vor allem auch die Vorschaufunktion von grossem Nutzen. Dieser Zeitaufwand verringert sich jedoch bei weiteren Klassifizierungen. Denn ist die Regelsammlung einmal definiert, muss sie für zukünftige Anwendungen nur noch kontrolliert und allenfalls angepasst werden.

Abschliessend kann man jedoch auch erwähnen, dass *ENVI* heute schon die Klassifizierung sehr benutzerfreundlich integriert hat. Die Kombination von Luftbildern der ADS40 und LiDAR-Daten hat sich als sehr nützlich erwiesen. In den nächsten Jahren wird sich dieser Bereich sicherlich noch weiter entwickeln und neue Verfahren bringen, welche die Daten dieser beiden Sensoren noch effizienter nutzen.

7 Glossar

DSM	Digitales Oberflächenmodell
DTM	Digitales Terrainmodell
ENVI	Softwarepaket zur Bildanalyse und Klassifizierung von ITT VIS, welches für diese Arbeit verwendet wurde
FCIR	False Colour Infrared (Infrarot / Rot / Grün dargestellt als RGB-Bild)
ISODATA	Iterative Self-Organizing Data Analysis Technique A
LiDAR	Light Detection And Ranging
NDVI	Normalized Differenced Vegetation Index
RGB	Rot / Grün / Blau - Bild
RVI	Ratio Vegetation Index
WYSIWYG	"What you see is what you get"

8 Quellenverzeichnis

Literatur

- Vorlesungsfolien „Satellitenfernerkundung I“, Prof. Baltsavias, Manos
- Travail de diplôme „Photogrammétrie et traitement d'image“, Fabing, Julien, 17. Dezember 2007
- „Earth observation with ADS40 – applications in agriculture, forestry and archaeology“, Kellenberger, Tobias, 12. November 2007
- Schlussbericht „Objektorientierte Klassifikation des Landwirtschaftsgebietes“, Bühler, Yves

Internet

- A FAQ on Vegetation in Remote Sensing, Terrill W. Ray (<http://hyperdaac.webthing.com/html/rsvegfaq.txt>)
- NASA EO Library: Measuring Vegetation (NDVI and EVI) (<http://earthobservatory.nasa.gov/Library/MeasuringVegetation/>)
- Science and Technology for Applied Remote Sensing (STARS) Vegetation Indices page (<http://www-gem.jrc.it/stars/vis.htm>)
- Lexikon der Fernerkundung (<http://www.fe-lexikon.info>)
- EO Edu – Introducing Remote Sensing (<http://eoedu.belspoo.be/en/guide/>)
- Klassifikation – Zuordnung von Bedeutung anhand ausgewählter Merkmale (http://www.irs.uni-stuttgart.de/skript/RA2/RA2-WS071112_www.pdf)
- ASTER Spectral Library (<http://speclib.jpl.nasa.gov/>)

Gespräche

- Leica Geosystems: 28. Februar 2008 mit Udo Tempelmann
- Swisstopo: 1. April 2008 mit Stéphane Bovet
- Uni ZH, RSL: 2. April 2008 mit Tobias Kellenberger
- WSL: 16. April 2008 mit Christian Ginzler und Lars Waser

9 Anhang

9.1 Aufgabenstellung

Themenvorschlag für eine Bachelorarbeit FS 2008

(Semi-) automatische Klassifikation mit ADS40 Bilddaten

Aufgabenstellung:

Die Klassifikation ist ein wichtiges Verfahren der Fernerkundung zur Extraktion von Informationen. Diese Art der Informationsgewinnung nicht ausschliesslich beschränkt auf Satellitenbilder. Mit der ADS40 der Firma Leica Geosystems steht ein Sensor zur Verfügung, welcher im Gegensatz zum analogen Luftbild über vier spektrale Kanäle verfügt und zusätzlich die Möglichkeit bietet, eine 100%ige Stereoüberlappung des aufgenommenen Gebietes zu realisieren.

Ziel der Arbeit ist es, die genannten Vorteile der ADS40 zu analysieren und ihre Eignung für Klassifikationsaufgaben zu untersuchen.

Vorgehensweise und Tätigkeiten:

- Sichtung der Daten und Definition eines geeigneten Testgebietes
- Definition der zu unterscheidenden Klassen bzw. Festlegung der Klassifikationstiefe
- Ausarbeitung eines Klassifikationsablaufs und Klassifikation des definierten Gebietes mittels der zur Verfügung stehenden Softwaresysteme.
- Untersuchung des potentiellen Vorteils der Einbindung von Stereoüberdeckung für Klassifikationen

Sonstiges:

Die zur Durchführung der Arbeit notwendige Hard- und Software wird zur Verfügung gestellt.

Betreuung:

Thomas Hanusch (Email: thomas@geod.baug.ethz.ch, HIL D52, Tel: 044 6332208)