



TECHNISCHE UNIVERSITÄT MÜNCHEN
Institut für Photogrammetrie und Kartographie
Fachgebiet Photogrammetrie und Fernerkundung

3D-Segmentierung von Einzelbäumen und
Baumartenklassifikation aus Daten flugzeuggetragener
Full Waveform Laserscanner

Josef Reitberger

Dissertation

2010



TECHNISCHE UNIVERSITÄT MÜNCHEN
Institut für Photogrammetrie und Kartographie
Fachgebiet Photogrammetrie und Fernerkundung

3D-Segmentierung von Einzelbäumen und Baumartenklassifikation aus Daten flugzeuggetragener Full Waveform Laserscanner

Josef Reitberger

Vollständiger Abdruck der von der Fakultät für Bauingenieur- und Vermessungswesen
der Technischen Universität München zur Erlangung des akademischen Grades eines

Doktor-Ingenieurs (Dr.-Ing.)

genehmigten Dissertation.

Vorsitzende: Univ.-Prof. Dr.-Ing. L. Meng

Prüfer der Dissertation:

1. Univ.-Prof. Dr.-Ing. U. Stilla
2. Univ.-Prof. Dr. techn. W. Wagner,
Technische Universität Wien/Österreich
3. Prof. Dr.-Ing. P. Krzystek,
Hochschule München

Die Dissertation wurde am 02.03.2010 bei der Technischen Universität München eingereicht
und durch die Fakultät für Bauingenieur- und Vermessungswesen am 26.04.2010 angenommen.

Kurzfassung

Das luftgestützte Laserscanning hat sich in den letzten 15 Jahren rasant entwickelt und hebt sich insbesondere im Waldbereich von anderen Fernerkundungsmethoden ab, weil die Waldstruktur an Lücken von den Laserstrahlen durchdrungen wird. Bedingt durch die Einschränkung der meisten konventionellen Lasersysteme, nur die ersten und letzten Reflexionen zu erfassen, konzentrierten sich die Forschungsaktivitäten der letzten Jahre auf die Ableitung präziser Oberflächen- und Geländemodelle, sowie auf die Nutzung dieser Modelle für die automatische Ermittlung von Waldinformationen. Im Gegensatz dazu besitzen die neuartigen Full Waveform Lasersysteme die Fähigkeit, den reflektierten Laserimpuls vollständig aufzuzeichnen. Dadurch wird neben der Oberfläche und dem Boden des Waldes auch die dazwischenliegende Waldstruktur detailliert erfasst. Um den Vorteil dieser neuen Technik nutzen zu können, müssen die bisherigen Methoden zur Datenauswertung überarbeitet und erweitert werden.

Dazu wird in dieser Arbeit ein Beitrag geleistet, der sich in drei Teilbereiche gliedern lässt. Im ersten Teil werden die aufgezeichneten Echoprofile durch eine Anpassung von Gauß-Funktionen in die einzelnen Reflexionsanteile zerlegt. Aus den geschätzten Parametern dieser Funktionen werden die 3D Positionen der Reflexionen und die Merkmale Intensität und Pulsbreite berechnet. Außerdem werden Ansätze zur Kalibrierung dieser Merkmale untersucht.

Im zweiten Teil wird ein dreistufiges Verfahren zur Segmentierung von Einzelbäumen vorgestellt. Hierbei handelt es sich bei der ersten Stufe um eine Watershed Segmentierung im Baumhöhenmodell. In der zweiten Stufe wird in den Laserdaten nach Baumstämmen gesucht, wofür eine Filterung der Stammpunkte und ein hierarchisches Clustering bzgl. der horizontalen Abstände dieser Punkte erforderlich sind. In der dritten Stufe wird eine Segmentierung der attributierten 3D Punktwolke mit dem Normalized Cut Verfahren entwickelt, das die Ergebnisse der ersten beiden Stufen optional nutzen kann.

Im dritten Teil wird gezeigt, wie den Segmenten in einer Baumartenklassifikation die korrekte Baumart zugeordnet wird. Die dabei eingesetzten Merkmale nutzen neben den Koordinaten der Reflexionen auch die Intensität, die Pulsbreite und die Anzahl von Reflexionen pro Lasermessung.

Die Evaluierung der vorgestellten Methoden zeigt, dass die Zerlegung der Waveforms zu einer hohen räumlichen Punktdichte führt, weil auch überlagerte und schwache Reflexionen berücksichtigt werden. Insbesondere im Vergleich zu First/Last-Pulse Systemen erhält man viele zusätzliche Laserpunkte, die zwischen dem ersten und dem letzten Puls liegen. Beim Verfahren zur Stammerkennung und bei der 3D Segmentierung wird diese hohe räumliche Punktdichte genutzt und führt zu einer höheren Erkennungsrate im Vergleich zur Watershed Segmentierung. Vor allem in den unteren Waldschichten werden deutlich mehr Bäume gefunden. Bei der Baumartenklassifikation zeigt die Nutzung der kalibrierten Intensität eine erhebliche Verbesserung gegenüber der alleinigen Verwendung der Koordinaten der Reflexionen.

Abstract

Airborne laser scanning has developed at a tremendous speed over the last 15 years, and it sets itself apart from other remote sensing techniques, in the forestry sector particularly, because the forest structure is penetrated by the laser beams along gaps. Constrained by the fact that most conventional laser systems can only register the first and last reflections, the research activities of recent years have focused on deriving precise canopy and terrain models, and on using these models for the automatic ascertaining of forest information. By contrast, the novel full waveform laser systems have the ability to record the reflected laser pulse signal in its entirety. This means that as well as the canopy and floor of the forest, the intermediate forest structure is also captured in detail. In order to be able to exploit the advantages of this new technique, the existing methods of data analysis must be revised and expanded.

This thesis makes a contribution towards this, which can be divided into three sections. In the first section, the recorded waveforms are decomposed into the individual reflections using adjusted Gaussian curves. From the estimated parameters of these curves, the 3D positions of the reflections and their intensity and pulse width attributes are calculated. In addition, approaches for calibrating these attributes are investigated.

In the second section, a three-stage procedure for the segmentation of individual trees is presented. The first stage involves a watershed segmentation using the canopy height model. In the second stage, a search is made in the laser data for tree trunks, which requires filtering the laser points resulting from trunks and clustering them hierarchically according to the horizontal distances between them. In the third stage, a segmentation of the 3D point cloud is developed which bases upon the normalized cut algorithm and optionally can utilize the attributes intensity and pulse width and the results of the first two stages.

The third section shows how the correct tree species are assigned to the segments by carrying out a tree species classification. The utilised features base upon the coordinates of the reflections, the intensity, the pulse width and the number of reflections per laser measurement.

The evaluation of the methods presented shows that the decomposition of the waveforms leads to a high spatial point density because superposed and weak reflections are also included. Particularly in comparison to first/last pulse systems, many additional laser points which lie between the first and last pulse are obtained. This high spatial point density is used in the trunk identification procedure and in the 3D segmentation, and it leads to a higher identification rate compared to the watershed segmentation. Considerably more trees are detected, especially in lower forest layers. When it comes to the classification of tree species, the use of the calibrated intensity of the reflections shows a substantial improvement as compared to using the coordinates of the reflections alone.

Inhaltsverzeichnis

| | |
|---|------------|
| Kurzfassung | i |
| Abstract | ii |
| Inhaltsverzeichnis | iii |
| Liste der Symbole und Abkürzungen | vii |
| Abbildungsverzeichnis | ix |
| Tabellenverzeichnis | xi |
| 1 Einleitung | 1 |
| 1.1 Motivation für eine automatisierte Erfassung von Waldstrukturen mit Hilfe der Fernerkundung | 1 |
| 1.2 Automatisierte Inventur auf Bestandes- und Einzelbaumebene | 2 |
| 1.3 Fernerkundungstechniken im Überblick | 4 |
| 1.3.1 Radar | 4 |
| 1.3.2 Passive optische Sensoren | 5 |
| 1.3.3 Laserscanning | 6 |
| 1.4 Ziele der Arbeit | 11 |
| 1.5 Aufbau der Arbeit | 12 |
| 2 Full Waveform Laserscanning | 15 |
| 2.1 Grundlagen | 15 |
| 2.2 Zerlegung der Waveforms | 18 |
| 2.2.1 Waveforms als Summe von Gauß-Funktionen | 18 |
| 2.2.2 Schätzung der Modellparameter | 19 |
| 2.2.3 Ringing Effekt | 21 |
| 2.3 3D Punkte und deren Attribute | 22 |
| 2.3.1 Ableitung aus den geschätzten Parametern | 22 |
| 2.3.2 Kalibrierung von Intensität und Pulsbreite | 23 |
| 3 Segmentierung von Einzelbäumen | 27 |
| 3.1 Segmentierung auf Basis des Baumhöhenmodells | 28 |
| 3.1.1 Berechnung des CHM | 28 |
| 3.1.2 Watershed Algorithmus | 29 |

| | | |
|----------|---|-----------|
| 3.2 | Detektion von Baumstämmen | 30 |
| 3.2.1 | Nutzung der Information unterhalb des CHM | 30 |
| 3.2.2 | Filterung von Stammpunkten | 31 |
| 3.2.3 | Hierarchisches Clustering | 32 |
| 3.2.4 | Nachbearbeitung der Stammcluster | 33 |
| 3.2.5 | Vorteile und Grenzen der Stammerkennung | 34 |
| 3.3 | Segmentierung auf Basis der attributierten 3D Punktwolke | 35 |
| 3.3.1 | Anforderung an das Verfahren | 35 |
| 3.3.2 | Grundlagen der Normalized Cut Segmentierung | 36 |
| 3.3.3 | Voxelbildung | 39 |
| 3.3.4 | Ähnlichkeitsfunktion | 40 |
| 3.3.5 | Diskretisierung des Lösungsvektors | 42 |
| 3.3.6 | Hierarchisches Ablaufschema | 43 |
| 3.3.7 | Nachbearbeitung der Segmente | 45 |
| 3.3.8 | Vorteile der 3D Segmentierung gegenüber der Watershed Segmentierung und der Stammdetektion | 45 |
| 4 | Baumartenklassifikation | 47 |
| 4.1 | Extraktion von Merkmalen | 47 |
| 4.1.1 | Äußere Baumgeometrie | 48 |
| 4.1.2 | Interne Baumstruktur | 49 |
| 4.1.3 | Merkmale aus den Attributen der Reflexionen | 50 |
| 4.2 | Unüberwachte und überwachte Klassifikation | 51 |
| 5 | Messkampagnen | 53 |
| 5.1 | Referenzflächen | 53 |
| 5.2 | Laserdaten | 55 |
| 6 | Experimente | 57 |
| 6.1 | Auswertung der Waveforms | 57 |
| 6.1.1 | Ableitung von Punkten und Attributen | 57 |
| 6.1.2 | Kalibrierung von Intensität und Pulsbreite | 64 |
| 6.1.3 | Analyse von Intensität und Pulsbreite | 66 |
| 6.2 | Segmentierung | 69 |
| 6.2.1 | Evaluierung der Ergebnisse | 69 |
| 6.2.2 | Steuerparameter | 69 |
| 6.2.3 | Durchführung und Kombination der Verfahren | 72 |
| 6.2.4 | Vergleich der Resultate für die verschiedenen Verfahren | 73 |
| 6.2.5 | Belaubter und unbelaubter Vegetationszustand | 76 |
| 6.2.6 | Einfluss der Punktdichte | 77 |
| 6.2.7 | Vergleich von First/Last-Pulse und Full Waveform | 78 |
| 6.2.8 | Vergleich der beiden Full Waveform Systeme | 80 |
| 6.3 | Baumartenklassifikation | 81 |
| 6.3.1 | Klassifikation von Laub- und Nadelbäumen | 82 |
| 6.3.2 | Klassifikation einzelner Laub- und Nadelbaumarten | 85 |

| | | |
|----------|---|------------|
| 7 | Diskussion | 87 |
| 7.1 | Zerlegung der Waveforms | 87 |
| 7.1.1 | Eignung des Gauß-Modells | 87 |
| 7.1.2 | Schätzung der unbekannt Parameter und deren Genauigkeiten | 88 |
| 7.1.3 | Ringing Effekt | 88 |
| 7.1.4 | Vergleich der beiden Scanner | 88 |
| 7.1.5 | Vorteile gegenüber der Erfassung bei diskret arbeitenden Systemen | 89 |
| 7.2 | Kalibrierung der Intensität | 89 |
| 7.3 | Analyse von Intensität und Pulsbreite | 90 |
| 7.3.1 | Vergleich von Boden-, Stamm- und Kronenpunkten | 90 |
| 7.3.2 | Vergleich von Laub- und Nadelbäumen | 91 |
| 7.4 | Erkennung von Einzelbäumen | 91 |
| 7.4.1 | Watershed Segmentierung | 91 |
| 7.4.2 | Erkennung von Baumstämmen | 92 |
| 7.4.3 | Normalized Cut Segmentierung | 92 |
| 7.4.4 | Festlegung von Schwellwerten | 93 |
| 7.4.5 | Belaubter und unbelaubter Vegetationszustand | 94 |
| 7.4.6 | Unterschiedliche Punktdichten | 94 |
| 7.4.7 | Vorteil der Full Waveform Technologie | 94 |
| 7.4.8 | Vergleich der beiden Full Waveform Scanner | 95 |
| 7.5 | Baumartenklassifikation | 95 |
| 7.5.1 | Unterscheidung von Laub- und Nadelbäumen | 95 |
| 7.5.2 | Unterscheidung einzelner Laub- und Nadelbaumarten | 97 |
| 8 | Zusammenfassung und Ausblick | 99 |
| 8.1 | Zusammenfassung | 99 |
| 8.2 | Ausblick | 102 |
| | Literaturverzeichnis | 105 |
| | Lebenslauf | 113 |

Liste der Symbole und Abkürzungen

| Abkürzung | Beschreibung | Definition |
|-----------|--|------------|
| ALS | Airborne Laser Scanning | Seite 6 |
| ALTM | Airborne Laser Terrain Mapper | Seite 8 |
| BHD | Brusthöhendurchmesser | Seite 3 |
| CHM | Canopy Height Model | Seite 4 |
| DGM | Digitales Geländemodell | Seite 4 |
| DN | Digital Number | Seite 58 |
| DOM | Digitales Oberflächenmodell | Seite 4 |
| DTHM | Digital Tree Height Model | Seite 4 |
| EM | Expectation-Maximization | Seite 18 |
| FWHM | Full Width at Half Maximum | Seite 55 |
| GLAS | Geoscience Laser Altimeter System | Seite 7 |
| HYDICE | Hyperspectral Digital Imagery Collection Experiment | Seite 6 |
| H_{100} | Mittlere Höhe der 100 stärksten Bäume je Hektar (= Oberhöhe) | Seite 55 |
| InSAR | Interferometric Synthetic Aperture Radar | Seite 4 |
| LiDAR | Light Detection And Ranging | Seite 5 |
| LM | Levenberg-Marquardt | Seite 18 |
| LVIS | Laser Vegetation Imaging Sensor | Seite 7 |
| MAD | Median Absolute Deviation | Seite 21 |
| ML | Maximum-Likelihood | Seite 52 |
| MPiA | Multiple Pulses in Air | Seite 6 |
| PRF | Pulse Rate Frequency | Seite 55 |
| Radar | Radio detection and ranging | Seite 4 |
| RMSE | Wurzel des mittleren quadratischen Fehlers | Seite 4 |
| RTM | Radiative Transfer Model | Seite 8 |
| SAR | Synthetic Aperture Radar | Seite 4 |
| SHOALS | Scanning Hydrographic Operational Airborne Lidar Survey | Seite 7 |
| SLICER | Scanning LiDAR Imager of Canopies by Echo Recovery | Seite 7 |

Abbildungsverzeichnis

| | | |
|------|--|----|
| 1.1 | Automatisierte Erfassung von Waldstrukturen | 2 |
| 1.2 | Waldinventur auf Einzelbaumebene | 3 |
| 1.3 | Erfassung von Bäumen mit Hilfe von ALS | 7 |
| 2.1 | Geometrie und Messgrößen in der Radargleichung | 16 |
| 2.2 | Anpassung von Gauß-Funktionen an die Waveforms einer Messung | 17 |
| 2.3 | Modellierung einer Waveform mit fünf Reflexionen | 19 |
| 2.4 | Berücksichtigung des Ringing Effekts | 22 |
| 2.5 | Ableitung von 3D Punkten und deren Attributen | 23 |
| 2.6 | Überlagerung von Objekten mit unterschiedlich großen Footprints F_1 und F_2 | 25 |
| 3.1 | Filterung der höchsten Punkte | 28 |
| 3.2 | Interpolation der höchsten Punkte in ein regelmäßiges Gitter | 29 |
| 3.3 | Prinzip des Watershed Algorithmus | 30 |
| 3.4 | Anwendung des Watershed Algorithmus für die Segmentierung von Bäumen | 30 |
| 3.5 | Beispiele für Segmente mit Baumgruppen anstelle von Einzelbäumen | 31 |
| 3.6 | Vorgehensweise bei der Filterung von Stammpunkten | 32 |
| 3.7 | Hierarchisches Clustering von Stammpunkten | 33 |
| 3.8 | Erfolgreiche Detektion von Baumstämmen | 34 |
| 3.9 | Unterschiedliche Voraussetzungen für die Detektion von Stämmen | 35 |
| 3.10 | Repräsentation eines Bildes als voll verbundener Graph mit Knoten und Kanten | 37 |
| 3.11 | Bildung von Segmenten beim Normalized Cut Verfahren | 37 |
| 3.12 | Vergleich von „Minimum Cut“ und „Normalized Cut“ anhand eines Beispiels | 39 |
| 3.13 | Voxelbildung und Aufteilung in Segmente | 40 |
| 3.14 | Gewichtung in Abhängigkeit von der Entfernung zu $\mathbf{X}_{\text{apriori}}$ | 41 |
| 3.15 | Einfluss von σ_f auf die Werte von $e^{-\mathbf{F}(i,j)}$ | 41 |
| 3.16 | Beispiel für die optimale Wahl von y_{split} bei der Diskretisierung von \mathbf{y}_1 | 42 |
| 3.17 | Beispiel für einen von Null abweichenden Parameter y_{split} | 43 |
| 3.18 | Beispiel für rekursiven Two-Way Ncut | 45 |
| 3.19 | Segmentierung von Bäumen ohne eigenes lokales Maximum | 46 |
| 3.20 | Segmentierung von Verjüngung und verdeckten Bäumen | 46 |
| 4.1 | Anpassung eines Paraboloids an die Baumkrone | 48 |
| 4.2 | Unterteilung der Baumsegmente in Höhenschichten | 49 |
| 4.3 | Merkmale der internen Baumstruktur für fünf Fichten und fünf Buchen | 50 |

| | | |
|------|---|----|
| 5.1 | Lage der Teilgebiete im Nationalpark Bayerischer Wald | 53 |
| 5.2 | Teilgebiet E mit Referenzflächen | 54 |
| 5.3 | Teilgebiet C mit Referenzflächen | 54 |
| 6.1 | Überprüfung des TopEye Scanners auf gaußförmige Signale | 58 |
| 6.2 | Überprüfung des Riegl Scanners auf gaußförmige Signale | 58 |
| 6.3 | Beispiel für die Auswirkungen des Ringing Effekts | 59 |
| 6.4 | Vergleich von First/Last-Pulse und Full Waveform anhand von Beispielen | 61 |
| 6.5 | Waveforms mit vielen Reflexionen | 62 |
| 6.6 | Waveforms mit nur einem Einzelpunkt bei der diskreten Aufzeichnung | 62 |
| 6.7 | Trennung stark überlagernder Reflexionen | 63 |
| 6.8 | Trennung von Reflexionen ohne eigenes lokales Maximum | 63 |
| 6.9 | Keine Trennung überlagernder Reflexionen | 64 |
| 6.10 | Flugplatz in Straubing mit Flugspuren und Kalibrierflächen | 65 |
| 6.11 | Laserpunkte von den beiden Vegetationsbereichen in der Abbildung 6.10 | 66 |
| 6.12 | Analyse von Pulsbreite und Intensität für Stamm-, Kronen- und Bodenpunkte | 67 |
| 6.13 | Analyse von Pulsbreite und Intensität für die Kronenpunkte von Laub- und Nadelbäumen | 68 |
| 6.14 | Analyse von Pulsbreite und Intensität für die Stammpunkte von Laub- und Nadelbäumen | 68 |
| 6.15 | Watershed Segmente für verschiedene Glättungen des CHM | 70 |
| 6.16 | Abhängigkeit der Watershed Segmentierung vom Glättungsfaktor λ | 71 |
| 6.17 | Abhängigkeit der Normalized Cut Segmentierung vom Schwellwert $NCut_{max}$ | 72 |
| 6.18 | Gefundene Bäume in Abhängigkeit vom BHD für den Datensatz IV | 74 |
| 6.19 | Gefundene Bäume in Abhängigkeit vom BHD für den Datensatz IV (nur Laubbäume) | 75 |
| 6.20 | Gefundene Bäume in Abhängigkeit vom BHD für den Datensatz IV (nur Nadelbäume) | 75 |
| 6.21 | Beispiele für die Zusammenfassung mehrerer Bäume | 76 |
| 6.22 | Beispiele für mehrere kleine Bäume in einem Segment (blau) | 76 |
| 6.23 | Beispiele für falsche Segmente | 77 |
| 6.24 | Vergleich von First/Last-Pulse und Full Waveform für zwei benachbarte Fichten | 79 |
| 6.25 | Beispiel für die gute Auflösung von Kronenstrukturen durch die Waveform Zerlegung | 79 |
| 6.26 | Beispiel für den sowohl technologisch als auch methodisch bedingten Fortschritt | 80 |

Tabellenverzeichnis

| | | |
|------|---|----|
| 2.1 | Unterteilung der abgeleiteten Punkte \mathbf{X}_m in Klassen | 23 |
| 5.1 | Eigenschaften der Referenzflächen | 54 |
| 5.2 | Charakteristiken der verschiedenen ALS Kampagnen | 55 |
| 5.3 | Spezifikationen der verwendeten Scanner | 55 |
| 6.1 | Vergleich von First/Last-Pulse mit Full Waveform Punkten | 60 |
| 6.2 | Ergebnisse für die Kalibrierung der Intensität | 65 |
| 6.3 | Steuerparameter für die Verfahren zur Einzelbaumerkennung | 70 |
| 6.4 | Parametrisierungen der Ähnlichkeitsfunktion bei der Normalized Cut Segmentierung | 73 |
| 6.5 | Segmentierungsergebnisse für den Datensatz IV (alle Teilgebiete) | 73 |
| 6.6 | Genauigkeit der Baumpositionen für den Datensatz IV | 74 |
| 6.7 | Segmentierungsergebnisse für den Datensatz V (alle Teilgebiete) | 77 |
| 6.8 | Segmentierungsergebnisse für den Datensatz V (Teilgebiet E) | 78 |
| 6.9 | Segmentierungsergebnisse für den Datensatz VI (Teilgebiet E) | 78 |
| 6.10 | Segmentierungsergebnisse für den Datensatz II (Teilgebiet E) | 78 |
| 6.11 | Segmentierungsergebnisse für den Datensatz III (Referenzflächen 74 und 81) | 81 |
| 6.12 | Segmentierungsergebnisse für den Datensatz V (Referenzflächen 74 und 81) | 81 |
| 6.13 | Ergebnisse der Klassifikation zwischen Laub- und Nadelbäumen für die Watershed Segmente | 82 |
| 6.14 | Ergebnisse der Klassifikation zwischen Laub- und Nadelbäumen für die Normalized Cut Segmente | 82 |
| 6.15 | Konfusionsmatrizen der überwachten Klassifikation von Laub- und Nadelbäumen | 84 |
| 6.16 | Klassifikationsgenauigkeit in Abhängigkeit von der Höhenschicht | 84 |
| 6.17 | Konfusionsmatrix der überwachten Klassifikation von Fichte und Tanne | 85 |

Kapitel 1

Einleitung

1.1 Motivation für eine automatisierte Erfassung von Waldstrukturen mit Hilfe der Fernerkundung

In jüngster Zeit ist die Attraktivität von Holz als CO₂ neutrale, nachwachsende Energiequelle stark gestiegen. Studien wie [United Nations, 2005] deuten darauf hin, dass die holzverarbeitende Industrie in Europa künftig mehr Holz benötigt. Somit nimmt der Bedarf an Holz zu und die Konkurrenz um diesen Rohstoff verschärft sich. Um trotzdem eine nachhaltige Forstwirtschaft gewährleisten zu können, sind effiziente Methoden der Waldinventur notwendig. Das Management und die Planung der Waldbewirtschaftung benötigen präzise und aktuelle Inventurergebnisse, die auch für die Beurteilung von ökologischen Aspekten, wie Schutzfunktionen, Biodiversität oder Habitatbedingungen geeignet sind [Desclée et al., 2008].

In den meisten europäischen Ländern werden seit Jahrzehnten Waldinventuren durchgeführt, die auf einer stichprobenartigen, manuellen Erfassung von Waldparametern, wie z.B. Baumart, Baumhöhe, Baumdurchmesser und Baumalter beruhen. Das dabei verwendete Gitternetz hat je nach Land eine Gitterweite zwischen 1 × 1 km und 32 × 32 km [Lorenz et al., 2007]. Mit Hilfe statistischer Methoden werden aus den registrierten Werten an den Inventurpunkten die Zielparameter der Inventur flächenhaft berechnet. Die genaue Vorgehensweise kann z.B. der Aufnahmeanweisung für die Bundeswaldinventur II [Polley, 2001] entnommen werden. Zusätzlich zu den nationalen Erhebungen finden auch in den privaten und staatlichen Forstbetrieben, wie den Bayerischen Staatsforsten, Inventuren mit engeren Gitternetzen statt.

Mit dieser stichprobenartigen Erfassung des Waldes kann dessen Zustand großräumig gut charakterisiert werden. Kleinräumige Analysen, wie die präzise Ortung von Beständen oder einzelner Bäume mit ganz bestimmten Eigenschaften sind aber kaum möglich. Ein weiterer Nachteil ist der hohe Zeit- und Personalaufwand für die Datenerfassung, was zu großen zeitlichen Abständen zwischen den einzelnen Inventuren führt und keine schnelle Reaktion bei Naturkatastrophen oder sonstigen Schadensereignissen erlaubt.

Die Fernerkundung bietet die Chance, Inventuren viel schneller durchzuführen und den Wald großflächig bei hohem Detaillierungsgrad zu erfassen, so dass zusätzlich zu den klassischen Zielparametern (z.B. Holzvolumen) auch Informationen über die Struktur der Bestände abgeleitet werden können. Neben der Verfügbarkeit geeigneter Sensoren sind vor allem Methoden für die Extraktion der relevanten Informationen aus den erfassten Rohdaten erforderlich.

1.2 Automatisierte Inventur auf Bestandes- und Einzelbaumebene

Für die Automatisierung von Waldinventuren mit Fernerkundungsdaten gibt es zwei grundsätzlich verschiedene Lösungsansätze, zum einen die Inventur auf Bestandesebene und zum anderen die Inventur auf Einzelbaumebene (Abbildung 1.1). Bei der Bestandesebene werden zunächst für die einzelnen

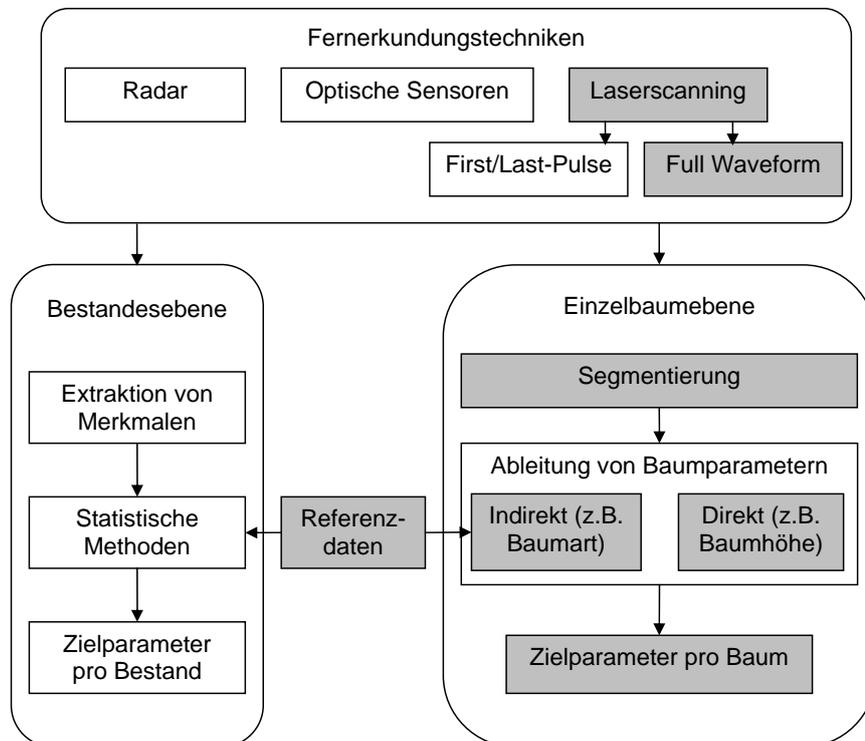


Abbildung 1.1: Automatisierte Erfassung von Waldstrukturen auf Bestandes- und Einzelbaumebene. Die markierten Felder kennzeichnen die Vorgehensweise in der vorliegenden Arbeit.

Bestände Merkmale aus den Daten extrahiert. Diese werden auf Referenzflächen empirisch mit manuell erfassten Werten für die Zielparameter, wie z.B. dem Holzvorrat, verknüpft. Hierbei kommen meist statistische Methoden mit Regressionsmodellen zum Einsatz, die dann eine Ableitung der Zielparameter auf allen anderen Flächen ermöglichen. Diese Vorgehensweise hat den Vorteil, dass kein explizites Modell für die Abbildung des Waldes durch den jeweiligen Sensor formuliert werden muss. Wie die Arbeit von [Hyypä et al. \[2000\]](#) zeigt, können die Daten unterschiedlichster Sensoren bei diesem Verfahren eingesetzt werden, wobei der Unterschied nur in der Berechnung der Merkmale liegt. Zudem können auch Daten mit relativ grober räumlichen Auflösung (z.B. Satellitendaten) genutzt werden, um großflächige Aussagen zu treffen. In den einfach strukturierten borealen Wäldern wird das Verfahren auf Bestandesebene schon seit einigen Jahren kommerziell angewendet [[Naesset, 2004](#)], wobei meist die Daten flugzeuggetragener Laserscanner verwendet werden. In den Mischwäldern der gemäßigten Klimazone hingegen stößt dieses Verfahren an seine Grenzen. [Koch et al. \[2006\]](#) betonen, dass die Inventur auf Bestandesebene sehr schwierig ist und Vorwissen über die Anzahl der Stämme und die Baumartenverteilung braucht, wenn in einem Bestand mehrere Baumarten mit unterschiedlichem Wachstumsverhalten auftreten.

Eine Inventur auf Einzelbaumebene ist bei solchen Wäldern vorteilhaft (Abbildung 1.2a) und kann

die für Ernteplanungen notwendigen Einzelbauminformationen liefern. Das Prinzip dieser Methode besteht darin, die bei der konventionellen Inventur nur an den Inventurpunkten erfassten Parameter für alle Bäume automatisch zu bestimmen, was eine detaillierte Vermessung der einzelnen Bäume bedeutet (Abbildung 1.2b). Der wesentliche Schritt ist dabei die Segmentierung zur Abgrenzung der einzelnen

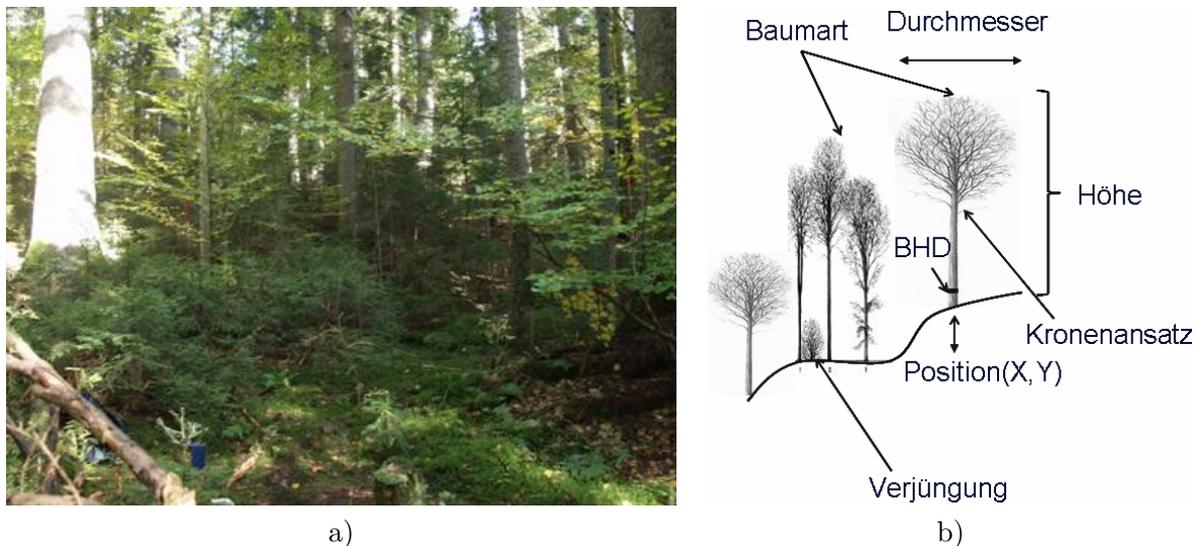


Abbildung 1.2: Waldinventur auf Einzelbaumbene. a) Beispiel für einen Bestand mit verschiedenen großen Bäumen und unterschiedlichen Baumarten, in dem diese Methode vorteilhaft ist, b) Parameter bei der Inventur auf Einzelbaumbene [Schumann, 2005]

Bäume. Aus den Segmenten werden dann die gesuchten Baumparameter abgeleitet, wobei nur für einen Teil dieser Parameter (z.B. Baumposition, Baumhöhe, Ansatz und Durchmesser der Krone) eine direkte Bestimmung möglich ist. Andere Parameter, wie die Baumart und der Brusthöhendurchmesser (BHD), können nur indirekt abgeleitet werden. Um den Zusammenhang zwischen diesen Parametern und Merkmalen aus den Segmenten zu kalibrieren, sind Referenzdaten notwendig, deren Anzahl jedoch bei weitem nicht so hoch sein muss wie bei der Inventur auf Bestandesebene [Chen et al., 2007]. Das Ergebnis sind umfangreiche und flächendeckende Informationen, die über die Waldinventur hinaus auch für viele andere Anwendungen, wie die Waldforschung, geeignet sind. Insbesondere die Fähigkeit, dass die detaillierten Einzelbaumparameter leicht zu beliebig großen Einheiten akkumuliert werden können, macht das Verfahren sehr allgemein und breit einsetzbar.

Packalén et al. [2008] vergleichen die Einzelbaum- und Bestandesmethode in einem borealen, von Fichten und Kiefern dominierten Wirtschaftswald und stellen fest, dass der Holzvorrat etwa genau ermittelt werden kann. Beim Einzelbaumverfahren sind zwar die Anforderungen an die räumliche Auflösung der Daten höher, dafür kann aber bei der Erfassung der Referenzdaten gespart werden. Da der rasche technologische Fortschritt eine immer schnellere und billigere Erfassung hochaufgelöster Daten ermöglicht, hat der Einzelbaumansatz gute Perspektiven für die Zukunft. Das größte Verbesserungspotenzial bei dieser Methode liegt in einer genaueren Erkennung und Isolierung der einzelnen Bäume und in einer besseren Bestimmung der Baumart. Vor allem bei kleineren Bäumen gibt es hier noch große Defizite. Ziel dieser Arbeit ist es deshalb, Verbesserungen im Bereich der Baumsegmentierung und der Baumartenklassifikation zu erreichen.

1.3 Fernerkundungstechniken im Überblick

Für die Erfassung von Wäldern stehen mehrere Fernerkundungstechniken zur Verfügung, auf welche in den folgenden Abschnitten näher eingegangen wird.

1.3.1 Radar

Beim aktiven Radar Verfahren werden Mikrowellen ausgesendet und die Laufzeit und Amplitude der reflektierten Signale gemessen, so dass die Entfernung der Objekte zum Sensor berechnet werden kann. Mikrowellen nehmen im elektromagnetischen Spektrum Wellenlängen zwischen 1 mm und 1 m ein und besitzen eine Energie von 2×10^{-25} bis 2×10^{-22} J. Auf Grund dieser Wellenlänge bzw. Frequenz ergibt sich eine charakteristische Wechselwirkung mit der Materie. Die Reflexion der Mikrowellen wird hauptsächlich von den elektrischen Materialeigenschaften beeinflusst. Weitere Merkmale sind ein hoher Transmissionsgrad der Atmosphäre und die Fähigkeit der Mikrowellen, in bestimmtem Maße in Objekte einzudringen oder sie zu durchdringen. Die Eindringtiefe ist dabei um so größer, je länger die verwendeten Wellen sind und je niedriger der Feuchtegehalt des Materials ist. Zum Beispiel können die Wellen des L-Bands (15 cm - 30 cm) den Oberflächenstreuer Vegetation durchdringen und direkt mit dem darunter liegenden Volumenstreuer Boden reagieren. Aus der Intensität der Rückstreuung kann man auf die Oberflächenrauigkeit und den Wassergehalt der Objekte schließen.

Bei Radarsystemen mit „Realer Apertur“ nimmt die geometrische Auflösung in Flugrichtung (=Azimutrichtung) mit zunehmender Entfernung zwischen Antenne und Gelände ab, so dass sich Systeme dieser Art nur für geringe Flughöhen eignen. Um in Flugrichtung eine höhere Auflösung zu erreichen und insbesondere die Aufnahme von Radarbildern auch von Satelliten aus möglich zu machen, müssen Radar-Systeme mit „Synthetischer Apertur“ (engl. Synthetic Aperture Radar oder SAR) eingesetzt werden. Dabei wird nur eine kurze Antenne verwendet, welche die Mikrowellenimpulse in einer breiten Keule abstrahlt. Während des Fluges werden die einzelnen Geländepunkte mehrfach bestrahlt und tragen vielfach zu den empfangenen Reflexionssignalen bei. Bei der Verarbeitung werden die Daten so behandelt, als würden sie von einzelnen Elementen eines sehr langen Antennensystems stammen. Dadurch lassen sich Bilddaten mit hoher geometrischer Auflösung ableiten. Je weiter die Geländepunkte von der Antenne entfernt sind, desto häufiger werden sie abgebildet und desto länger ist die scheinbare (synthetische) Antenne. Dies führt dazu, dass die Auflösung in der Flugrichtung theoretisch entfernungsunabhängig wird [Albertz, 2007]. Um dreidimensionale Objektinformationen aus Radardaten abzuleiten, kann der Phasenunterschied zwischen zwei SAR-Aufnahmen, die von verschiedenen Positionen stammen, ausgewertet werden, was man als SAR-Interferometrie (InSAR) bezeichnet.

Radar kann bei der Waldinventur sowohl auf Bestandesebene als auch auf Einzelbaumebene eingesetzt werden. Bei der Untersuchung von Hyypä et al. [2000], die das Holzvolumen eines borealen Waldes auf Bestandesebene bestimmen, beträgt die Wurzel aus dem mittleren quadratischen Fehler (RMSE) 34 %, wenn die Daten eines flugzeuggetragenen Radar-Sensors verwendet werden. Im Vergleich dazu erreichen die Autoren mit Merkmalen aus Luftbildern nur einen RMSE-Wert von 46 %. Die Verwendung von satellitengestützten Radardaten führt lediglich zu einem Wert von 58 %. Bei der Inventur auf Einzelbaumebene werden die Höhen der einzelnen Bäume im Baumhöhenmodell bestimmt, das im Englischen als „Canopy Height Model“ (CHM) oder „Digital Tree Height Model“ (DTHM) bezeichnet wird und die Differenz zwischen dem digitalen Oberflächenmodell (DOM) und dem digitalen Geländemodell (DGM) darstellt. Zur Ableitung des DOM eignen sich die kurzen Wellen des X-Bands (ca. 3 cm), weil diese kaum in den Wald eindringen und an den Blättern und Zweigen gestreut werden.

Die Wellen des P-Bands (30 cm - 100 cm) hingegen können den Wald bis zum Boden durchdringen und ermöglichen somit die Ableitung des DGM. Die Charakteristiken der aus flugzeuggestützten InSAR Daten abgeleiteten Höhenmodelle werden in den Arbeiten von Andersen et al. [2003], Heurich [2006] und Balzter et al. [2007] untersucht. Dabei kommen sie zu dem Ergebnis, dass die InSAR Gelände- und Oberflächenmodelle generalisierter und weniger detailliert sind als Modelle, die aus „Light Detection And Ranging (LiDAR)“ Daten berechnet werden. Die ungenaue Repräsentation der Baumspitzen im InSAR-DOM führt zu einer erheblichen Unterschätzung der Baumhöhen von mehreren Metern. Heurich [2006] und Balzter et al. [2007] stellen auch grobe Fehler im InSAR-DGM von örtlich mehr als 10 m fest, was vermutlich am dichten und hohen Baumbestand in deren Testgebieten liegt. Somit vermag das P-Band nicht mehr bis zum Boden vorzudringen, sondern wird durch stärkere Baumstrukturen bereits vorher gestreut. Die Verwendung von noch längeren Wellen als die des P-Bands könnte hier hilfreich sein. Insgesamt geht aus den obigen Arbeiten hervor, dass die Ableitung von Einzelbauminformationen aus Radardaten bis jetzt noch recht ungenau ist. Es gibt jedoch vielversprechende Ansätze, Baumparameter mit Hilfe spezieller Rückstreumodelle aus diesen Daten zu bestimmen. Kononov & Ka [2008] stellen zum Beispiel ein Modell zur Schätzung des Stammvolumens auf Einzelbaumebene vor, das allerdings die Dichte des Baumbestandes als Eingangsinformation benötigt.

1.3.2 Passive optische Sensoren

Diese Gruppe von Sensoren umfasst Luftbildkameras und abbildende Spektrometer, welche die von der Waldoberfläche reflektierte Sonnenstrahlung aufzeichnen. Dabei kann die Aufnahme vom Flugzeug oder vom Satelliten aus erfolgen. Bei digitalen Systemen unterscheidet man je nach Anzahl der spektralen Kanäle zwischen panchromatischen, multispektralen und hyperspektralen Sensoren.

Standard-Luftbilder werden schon seit geraumer Zeit für die Forstplanung eingesetzt, weil sie eine effektive Bearbeitung großer Flächen ermöglichen. Mit Hilfe stereoskopischer Messungen und visueller Interpretationen können Bestände beschrieben, voneinander abgegrenzt und deren Fläche ermittelt werden. Insbesondere Farbinfrarot-Luftbilder eignen sich zur Unterscheidung von Baumarten und zum Monitoring von Waldschäden [Rall & Martin, 2002], da das Chlorophyll der Vegetation vor allem im nahen Infrarot viel stärker reflektiert als im sichtbaren Spektralbereich. Neben einer guten Differenzierung zwischen lebendem und abgestorbenem Pflanzenmaterial ist die Reflexion in diesem Spektrum auch von Parametern wie dem Aufbau der Zellstruktur abhängig.

Die ersten Ansätze für die Automatisierung von Waldinventuren basieren ebenfalls auf Luftbildern und setzen sich aus den folgenden Hauptschritten zusammen: (i) Es müssen die Positionen der einzelnen Bäume bestimmt und deren Kronen voneinander abgegrenzt und parametrisiert werden. (ii) Aus den abgeleiteten Kronenmerkmalen (z.B. Fläche, Umfang, Grauwerte, Texturen) werden dann weitere Baumparameter (z.B. Holzvolumen, Baumart) ermittelt. Zur Bestimmung der Baumpositionen werden häufig die lokalen Maxima der Helligkeit verwendet [Wulder et al., 2000], die insbesondere bei Nadelbäumen gut mit den Baumspitzen korrespondieren. Bei der Abgrenzung der Baumkronen verfolgt z.B. Gougeon [1995] die Schattenbereiche zwischen den Kronen. Brandtberg & Walter [1998] hingegen nutzen Methoden zur Kantendetektion im Gradientenbild. Neben diesen datengetriebenen Ansätzen existieren auch modellbasierte Ansätze, die mit Hilfe von „Template Matching“ Methoden in den Bildern nach zuvor definierten Kronenmodellen suchen [Olofsson, 2002].

Bei der Verwendung von Luftbildern für die automatische Ableitung von Baumparametern müssen die Charakteristiken dieser Erfassungsmethode berücksichtigt werden. Die Abhängigkeit der Beleuchtung von der jeweiligen Sonnenposition und dem Wetter verlangt, dass der Himmel zum Befliegungs-

zeitpunkt klar sein muss und die Befliegung nicht zu lange dauern darf, um Luftbilder mit gleichmäßiger Radiometrie zu erhalten [Desclée et al., 2008]. Neben den genannten Abhängigkeiten verändern Bäume die Beleuchtung ihrer Nachbarbäume. Da der größte Teil des Sonnenlichts von der Waldoberfläche reflektiert wird, ist diese in den Bildern detailliert erfasst. Aus diesem Grund eignen sich Luftbilder sehr gut für die DOM Berechnung. Baltasvias et al. [2008] stellen in einem Vergleich fest, dass hier mit Hilfe von Luftbildern ähnliche Genauigkeiten wie mit LiDAR Daten erzielt werden können. Weil jedoch der Waldboden in den Bildern nur bei größeren Lücken zwischen den Bäumen sichtbar ist, erweist sich die DGM Ableitung vor allem in geschlossenen Beständen als sehr schwierig [Bauerhansl et al., 2004]. Bei fehlendem DGM können die Baumhöhen nicht direkt bestimmt werden, was eine indirekte Schätzung aus Kronenmerkmalen mit Hilfe von Referenzdaten erfordert. Diese Höheninformation ist jedoch nur ungenau und spiegelt sich in einer groben Ermittlung des Holzvolumens wider. Im Gegensatz dazu können LiDAR-Systeme die vertikale Struktur der Wälder und den Boden auch bei dichtem Baumbestand mit hoher Genauigkeit erfassen, so dass sich die Forschungsaktivitäten im Bereich der automatischen Waldinventur seit dem Einsatz dieser Systeme immer mehr auf das Laserscanning konzentrieren.

Die große Stärke von passiven optischen Sensoren liegt eindeutig in der Möglichkeit, mehrere Bänder im elektromagnetischen Spektrum erfassen zu können. Während das Laserscanning nur eine Wellenlänge verwendet, decken Kamerasysteme einen großen spektralen Bereich ab. Hyperspektrale Sensoren können Strahlungsintensitäten sogar in hunderten eng benachbarten Kanälen vom sichtbaren Licht bis in den mittleren Infrarotbereich aufnehmen. Somit stehen detaillierte Informationen zur präzisen Ableitung verschiedener biophysikalischer und struktureller Oberflächeneigenschaften zur Verfügung [Blackburn, 2007]. Die Eignung dieser Sensoren für die Unterscheidung von Baumarten wird z.B. von Clark et al. [2005] nachgewiesen. In dieser Studie gelingt die Klassifikation von sieben Baumarten im tropischen Regenwald von Costa Rica unter Verwendung des „Hyperspectral Digital Imagery Collection Experiment (HYDICE)“ Sensors mit einer Klassifikationsrate von 92 %. Dieser Zeilenscanner arbeitet nach dem Pushbroom-Prinzip und erfasst 210 Kanäle im Bereich von 400 – 2500 nm des elektromagnetischen Spektrums.

1.3.3 Laserscanning

Das luftgestützte Laserscanning (ALS) hat sich in den letzten 15 Jahren als effizientes Verfahren zur großflächigen Erfassung von Höheninformationen entwickelt und schnell ein breites Anwendungsspektrum erreicht. Insbesondere im Waldbereich hebt sich diese Technik von anderen Fernerkundungsmethoden ab, weil die Waldstruktur an Lücken von den Laserstrahlen durchdrungen werden kann und somit die Waldstruktur von der Oberfläche bis zum Boden erfasst wird. Durch die rasante Entwicklung von elektronischen Bauteilen konnte die Leistungsfähigkeit der Systeme insbesondere im Bereich der Pulsrate und der Messgeschwindigkeit deutlich gesteigert werden. Die neuartige „Multiple Pulses in Air (MPiA)“ Technologie erlaubt sogar das Aussenden eines neuen Laserpulses bevor das reflektierte Signal des vorherigen Pulses empfangen wurde [Roth & Thompson, 2008]. Neben der Pulsratensteigerung stellt die vollständige Aufzeichnung des reflektierten Laserimpulses einen wichtigen Fortschritt gegenüber der konventionellen Methode dar. Bei den herkömmlichen Systemen werden meistens nur die Zeitwerte der ersten und letzten Reflexion (=First/Last-Pulse) des Laserstrahls registriert (Abbildung 1.3a), höchstens aber bis zu fünf Reflexionen. Neben der begrenzten Anzahl der erfassbaren 3D Punkte fehlt dem Nutzer in der Regel die Kenntnis über die Art der Pulsdetektion [Stilla & Jutzi, 2008], die einen erheblichen Einfluss auf die Genauigkeit der Messungen hat [Wagner et al., 2004]. Rückschlüsse

auf die Reflexionseigenschaften der erfassten Objekte sind daher kaum möglich. Im Gegensatz zu diesen diskret arbeitenden Systemen ermöglicht die neue Technologie eine detaillierte Analyse des vom Empfänger aufgezeichneten Signals, das typischerweise „Echoprofil“ oder „Waveform“ genannt wird (Abbildung 1.3b). Die im Echoprofil digitalisierte Empfängerenergie ist ein Maß für die vertikale Ver-

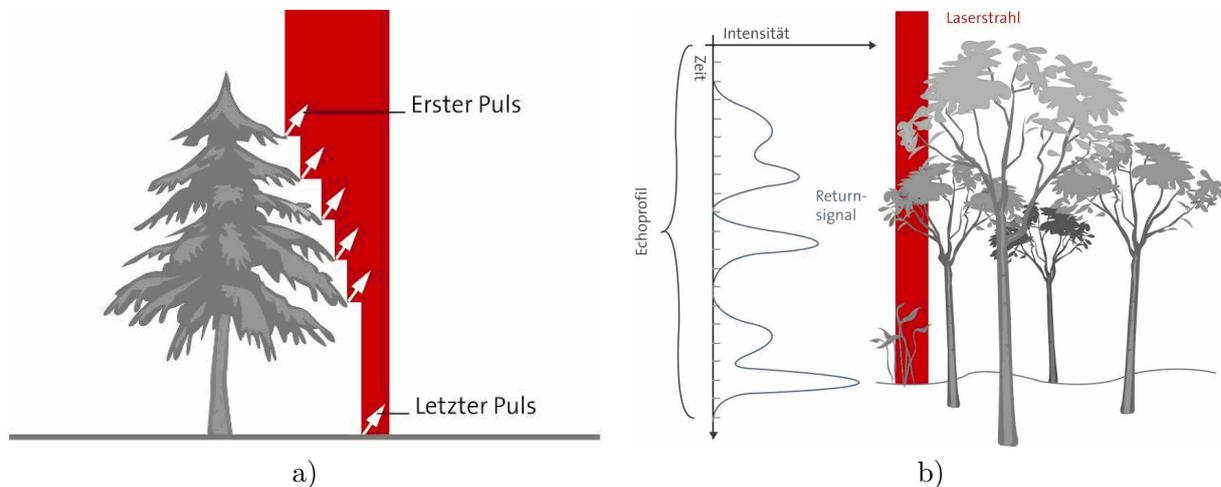


Abbildung 1.3: Erfassung von Bäumen mit Hilfe von ALS. a) mit einem First/Last-Pulse System, b) mit einem Full Waveform System

teilung der beleuchteten Oberflächen, die den Laserstrahl in Abhängigkeit der Reflektivität bezüglich der Wellenlänge zurückwerfen. Vor allem im Vegetationsbereich zeigt die Auswertung der Echoprofile deutliche Vorteile gegenüber den konventionellen Daten. Im Wald lassen sich bei einer dichten Abtastung Rückschlüsse über die räumliche Verteilung und Charakterisierung der Waldstruktur unter der geschlossenen Oberfläche ziehen.

Die ersten Full Waveform Systeme wurden in den 1980er Jahren für bathymetrische Anwendungen entworfen [Guenther & Mesick, 1988]. Diese Systeme nutzen zwei Laserstrahlen mit unterschiedlicher Wellenlängen zur Bestimmung der Wassertiefe, wobei der infrarote Strahl (1064 nm) bereits an der Wasseroberfläche reflektiert und der blau-grüne Strahl (532 nm) bis zum Gewässerboden vordringt. Als Beispiel für ein bathymetrisches System kann das „Scanning Hydrographic Operational Airborne Lidar Survey (SHOALS)“ System genannt werden, das Gewässer bis zu einer Tiefe von 60 m durchdringt [Irish & Lillycrop, 1999].

Die Entwicklung der ersten experimentellen Full Waveform Systeme für topographische Anwendungen begann in den 1990er Jahren. Beispiele hierfür sind die luftgestützten Systeme „Scanning LiDAR Imager of Canopies by Echo Recovery (SLICER)“ [Blair et al., 1994] und „Laser Vegetation Imaging Sensor (LVIS)“ [Blair et al., 1999], die wegen ihres Footprints von mehreren Metern als „large footprint“ Lasersysteme bezeichnet werden. Auch der satellitengetragene Sensor „Geoscience Laser Altimeter System (GLAS)“ gehört zu dieser Kategorie. Wegen der geringen räumlichen Auflösung ist eine Inventur auf Einzelbaumebene mit diesen Systemen nicht möglich. Insbesondere im geneigten Gelände sind Vegetations- und Bodenreflexionen nur schwer voneinander zu trennen. Lefsky et al. [1999] und Means et al. [1999] zeigen jedoch, dass eine bestandesweise Ableitung von Baumparametern, wie der mittleren Höhe, der Grundfläche und der Biomasse, aus SLICER-Daten erfolgreich ist.

Seit 2004 stehen Full Waveform Systeme mit kleinen Footprints für den kommerziellen Einsatz zur Verfügung und lösen die diskret arbeitenden First/Last-Pulse Systeme schrittweise ab. Der Riegl LMS-

Q560 Scanner zum Beispiel kann die empfangenen Echoprofile in voller Länge aufzeichnen und verfügt über eine radiometrische Auflösung von 16 Bit und eine zeitliche Auflösung von 1 ns. Zusätzlich wird das ausgesendete Signal aufgezeichnet, um eine präzise Auswertung der Daten zu ermöglichen. Dieser Scanner ist Bestandteil der Systeme LiteMapper-5600 [Hug et al., 2004] von IGI und Harrier 56 von TopoSys. Beim Scanner TopEye MK II war bei der ersten Version die Aufzeichnung der Waveforms auf einen Bereich von 19 m beschränkt, was jedoch auf das aktuelle Gerät nicht mehr zutrifft. Auch die „Airborne Laser Terrain Mapper (ALTM)“ Systeme von Optech können sowohl das ausgesendete als auch das empfangene Signal aufzeichnen [Gutierrez et al., 2005], allerdings beträgt hier die radiometrische Auflösung nur 8 Bit. Details über die technischen Spezifikationen der bekanntesten Full Waveform Systeme sind bei Jutzi & Stilla [2006a] und Mallet & Bretar [2009] zusammengefasst.

Bei der Verwendung von Echoprofilen zur automatischen Waldinventur gibt es zwei grundsätzlich verschiedene Vorgehensweisen:

- Die erste Strategie nutzt direkt die Rohdaten entweder als einzelne Waveforms oder als summierte Waveforms in einem vorgegebenen Raumbereich (z.B. Einzelbaum). Über ein Strahlungstransfermodell (engl. Radiative Transfer Model (RTM)) wird der Zusammenhang zwischen den Vegetationseigenschaften und den Waveforms hergestellt, wobei alle Einflüsse auf den Messvorgang (z.B. Sensoreigenschaften, Absorption und Rückstreuung in der Vegetation) explizit beschrieben werden müssen. Für die Ableitung der gesuchten Waldparameter aus den erfassten Daten ist eine Inversion des RTM erforderlich. Wegen der Vielzahl von Parametern, die zur Beschreibung des komplexen Systems notwendig sind, ist diese Inversion im Allgemeinen unterbestimmt, so dass bestimmte Annahmen und Vereinfachungen notwendig sind. Zum Beispiel invertieren Koetz et al. [2006] das Modell von Sun & Ranson [2000] mit Hilfe von Lookup-Tabellen und leiten Parameter, wie die maximale Baumhöhe und den Blattflächenindex, auf Bestandesebene ab. Auch Morsdorf et al. [2008] beschäftigen sich mit dieser Thematik und modellieren Waveforms auf Einzelbaumebene sogar für Laserstrahlen mit unterschiedlicher Wellenlänge.
- Die zweite Strategie zur Auswertung von Waveforms liegt in deren Zerlegung in die einzelnen Reflexionsanteile. Meistens werden dazu Gauß-Funktionen entweder direkt an das empfangene Signal [Hofton et al., 2000; Jutzi & Stilla, 2005; Persson et al., 2005; Söderman et al., 2005; Wagner et al., 2006] oder an die Oberflächenantwort angepasst, die man durch eine Entfaltung (Deconvolution) mit dem gesendeten Signal erhält [Jutzi & Stilla, 2006b]. Somit bekommt man neben den 3D Positionen der einzelnen Reflexionen auch die Pulsamplitude und die Pulsbreite der empfangenen Impulse als zusätzliche Merkmale. Diese charakterisieren die Zielobjekte bezüglich ihrer Geometrie und Reflektivität und können bei der Segmentierung und Klassifikation von Bäumen genutzt werden. Gegenüber diskret arbeitenden Systemen erhöht sich die räumliche Punktdichte, weil die Anzahl von detektierbaren Punkten pro Laserschuss unbegrenzt ist. Außerdem können überlappende Reflexionen noch voneinander getrennt werden, was zu einer verbesserten Auflösung benachbarter Objekte führt und die Erkennung von Details möglich macht, wie z.B. die Verjüngung im Unterstand. Bei den konventionellen Systemen hingegen existiert nach einer registrierten Reflexion eine Totzeit von mindestens einer Pulslänge, in der keine neue Reflexion erfasst werden kann.

In den letzten Jahren konzentrierten sich die Forschungsaktivitäten auf dem Gebiet der automatischen Waldinventur insbesondere auf „small footprint“ ALS Systeme mit diskreter Echobestimmung. Neben den Methoden zur bestandesweisen Inventur [Naesset, 2004] wurden Verfahren zur Erkennung

und Charakterisierung von Einzelbäumen entwickelt, wobei hier meistens die lokalen Maxima im CHM zur Identifikation der einzelnen Bäume verwendet werden [Hyypä et al., 2001; Persson et al., 2002; Solberg et al., 2006]. Die Lage und Höhe der Bäume entsprechen dann den 3D Koordinaten der Maxima im CHM. Zur Segmentierung der Baumkronen werden Methoden der digitalen Bildverarbeitung genutzt, welche die Täler im CHM als Segmentgrenzen bestimmen. Die größte Herausforderung bei diesen Verfahren ist eine geeignete Glättung des CHM, so dass pro Baum genau ein Maximum existiert. Bei zu geringer Glättung werden speziell bei Laubbäumen einzelne Kronenteile als eigene Bäume identifiziert, wohingegen eine zu starke Glättung mehrere Baumkronen zusammenfasst. Innerhalb der gewonnenen Segmentpolygone werden dann Baumparameter, wie die Fläche der Krone, deren Durchmesser, Höhe und Ansatz, berechnet, wobei sich hierfür die Nutzung der originalen Laserpunkte als vorteilhaft erweist [Pyysalo & Hyypä, 2002]. Der Erfolg dieser Verfahren, die nur das CHM als Datengrundlage für die Segmentierung verwenden, hängt stark vom jeweiligen Waldtyp ab. Solberg et al. [2006] erreichen in einem borealen, heterogenen Fichtenbestand eine Erkennungsrate von 66 %. Persson et al. [2002] können in einem borealen, von Fichten und Kiefern dominierten Wald 71 % aller Bäume richtig erkennen und 91 % des Holzvolumens mit einem RMSE von 22 % schätzen. Heurich [2006] hingegen erreicht mit dem Verfahren von Persson et al. [2002] im strukturreichen Bayerischen Wald nur eine Erkennungsrate von 45 %, die sich aus 51 % für Nadelbäume und 40 % für Laubbäume zusammensetzt. Das Holzvolumen kann dort zu 85 % mit einem RMSE von 31 % bestimmt werden.

Der Nachteil dieser Methoden ist, dass sie nur auf dem CHM basieren und lediglich Bäume mit einem eigenen lokalen Maximum erkannt werden können. Die notwendige Glättung des CHM trägt dazu bei, dass mehrere eng beieinander stehende Bäume häufig nur durch ein gemeinsames Maximum repräsentiert und somit in der Segmentierung zusammengefasst werden. Kleinere Bäume unterhalb der Waldoberfläche sind nicht im CHM enthalten und können deshalb nicht gefunden werden. Insbesondere in heterogenen Wäldern mit Verjüngungen ist die Erkennungsrate dieser Methoden dadurch eingeschränkt. Zur Kompensation dieser Beschränkung wurden Verfahren entwickelt, die den Anteil der nicht erkannten Bäume schätzen. Zum Beispiel verwenden Maltamo et al. [2004] theoretische Verteilungsfunktionen zur Vorhersage von verdeckten Bäumen im unteren Waldbereich. Mehtätalo [2006] entwickelt eine Funktion, welche die Erkennungswahrscheinlichkeit in Abhängigkeit vom Kronenradius beschreibt. Für den Erfolg dieser Ansätze sind jedoch geeignete Kalibrierungen mit Felddaten bzw. zutreffende Annahmen für den jeweiligen Waldtyp notwendig.

Segmentierungsansätzen, welche direkt an den 3D Laserpunkten ansetzen, wurde bis jetzt wenig Beachtung geschenkt, obwohl darin ein erhebliches Verbesserungspotenzial liegt. Der Hauptgrund dafür ist, dass die bis jetzt überwiegend eingesetzten First/Last-Pulse Systeme eine für solche Verfahren ungünstige Punktverteilung liefern. Ein erster Ansatz in diese Richtung stammt von Morsdorf et al. [2003], die den K-Means Algorithmus zur Segmentierung der Bäume im 3D Voxelraum nutzen. Sie erhalten dadurch „echte“ 3D Segmente, d.h. eine Überlappung benachbarter Segmente ist möglich. Eine Steigerung der Erkennungsrate gegenüber den CHM basierten Verfahren erfolgt jedoch nicht, weil das Verfahren auf die lokalen Maxima im CHM als Saatpunkte angewiesen ist. Der Ansatz von Wang et al. [2008] geht einen Schritt weiter. Hier wird die Voxelstruktur in einzelne Schichten zerlegt, in denen 2D Kronenregionen mit morphologischen Methoden segmentiert werden. Anschließend erfolgt eine 3D Rekonstruktion durch eine hierarchische Kombination dieser Regionen. Der Vorteil besteht darin, dass auch Bäume ohne ein lokales Maximum im CHM gefunden werden, jedoch müssen die Baumspitzen in einer der Schichten korrekt detektiert werden können.

Ansätze zur Baumsegmentierung, die ohne den Umweg über die 2D Schichten und ohne vorgegebe-

ne Saatpunkte direkt im 3D Raum arbeiten, sind aus der Literatur bis jetzt nicht bekannt. Gegenstand dieser Arbeit ist deshalb die Entwicklung eines Verfahrens zur 3D Segmentierung von Bäumen, das möglichst alle erfassten Reflexionen nutzen kann und keine Reduzierung auf den 2D Raum verlangt. Die Anzahl der Segmente muss dabei dynamisch bestimmt werden, so dass keine Initialisierung notwendig ist. Nur dann ist es möglich, neben den dominanten Bäumen der oberen Waldschicht auch die dominierten Bäume im Unterstand zu erkennen und auch komplexe Waldstrukturen erfolgreich zu segmentieren.

Neben der Segmentierung ist die korrekte Bestimmung der Baumart maßgebend für den Erfolg der Inventur auf Einzelbaumbene, weil diese Information bei der Ableitung von Parameter, wie dem Holzvolumen, benötigt wird. Wie im Abschnitt 1.3.2 beschrieben, eignen sich zwar passive optische Sensoren wegen der Abdeckung eines großen spektralen Bereichs gut für diese Aufgabe, können aber auf Grund der fehlenden Durchdringbarkeit nur die an der Waldoberfläche sichtbaren Bäume charakterisieren. Beim Laserscanning hingegen ist diese Einschränkung nicht vorhanden, so dass auch Laserdaten für die Baumartenklassifikation attraktiv sind. Bisherige Untersuchungen auf diesem Gebiet nutzen dazu First/Last-Pulse Daten mit hoher Punktdichte. Holmgren & Persson [2004] können damit die Baumarten Fichte und Kiefer mit einer Klassifikationsrate von 95 % unterscheiden. Heurich [2006] erreicht bei der Trennung von Fichte und Buche mit Daten einer Winterbefliegung sogar eine Klassifikationsrate von 97 %, wobei jedoch für die Segmentierung die Daten einer Sommerbefliegung notwendig sind. Werden die Sommerdaten für die Baumartenklassifikation verwendet, beträgt die Klassifikationsrate lediglich 81 %. Brandtberg [2007] kann die drei Laubbaumarten Eiche (*Quercus spp.*), Rot-Ahorn (*Acer rubrum*) und Tulpenbaum (*Liriodendron tuliperifera*) im unbelaubten Zustand mit einer Klassifikationsrate von 64 % unterscheiden, was auf die Schwierigkeit bei der Identifikation einzelner Laubbaumarten hindeutet. Die genannten Studien haben die Gemeinsamkeit, dass die verwendeten Merkmale überwiegend aus den Koordinaten der Laserpunkte abgeleitet sind. Holmgren & Persson [2004] und Brandtberg [2007] nutzen zusätzlich die vom Lasersystem erfassten Intensitätswerte, obwohl diese bei diskret arbeitenden Systemen meist den unkalibrierten Amplitudenwerten entsprechen und somit nur bedingt einsetzbar sind. Eine nachträgliche Kalibrierung ist häufig nicht möglich, weil die dazu notwendigen Informationen fehlen. Man erwartet jedoch, dass die Intensität mit dem Einsatz von Full Waveform Systemen an Bedeutung gewinnt, weil den Nutzern jetzt sämtliche Daten für die Berechnung und Kalibrierung der Intensität zur Verfügung stehen. Die dafür notwendigen Arbeitsschritte sind unter anderem Gegenstand der vorliegenden Arbeit.

Maltamo et al. [2007] sehen in der Einzelbaumerkennung auf der Basis von ALS Daten ein enormes Potenzial. Sie betonen aber auch, dass für einen operationellen Einsatz noch Verbesserungen bei der Segmentierung, Klassifikation und Bestimmung von Baumparametern notwendig sind. Eine automatisierte Methode soll gegenüber der konventionellen Durchführung der Waldinventur nicht nur Kostenvorteile haben, sondern auch erheblich genauere Ergebnisse liefern. Die neue Full Waveform Aufzeichnung stellt eine entscheidende Triebfeder dar, diese Methoden auf ein neues Leistungsniveau zu bringen und dadurch die geforderten Verbesserungen zu erreichen. Die überwiegend für First/Last-Pulse Daten konzipierten Verfahren müssen an die neue Datengrundlage angepasst werden, um die Vorteile dieser Daten überhaupt nutzen zu können. Denn was bringt die hohe Anzahl erfasster Reflexionen bei den Full Waveform Systemen, wenn der Großteil dieser Daten bei der Berechnung des CHM wieder verworfen wird? Ebenso finden die Zusatzinformationen aus den Waveforms, wie die Intensität oder Pulsbreite der Reflexionen, bei den jetzigen Methoden kaum Eingang.

1.4 Ziele der Arbeit

Zusammenfassend werden in dieser Arbeit folgende Ziele verfolgt:

- Es ist eine Methode zu entwickeln, die eine möglichst vollständige und robuste Zerlegung der Echoprofile in die einzelnen Reflexionsanteile erlaubt. Hierbei sollen mögliche Nachschwinger erkannt und eliminiert werden und die Ergebnisse einer internen Qualitätskontrolle unterzogen werden. Die Eignung des Verfahrens ist anhand der Daten unterschiedlicher ALS-Systeme zu überprüfen.
- Es ist zu untersuchen, welche Unterschiede zwischen der konventionellen First/Last-Pulse Technik und der neuen Full Waveform Technik bezüglich der Anzahl, Verteilung und Trennbarkeit der erfassten Reflexionen zu beobachten sind. Hierzu soll ein Vergleich zwischen Punkten aus der Waveform-Zerlegung und simultan erfassten First/Last-Pulse Punkten durchgeführt werden.
- Für den erfolgreichen Einsatz der Merkmale Intensität und Pulsbreite ist eine vorhergehende Kalibrierung notwendig. Es ist deshalb eine geeignete Methode auszuwählen und anzupassen, um eine Korrektur bezüglich der Variationen der ausgesendeten Signalintensität und der Laufzeit des Laserpulses zu erreichen.
- Zum Nachweis, dass die Merkmale Intensität und Pulsbreite für die Unterscheidung von Waldstrukturen charakteristisch sind, ist eine Analyse für Reflexionen an verschiedenen Objekten im Wald, wie Boden, Baumstamm, Baumkrone, Laub- und Nadelbaum, durchzuführen.
- Zur präzisen Ableitung von Baumparametern auf Einzelbaumebene ist eine möglichst vollständige und korrekte Segmentierung von Einzelbäumen notwendig. Bisherige Verfahren basieren lediglich auf dem Baumhöhenmodell (CHM), so dass nur die dominanten, im CHM enthaltenen Bäume identifiziert werden können. In dieser Arbeit ist deshalb ein Segmentierungsverfahren zu entwickeln, das diese Einschränkung auf das CHM überwindet und direkt an den 3D Laserpunkten ansetzt, um alle Reflexionen eines gesendeten Pulses zu nutzen. Ein Baumsegment enthält dann im Idealfall genau die Laserpunkte, die von diesem Baum stammen. Unter Verwendung von manuell erfassten Referenzdaten ist zu überprüfen, bis zu welchem Grad dadurch auch kleinere Bäume im Unterstand erkannt werden können.
- Im Rahmen der Segmentierung ist zu überprüfen, ob Baumstämme in den Laserdaten identifiziert werden können. Gefundene Stämme könnten zu sehr genauen Baumpositionen führen und die Segmentierung unterstützen.
- Die Bestimmung der Baumart stellt einen wichtigen Schritt beim Einzelbaumansatz dar, weil diese Information für die Ableitung weiterer Baumparameter, wie das Holzvolumen, benötigt wird. Während Baumartenklassifikationen mit konventionellen First/Last-Pulse Daten überwiegend auf den Koordinaten der Reflexionen beruhen, ist in dieser Arbeit ein Verfahren zu entwickeln, in dem zusätzliche Merkmale aus den Echoprofilen zum Einsatz kommen. Die Auswirkungen auf das Klassifikationsergebnis sind mit Hilfe von Referenzdaten zu überprüfen. Außerdem ist zu untersuchen, ob neben der Trennung von Laub- und Nadelbäumen eine noch detailliertere Unterscheidung von Baumarten möglich ist.

1.5 Aufbau der Arbeit

Der Inhalt dieser Arbeit ist in neun Kapitel gegliedert. Im Kapitel 2 werden zunächst die grundlegenden Einflüsse auf den Messvorgang beim Full Waveform Laserscanning erläutert und Möglichkeiten zur Auswertung der aufgezeichneten Signale aufgezeigt. Anschließend folgt eine detaillierte Beschreibung der in dieser Arbeit eingesetzten Methode zur Anpassung von Gauß-Funktionen unter Verwendung des Levenberg-Marquardt Algorithmus. Aus den geschätzten Parametern dieser Funktionen können dann die 3D Positionen der Reflexionen abgeleitet und die Attribute Intensität und Pulsbreite berechnet werden. Für die notwendige Kalibrierung dieser Attribute werden sowohl modell- als auch datengetriebene Ansätze beschrieben, wobei auf die Problematik bei der Bestimmung der Reflektivität bei unbekannter Ausdehnung des Zielobjekts eingegangen wird.

Im Kapitel 3 wird ein dreistufiges Verfahren zur Segmentierung von Einzelbäumen vorgestellt, das die im Kapitel 2 abgeleiteten 3D Positionen und Attribute der Reflexionen nutzt. Bei der ersten Stufe handelt es sich um eine Watershed Segmentierung im CHM, wobei auf die notwendige Filterung und Interpolation zur Ableitung des CHM eingegangen wird. In der zweiten Stufe werden die Laserdaten nach Baumstämmen durchsucht, wofür eine Filterung der Stammpunkte und ein hierarchisches Clustering bezüglich der horizontalen Abstände dieser Punkte erforderlich sind. Vor der endgültigen Stammrekonstruktion erfolgt eine Überprüfung der Cluster anhand bestimmter Kriterien. In der dritten Stufe wird eine echte 3D Segmentierung auf der Basis des Normalized Cut Verfahrens entwickelt, das gegenüber existierenden Ansätzen methodische Vorteile aufweist und die Ergebnisse der ersten beiden Stufen optional nutzen kann. Dazu werden die Grundlagen des aus der digitalen Bildverarbeitung stammenden Normalized Cut Verfahrens erläutert und die notwendigen Anpassungen an den 3D Fall beschrieben. Entscheidend ist eine geeignete Berechnung von Ähnlichkeitswerten, die für Voxel innerhalb eines Baums zu großen Werten, und für Voxel von verschiedenen Bäumen zu kleinen Werten führt. Ein hierarchisches Ablaufschema steuert die iterative Anwendung des Verfahrens.

Um den einzelnen Segmenten die korrekte Baumart zuzuordnen zu können, wird im Kapitel 4 ein Verfahren zur Baumartenklassifikation vorgestellt. Hierbei ist die Extraktion geeigneter Merkmale aus den Laserdaten notwendig. Die vorgestellten Merkmale nutzen sowohl die Koordinaten der Laserpunkte als auch die Attribute Intensität, Pulsbreite und die Anzahl von Reflexionen pro Waveform. Zur Durchführung der Klassifikation werden beispielhaft die unüberwachten Methoden „K-Means“ und „Expectation-Maximization“ und die überwachte Methode „Maximum-Likelihood“ erläutert.

Im Kapitel 5 werden die zur Evaluierung der beschriebenen Methoden verwendeten Daten eingeführt. Dazu sind die Charakteristiken der verschiedenen ALS Datensätze und der eingesetzten Erfassungssysteme zusammengefasst. Außerdem wird die Beschaffenheit der Befliegungsgebiete und der dort vorhandenen Referenzdaten zur Überprüfung der Segmentierungs- und Klassifikationsergebnisse dargestellt.

Das Kapitel 6 umfasst sämtliche Experimente, die mit den Verfahren der Kapitel 2, 3 und 4 durchgeführt werden. Zu Beginn wird überprüft, ob die Signale der beiden eingesetzten Full Waveform Scanner von TopEye und Riegel gaußförmig sind und somit die anschließende Waveform-Zerlegung mit Hilfe von Gauß-Funktionen geeignet ist. Anhand von Beispielen werden die Vorteile dieser Auswertung gegenüber der diskreten Aufzeichnung von Punkten im Lasersystem aufgezeigt. Die Attribute Intensität und Pulsbreite werden mit Hilfe von Daten aus unterschiedlicher Flughöhe kalibriert und deren Werte für verschiedene Objektklassen im Waldbereich analysiert. Anschließend folgt eine Segmentierung von Einzelbäumen für alle Datensätze, eine Beschreibung der jeweils verwendeten Kontrollparameter und

ein Vergleich der Ergebnisse für die verschiedenen Verfahren. Die unterschiedlichen Daten erlauben außerdem eine Analyse bezüglich der Belaubung, der Punktdichte und des Erfassungssystems. Im nächsten Schritt werden die Segmente in Laub- und Nadelbäume klassifiziert und die Wirksamkeit der verwendeten Merkmale verglichen, wobei insbesondere die Nutzbarkeit der zusätzlichen Informationen aus den Waveforms von Interesse ist. Zusätzlich wird getestet, ob eine weitergehende Klassifikation in einzelne Laub- und Nadelbaumarten erfolgreich ist.

Die Arbeit schließt mit einer detaillierten Diskussion der Ergebnisse im Kapitel 7 und einer Zusammenfassung mit dem Ausblick auf zukünftige Forschungsthemen im Kapitel 8.

Kapitel 2

Full Waveform Laserscanning

2.1 Grundlagen

Beim Laserscanning wird das empfangene Signal von verschiedenen Faktoren beeinflusst:

- Eine grundlegende Bedeutung haben die Energie und der zeitliche Verlauf des ausgesendeten Signals. Da diese Charakteristiken von der Generierung des Laserpulses durch die Laserquelle abhängen, kann das Sendesignal für verschiedene Lasersysteme unterschiedlich sein. Häufig ist eine gute Approximation des Signalverlaufs mit bekannten Funktionen, wie der Gauß-, Exponential- oder Rechteckfunktion möglich. Es können jedoch auch erhebliche Abweichungen von diesen Modellen auftreten [Jutzi & Stilla, 2006b].
- Die Beschaffenheit eines oder mehrerer Zielobjekte im Strahlengang beeinflusst die Stärke und Form des reflektierten Signals. Hierbei spielen Eigenschaften wie der Reflexionsgrad, die Rauigkeit, die Form, die Größenausdehnung und die Neigung gegenüber dem einfallenden Strahl eine Rolle.
- Der Laserstrahl wird beim zweimaligen Durchlaufen der Atmosphäre durch Absorptions- und Streuvorgänge gedämpft.
- Sowohl beim Empfang als auch beim Aussenden des Signals treten Energieverluste im Gerät auf. Zudem führen die optischen Linsen des Systems zu Beugungserscheinungen der elektromagnetischen Strahlung.

Während bei diskret arbeitenden Laserscannern die Bestimmung der Entfernung zum Zielobjekt im Vordergrund steht, lässt die Kenntnis des gesamten Signalverlaufs beim Full Waveform Laserscanning weitergehende Rückschlüsse auf die erfassten Objekte zu. Dazu ist eine Modellierung der verschiedenen Einflussfaktoren auf den Messvorgang notwendig.

Nach Jelalian [1992] unterscheidet sich Laserscanning vom Mikrowellenradar lediglich durch die kürzere Wellenlänge, so dass die Radar Entfernungsgleichung anwendbar ist. Betrachtet man die empfangene Pulsenergie P_E , die durch Reflexion an einem Zielobjekt entsteht, so lautet eine dem Laserscanning angepasste Formulierung der Radargleichung [Wagner et al., 2004]:

$$P_E = \frac{P_S D_E^2}{4\pi R^4 \beta_S^2} \eta_{\text{sys}} \eta_{\text{atm}} \Gamma \quad (2.1)$$

Hierbei ist P_E eine Funktion der ausgesendeten Pulsenergie P_S , des Durchmessers der Empfängerpertur D_E , der Entfernung R vom Sensor zum Ziel, des Öffnungswinkels β_S des Laserstrahls, der

Transmissionsfaktoren des Systems η_{sys} und der Atmosphäre η_{atm} und des so genannten Streuquerschnitts Γ (siehe Abbildung 2.1). Nach Jelalian [1992] ist Γ die effektive Fläche der Kollision des

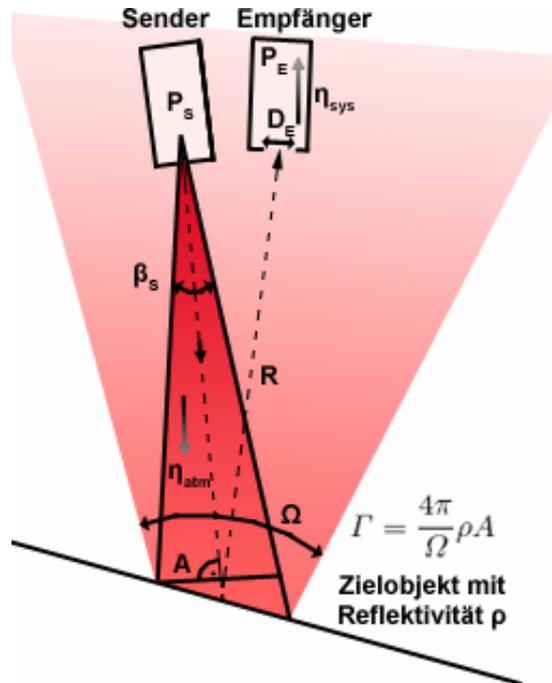


Abbildung 2.1: Geometrie und Messgrößen in der Radargleichung.

Laserstrahl mit dem Zielobjekt, wobei die Richtung und Stärke der Reflexion berücksichtigt werden. In der Größe Γ sind die Objekteigenschaften folgendermaßen zusammengefasst:

$$\Gamma = \frac{4\pi}{\Omega} \rho A \quad (2.2)$$

Dabei ist Ω der Raumwinkel, in den die Strahlung reflektiert wird. Dieser ist bei einer spiegelnden Oberfläche sehr klein und wächst mit zunehmender Rauigkeit bis zu einem Wert von 2π bei einer idealen diffusen Reflexion in alle Richtungen der Halbkugel über der Fläche. Da die meisten Oberflächen relativ zur Wellenlänge des Lasers rau sind, ist überwiegend von einer diffusen Reflexion auszugehen. Um ein reflektiertes Signal überhaupt empfangen zu können, muss der Empfänger des Laserscanners innerhalb von Ω liegen. Die Reflektivität ρ ist das Verhältnis von reflektierter zu einfallender Energie in der Wellenlänge des Lasers. Die Zielfläche A ist die effektiv vom Laserstrahl beleuchtete Fläche, d.h. die orthogonal zum Laserstrahl projizierte Fläche des rückstrahlenden Objekts.

Neben der Pulsenergie des empfangenen Signals muss auch die Pulsform betrachtet werden. Aus der Sicht der Signalverarbeitung entsteht das reflektierte Signal aus einer Faltung des ausgesendeten Signals mit dem differentiellen Streuquerschnitt $d\Gamma = \Gamma(R)dR$, welcher als Streuquerschnitt pro Entfernungintervall dR definiert werden kann [Wagner et al., 2006]. Anstelle von $d\Gamma$ ist auch die Bezeichnung Oberflächenantwort $h(t)$ gebräuchlich. Es ist somit möglich, in einer Entfaltung eine von der Form des gesendeten Signals unabhängige Beschreibung der Oberfläche zu berechnen. Jedoch können hierbei in Abhängigkeit von der Stärke des Rauschens, das sowohl im gesendeten als auch im empfangenen Signal enthalten ist, große numerische Fehler auftreten. Von Jutzi & Stilla [2006b] wurde deswegen eine Filtermethode entworfen, in der automatisch ein Filter geschätzt wird, welcher das

Rauschen reduziert und das Nutzsignal (Oberflächenantwort) nur minimal beeinflusst. Damit können benachbarte Objekte sehr gut voneinander unterschieden werden, obwohl das ausgesendete Signal des eingesetzten experimentellen Lasersystems sehr stark variiert. Die Positionen der Objekte und deren Eigenschaften werden durch eine Anpassung von Gauß-Funktionen an die Oberflächenantwort bestimmt. Hierbei wird angenommen, dass die Streueigenschaft der einzelnen kleinen Streuer, deren Einzelreflexionen zu einer Gesamtreflexion verschmelzen, durch eine Gauß-Funktion beschrieben werden kann.

Führt man keine Entfaltung durch, dann muss zusätzlich zur obigen Annahme ein gaußförmiger Sendepuls vorliegen [Wagner et al., 2006]. Die empfangene Waveform kann man dann direkt als Summe von Gauß-Funktionen modellieren. Dadurch ist es möglich, sowohl die Positionen der einzelnen Ziele eines Laserstrahls als auch deren Reflexionseigenschaften abzuleiten. Diese Annahme der gaußförmigen Sendepulse kann man leicht durch eine Analyse der Signale überprüfen. Die Annahme, dass die Streueigenschaften der Zielobjekte gaußförmig sind, trifft sicher nicht auf alle natürlichen und künstlichen Objekte zu. So führen Oberflächen mit einer asymmetrischen Verteilungsdichtefunktion oder gekrümmte Oberflächen zu einem asymmetrischen Verlauf des empfangenen Signals [Jutzi & Stilla, 2006b]. Vernachlässigt man jedoch diese Fälle, dann kann man die Gleichung (2.1) für jede der m Reflexionen einer Waveform folgendermaßen formulieren:

$$A_m \sigma_m = \frac{A_S \sigma_S D_E^2}{4\pi R_m^4 \beta_S^2} \eta_{\text{sys}} \eta_{\text{atm}} \Gamma_m \quad (2.3)$$

Hierbei ist A_m die Amplitude und σ_m die Standardabweichung der m -ten Gauß-Funktion der empfangenen Waveform. In gleicher Weise charakterisieren A_S und σ_S die an das gesendete Signal angepasste Gauß-Funktion. Als Beispiel ist in der Abbildung 2.2 die Anpassung von Gauß-Funktionen an eine gesendete und eine empfangene Waveform dargestellt, wobei der Laserstrahl einmal am Dach eines Hauses, einmal am Balkon und einmal am Boden reflektiert worden ist. In der Gleichung 2.3 steht

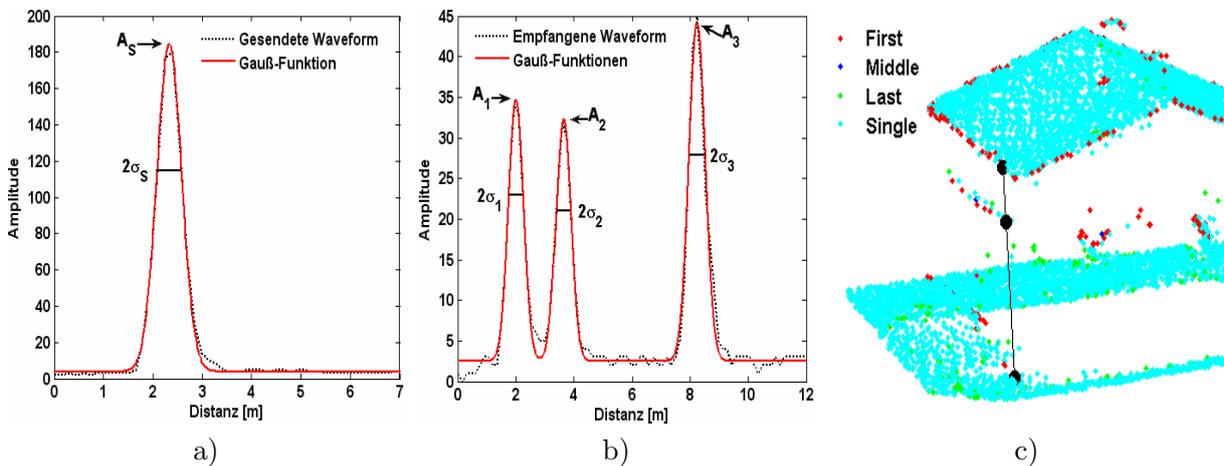


Abbildung 2.2: Anpassung von Gauß-Funktionen an die Waveforms einer Messung. a) die gesendete Waveform, b) die empfangene Waveform, c) die Positionen der drei Reflexionen als schwarze Punkte

der Streuquerschnitt Γ_m des m -ten Zielobjekts in direktem Zusammenhang mit den Parametern der m -ten Gauß-Funktion des empfangenen Signals, so dass Γ_m bei Kenntnis der übrigen Größen von (2.3) direkt berechnet werden kann.

2.2 Zerlegung der Waveforms

Bei der Auswertung der Waveforms kann man grundsätzlich auf dieselben Methoden zurückgreifen, die bei diskret arbeitenden Lasersystemen eingesetzt werden. Methoden wie „Peak-Detection“, „Leading-Edge-Detection“, „Constant-Fraction-Detection“ und „Center-of-Gravity-Detection“ sind bekannte Beispiele hierfür, deren Vor- und Nachteile z.B. von [Jutzi & Stilla \[2003\]](#) und [Wagner et al. \[2004\]](#) diskutiert werden. Wegen der Kenntnis des gesamten Signalverlaufs sind jedoch detailliertere Analysen möglich als bei den diskreten Systemen. Somit können die einzelnen Reflexionen vollständiger und genauer detektiert werden. Es ist sogar möglich, überlagerte Reflexionen zu trennen, so dass Objekte mit einem Abstand von weniger als der Länge eines Pulses noch aufgelöst werden können. Bei den diskret arbeitenden Systemen hingegen muss ein Echo vollständig abgeklungen sein, bevor ein neues detektiert werden kann. Bedingt durch Detektorphänomene und Reflexionen in den Leitungen und Verstärkern kann diese Abklingzeit Werte bis zur dreifachen Pulsdauer annehmen. Vor allem bei älteren Systemen mit breiten Pulsen existiert somit eine Totzeit von mehreren Metern.

Die genannten Methoden zur Pulsdetektion haben den Nachteil, dass sie zwar auf eine schnelle Bestimmung des Entfernungswerts ausgelegt sind, aber die Form des Signals kaum erfassen. Außerdem sind deren Ergebnisse stark vom ausgesendeten Signal abhängig. Zum Beispiel liefert die „Peak-Detection“ Methode bei einem Sendesignal mit mehreren lokalen Maxima keine brauchbaren Ergebnisse. Die Anpassung von Gauß-Funktionen an die Waveforms bietet den Vorteil, dass die Form der Reflexionen in den Parametern Amplitude und Pulsbreite abgebildet wird. Über die Gleichung 2.3 besteht eine direkte Beziehung zwischen diesen Parameter und den Reflexionseigenschaften der Zielobjekte. Somit stehen für diese Objekte neben der geometrischen Information zusätzliche Attribute zu deren Charakterisierung zur Verfügung. Weiterhin ist vorteilhaft, dass im Anpassungsprozess neben den absoluten Werten für die Parameter auch deren Genauigkeiten über eine Fehlerrechnung bestimmt werden können, um diese in der späteren Auswertung zu nutzen. Falls das ausgesendete Signal nicht gaußförmig ist, muss zunächst eine Entfaltung durchgeführt werden, um vom gesendeten Signal unabhängig zu werden [[Jutzi & Stilla, 2006b](#)]. Dann erst kann eine Anpassung von Gauß-Funktionen zur Beschreibung der Oberflächenantwort erfolgen.

Für die Zerlegung von Waveforms mit Hilfe von Gauß-Funktionen sind verschiedene Methoden bekannt. [Persson et al. \[2005\]](#) verwenden zum Beispiel das aus der Statistik bekannte „Expectation-Maximization (EM)“ Verfahren. Häufiger wird jedoch eine „Kleinste Quadrate“ Ausgleichung nach dem Gauß-Markov-Modell oder dem Levenberg-Marquardt (LM) Algorithmus eingesetzt [[Hofton et al., 2000](#); [Jutzi & Stilla, 2005](#); [Persson et al., 2005](#); [Söderman et al., 2005](#); [Wagner et al., 2006](#)]. Entscheidend für den Erfolg ist jeweils die geeignete Festlegung von Näherungswerten für die unbekannt Parameter. In den folgenden Abschnitten wird die in dieser Arbeit eingesetzte Methode zur Zerlegung der Waveforms mit Hilfe von Gauß-Funktionen detailliert beschrieben [[Reitberger et al., 2006a,b, 2008b](#)].

2.2.1 Waveforms als Summe von Gauß-Funktionen

Eine Waveform $w(t)$ wird also wie folgt als Summe von Gauß-Funktionen modelliert:

$$w(t) = b + \sum_{m=1}^{N_P} A_m \exp\left[-\frac{(t - t_m)^2}{2\sigma_m^2}\right] \quad (2.4)$$

Hierbei ist N_P die Anzahl der Reflexionen in der Wavform, A_m die m-te Amplitude, b ein Offset zur Beschreibung des Rauschpegels, t_m der Zeitpunkt der m-ten Reflexion und σ_m deren Halbbreite auf einer Höhe von $\frac{A_m}{\sqrt{e}}$, auch als Standardabweichung bezeichnet. Das Funktionsargument t steht für die Zeit an einer beliebigen Stelle im Strahlengang. In der Abbildung 2.3 ist eine Wavform mit fünf Reflexionen und die Überlagerung mit dem Modell dargestellt. Die Zeit t wurde mit Hilfe der Ausbreitungsgeschwindigkeit des Laserstrahls und unter Berücksichtigung des Hin- und Rückwegs in ein metrisches Maß umgerechnet, so dass auf der x-Achse direkt die Distanz zwischen den reflektierenden Objekten abgelesen werden kann. Für die zweite Gauß-Funktion sind die Parameter A , σ und t exemplarisch eingezeichnet.

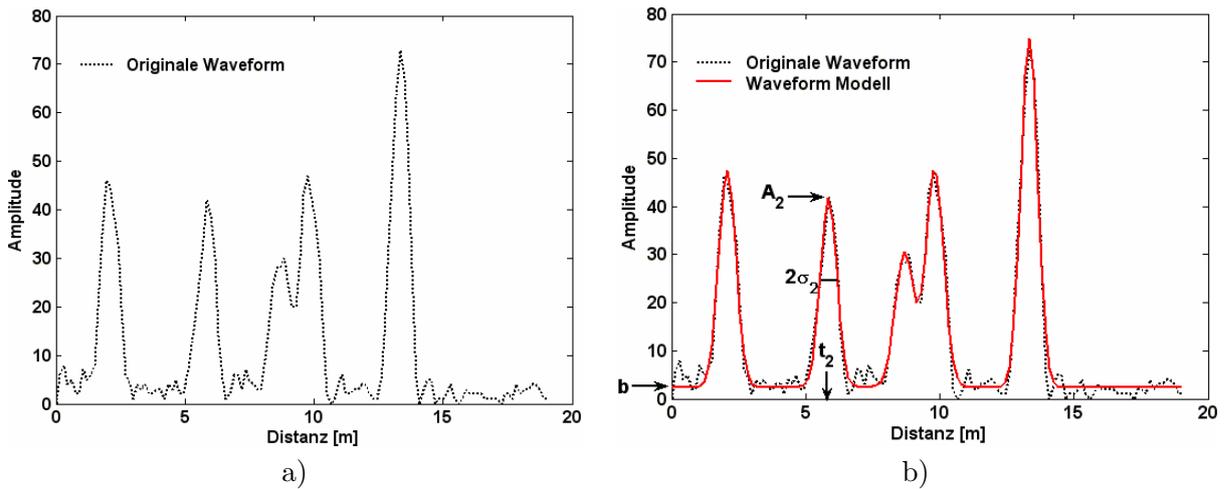


Abbildung 2.3: Modellierung einer Wavform mit fünf Reflexionen. a) Originale Wavform, b) Überlagerung mit dem Modell

2.2.2 Schätzung der Modellparameter

In der Gleichung 2.4 wird jede Messgröße $w(t)$ als Funktion der unbekannt Parameter $\mathbf{x}^T = (b, A_m, \sigma_m, t_m) (m = 1, \dots, N_P)$ dargestellt, so dass eine „Kleinste Quadrate“ Ausgleichung nach dem Gauß-Markov-Modell für die Bestimmung der Parameter geeignet ist [Niemeier, 2002]. Wenn man (2.4) als Beobachtungsgleichung einführt, muss das Normalgleichungssystem

$$(\mathbf{A}^T \mathbf{P} \mathbf{A}) \Delta \mathbf{x} = \mathbf{A}^T \mathbf{P} \mathbf{l} \quad (2.5)$$

gelöst werden. Die Jacobimatrix \mathbf{A} enthält dann die partiellen Ableitungen von 2.4 bezüglich der unbekannt Parameter \mathbf{x} an der Stelle der Näherungswerte $\hat{\mathbf{x}}$ und besteht aus n Zeilen und u Spalten, wobei n die Anzahl der Messwerte in der Wavform und $u = 1 + 3N_P$ die Anzahl der Unbekannt sind:

$$\mathbf{A} = \begin{bmatrix} \frac{\partial \hat{w}_1}{\partial b} & \frac{\partial \hat{w}_1}{\partial A_1} & \frac{\partial \hat{w}_1}{\partial \sigma_1} & \frac{\partial \hat{w}_1}{\partial t_1} & \cdots & \frac{\partial \hat{w}_1}{\partial A_{N_P}} & \frac{\partial \hat{w}_1}{\partial \sigma_{N_P}} & \frac{\partial \hat{w}_1}{\partial t_{N_P}} \\ \vdots & \vdots & \vdots & \vdots & & \vdots & \vdots & \vdots \\ \frac{\partial \hat{w}_n}{\partial b} & \frac{\partial \hat{w}_n}{\partial A_1} & \frac{\partial \hat{w}_n}{\partial \sigma_1} & \frac{\partial \hat{w}_n}{\partial t_1} & \cdots & \frac{\partial \hat{w}_n}{\partial A_{N_P}} & \frac{\partial \hat{w}_n}{\partial \sigma_{N_P}} & \frac{\partial \hat{w}_n}{\partial t_{N_P}} \end{bmatrix} \quad (2.6)$$

Die partiellen Ableitungen von 2.4 lauten folgendermaßen:

$$\begin{aligned} \frac{\partial w}{\partial b} &= 1; & \frac{\partial w}{\partial A_m} &= \exp\left[-\frac{(t-t_m)^2}{2\sigma_m^2}\right] \\ \frac{\partial w}{\partial \sigma} &= \frac{A_m(t-t_m)^2}{\sigma_m^3} \frac{\partial w}{\partial A_m}; & \frac{\partial w}{\partial t_m} &= \frac{A_m(t-t_m)}{\sigma_m^2} \frac{\partial w}{\partial A_m} \end{aligned} \quad (2.7)$$

Die Gewichtsmatrix \mathbf{P} erlaubt es, Unterschiede in den Genauigkeiten der Messwerte durch eine geeignete Wahl der Beobachtungsgewichte zu berücksichtigen. Da zur Vereinfachung angenommen wird, dass die einzelnen Abtastwerte einer Waveform unkorreliert und gleich genau sind, ist \mathbf{P} eine $n \times n$ Einheitsmatrix. Der Widerspruchsvektor \mathbf{l} enthält n Elemente und ist die Differenz zwischen den Beobachtungen $w(t)$ und den Funktionswerten $\hat{w}(t)$, die mit Hilfe der Näherungswerte $\hat{\mathbf{x}}$ berechnet werden. Der Vektor $\Delta\mathbf{x}$ enthält die Zuschläge zu den Näherungswerten $\hat{\mathbf{x}}$, so dass man daraus die Lösung für die Unbekannten $\mathbf{x} = \hat{\mathbf{x}} + \Delta\mathbf{x}$ berechnen kann. Zur Bestimmung von $\Delta\mathbf{x}$ aus der Gleichung 2.5 wird die Normalgleichungsmatrix $\mathbf{N} = \mathbf{A}^T \mathbf{P} \mathbf{A}$ invertiert. Wegen der Nichtlinearität von 2.4 bezüglich der unbekannt Parameter \mathbf{x} ist für die Lösung des Ausgleichsproblems eine iterative Vorgehensweise notwendig. Es werden dazu jeweils die Ergebnisse \mathbf{x} einer Iteration als Näherungswerte $\hat{\mathbf{x}}$ für die nächste Iteration verwendet. Der Prozess wird abgebrochen wenn sich die Unbekanntenzuschläge $\Delta\mathbf{x}$ nicht mehr ändern.

Das oben beschriebene Gauß-Newton Verfahren hat den Nachteil, dass die Anfangswerte $\hat{\mathbf{x}}$ schon nahe bei der endgültigen Lösung \mathbf{x} liegen müssen, um eine Konvergenz sicherzustellen. Eine leichte Abwandlung stellt der Levenberg-Marquardt Algorithmus [Levenberg, 1944; Marquardt, 1963] dar, der sich durch eine höhere Robustheit auszeichnet und auch bei schlechteren Anfangswerten meistens die optimale Lösung findet. Gerade bei sich stark überlappenden Reflexionen ist dies vorteilhaft. Des Weiteren beschleunigt dieses Verfahren die Konvergenz. Die Normalgleichungsmatrix \mathbf{N} in 2.5 wird dazu durch eine erweiterte Matrix \mathbf{N}' ersetzt, wobei gilt:

$$\mathbf{N}' = \mathbf{N} + \lambda \mathbf{diag}(\mathbf{N}) \quad (2.8)$$

Der Dämpfungsfaktor λ wird zu Beginn auf 10^{-3} gesetzt. Nach jeder Iteration wird geprüft, ob die Lösung zu einer Verkleinerung oder Vergrößerung des Betrags von \mathbf{l} geführt hat. Bei einer Verkleinerung konvergiert die Ausgleichung und λ wird dann um den Faktor 10 verkleinert. Im anderen Fall liegt eine Divergenz vor. Die Lösung wird dann mit den gleichen Näherungswerten wiederholt, wobei λ mit dem Faktor 10 multipliziert wird. Der Hintergrund für diese Skalierung der Diagonalelemente von \mathbf{N} ist, dass eine Vergrößerung von λ die Lösung mehr in die Richtung des absteigenden Gradienten der zu minimierenden Funktion lenkt. Der beschriebene Prozess wird wie beim Gauß-Newton Verfahren so lange durchgeführt, bis sich an den Unbekanntenzuschlägen $\Delta\mathbf{x}$ nichts mehr ändert.

Neben den Werten für die unbekannt Parameter werden im Zuge der Ausgleichung auch deren Genauigkeiten geschätzt. Dazu wird die Kovarianzmatrix \mathbf{K}_{xx} berechnet, deren Diagonalelemente die Varianzen der Unbekannten enthalten:

$$\mathbf{K}_{xx} = \sigma_0^2 \mathbf{N}^{-1} \quad (2.9)$$

Der Varianzfaktor σ_0^2 , der auch als mittlerer Gewichtseinheitsfehler bezeichnet wird und ein Gütemaß für die Approximation der Waveform $w(t)$ durch das geschätzte Modell ist, wird aus den Verbesserungen $\mathbf{v} = \mathbf{A} \Delta\mathbf{x} - \mathbf{l}$ berechnet:

$$\sigma_0^2 = \frac{\mathbf{v}^T \mathbf{P} \mathbf{v}}{n - u} \quad (2.10)$$

Im Folgenden wird erläutert, wie die für die Ausgleichung notwendigen Näherungswerte \hat{b} , \hat{A}_m , $\hat{\sigma}_m$, \hat{t}_m und die Anzahl N_P der Reflexionen bestimmt werden. Für den Rauschpegel \hat{b} ist entscheidend,

ob dieser Wert für die einzelnen Waveforms einer Befliegung variiert oder ob man eine Konstante verwenden kann. Eine Variation von \hat{b} tritt z.B. auf, wenn der Filter des Empfängers die Hintergrundstrahlung nicht vollständig abschirmt, so dass eine Abhängigkeit von der Sonnenstrahlung besteht. Zur Klärung dieser Frage sind Angaben vom Hersteller des jeweiligen Scanners hilfreich. Bei einem konstanten Rauschpegel kann \hat{b} anhand von ein paar Beispielen ermittelt und zur Auswertung der gesamten Befliegung verwendet werden. Variiert hingegen der Rauschpegel, muss \hat{b} individuell für jede Waveform festgelegt werden. Wie von Persson et al. [2005] vorgeschlagen, liefert der Median von $w(t)$ hierfür einen geeigneten Wert.

Zur Bestimmung von \hat{A}_m , \hat{t}_m und N_P wird $w(t)$ zuerst mit einem 1×3 Gauß-Filter geglättet. Dann werden die lokalen Maxima und die Terrassenpunkte gesucht und deren Amplituden und Positionen als \hat{A}_m und \hat{t}_m verwendet. Um sicherzustellen, dass diese Werte auf echten Reflexionen basieren, muss \hat{A}_m einen bestimmten Schwellwert $S_{\hat{A}_m}$ überschreiten. Im Falle eines konstanten Rauschpegels \hat{b} kann auch für $S_{\hat{A}_m}$ ein einmalig bestimmter und konstanter Wert verwendet werden. Bei einem variierenden \hat{b} jedoch muss $S_{\hat{A}_m}$ individuell für jede Waveform ermittelt werden. Hierzu eignet sich der sog. „Median Absolute Deviation (MAD)“ Wert, der ein Maß für die Streuung einer Verteilung um den Median ist [Rousseeuw & Leroy, 1987] und auch bei Persson et al. [2005] verwendet wird. Hierbei gilt:

$$MAD = \text{median}(|w(t) - \text{median}(w(t))|) \quad (2.11)$$

Durch Multiplikation des MAD mit 1.4826 erreicht man eine Konsistenz mit der Standardabweichung für asymptotische Normalverteilungen, so dass $S_{\hat{A}_m}$ wie folgt berechnet wird:

$$S_{\hat{A}_m} = \text{median}(w(t)) + 3 \times 1.4826 \times MAD \quad (2.12)$$

Als Wert für $\hat{\sigma}_m$ eignet sich die halbe Pulsbreite des ausgesendeten Signals. Falls dieses nicht aufgezeichnet wird, müssen stattdessen empfangene Signale verwendet werden, die das gesendete Signal möglichst gut widerspiegeln, d.h. Reflexionen von ausgedehnten ebenen Flächen mit möglichst geringem Einfallswinkel.

Vor der weiteren Verarbeitung der Ausgleichungsergebnisse wird eine interne Qualitätskontrolle mit Hilfe der Genauigkeiten aus der Ausgleichung durchgeführt. Hierzu wird getestet, ob die Standardabweichung σ_{t_m} für den geschätzten Zeitpunkt t_m der Reflexion einen Schwellwert $S_{\sigma_{t_m}}$ unterschreitet. Nur Gauß-Funktionen, die dies erfüllen, werden weiter verwendet. Somit soll sichergestellt werden, dass nur einwandfreie Ergebnisse in die Auswertungen eingehen.

2.2.3 Ringing Effekt

Auf Grund elektronischer Effekte in der Empfängereinheit des Lasersystems können unmittelbar nach dem Empfang starker Signale sog. Nachschwinger auftreten. Dieses Phänomen wird im Englischen auch als „ringing effect“ bezeichnet und kann bis zu zwei zusätzliche Pseudo-Peaks nach einem großen Peak verursachen. Liegt deren Amplitude über dem Schwellwert $S_{\hat{A}_m}$, so werden falsche Reflexionen angenommen. Die Abbildung 2.4a zeigt ein Beispiel für die Anpassung einer Gauß-Funktion an einen fehlerhaften Peak. Um dies zu verhindern, werden Regeln zur Erkennung dieser Pseudo-Peaks formuliert. Ein derartiger Peak wird angenommen, falls der Abstand $\Delta t = t_m - t_{m-1}$ zwischen zwei Gauß-Funktionen den Schwellwert $S_{\Delta t}$ unterschreitet und das Verhältnis $\frac{A_{m-1}}{A_m}$ kleiner als der Schwellwert S_{V_A} ist. Trifft dies zu, werden die entsprechenden Werte aus den Ausgleichungsergebnissen x entfernt und dieser Peak wird somit nicht weiter beachtet. In der Abbildung 2.4b sieht man ein Beispiel für die Berücksichtigung des Ringing Effekts.

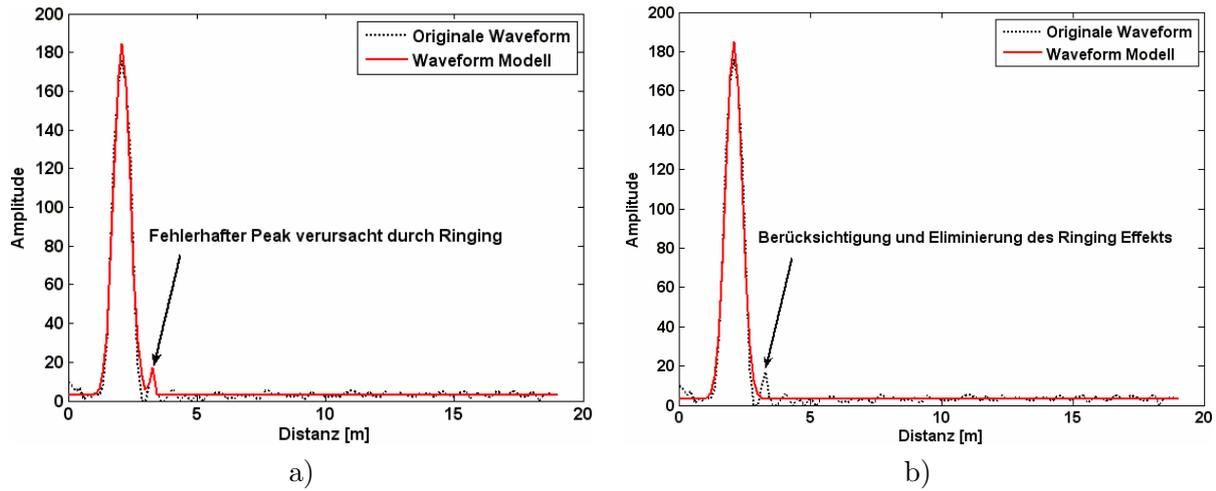


Abbildung 2.4: Berücksichtigung des Ringing Effekts. a) Waveform mit Pseudo-Peak, b) Nichtbeachtung dieses Peaks durch Modellierung des Ringing Effekts

2.3 3D Punkte und deren Attribute

2.3.1 Ableitung aus den geschätzten Parametern

Aus den Reflexionszeiten t_m , der Position \mathbf{X}_S zum Sendezeitpunkt t_S des Laserstrahls und dessen Richtungsvektor \mathbf{r}_S werden die 3D Positionen \mathbf{X}_m der Reflexionen durch polares Anhängen berechnet:

$$\mathbf{X}_m = \mathbf{X}_S + \frac{t_m - t_S}{2} v_g \mathbf{r}_S \quad (m = 1, \dots, N_P) \quad (2.13)$$

Bei der Umrechnung der Zeit ins metrische Maß muss berücksichtigt werden, dass die Differenz zwischen Empfangs- und Sendezeit den doppelten Laufweg repräsentiert und deshalb halbiert werden muss. Außerdem ist für die Ausbreitungsgeschwindigkeit des Laserstrahls die Gruppengeschwindigkeit v_g zu verwenden. Diese weicht aber im optischen und nahen infraroten Bereich bei trockener Luft höchstens um 0.03 % von der Lichtgeschwindigkeit c im Vakuum ab [Wagner et al., 2004]. Neben den Koordinaten werden jedem 3D Punkt \mathbf{X}_m die Intensität I_m und die Pulsbreite W_m als Attribute zugeordnet, d.h. $\mathbf{X}_m^T = (x_m, y_m, z_m, I_m, W_m)$. Dabei ist $W_m = 2\sigma_m$ die doppelte Standardabweichung der m-ten Gauß-Funktion und spiegelt geometrische Eigenschaften der Zielobjekte wider. Raue Oberflächen mit einer gewissen Ausdehnung in der Richtung des Laserstrahls führen zu einer Pulsaufweitung, so dass W_m ein Maß für Höhenänderungen der vom Laserstrahl beleuchteten Oberfläche ist. Gleichzeitig verringert sich bei einer Pulsaufweitung die Amplitude A_m der Reflexion, weil die reflektierten Photonen über einen größeren Zeitraum verteilt werden [Stilla & Jutzi, 2008]. Die Intensität $I_m = \sqrt{2\pi}\sigma_m A_m$ entspricht dem Flächenintegral der m-ten Gauß-Funktion und ist proportional zur Pulsenergie der Reflexion. Vor allem bei diskret arbeitenden Systemen ist es üblich, die reinen Amplitudenwerte als Intensitäten zu bezeichnen, so dass die Höchstenergie der Echos charakterisiert wird. Aus physikalischer Hinsicht ist es jedoch natürlicher, die Intensität mit der Gesamtenergie eines Echos in Verbindung zu bringen [Wagner et al., 2008]. In der Abbildung 2.5 ist die Ableitung der Punkte und Attribute aus den Waveforms anhand eines Beispiels graphisch dargestellt. Wie man sieht, werden mit diesem Ansatz alle Reflexionen in der Waveform detektiert.

Des Weiteren werden die abgeleiteten Punkte \mathbf{X}_m abhängig von der Anzahl N_P der Reflexionen und ihrer Reihenfolge in der Waveform in vier Klassen aufgeteilt (Tabelle 2.1).

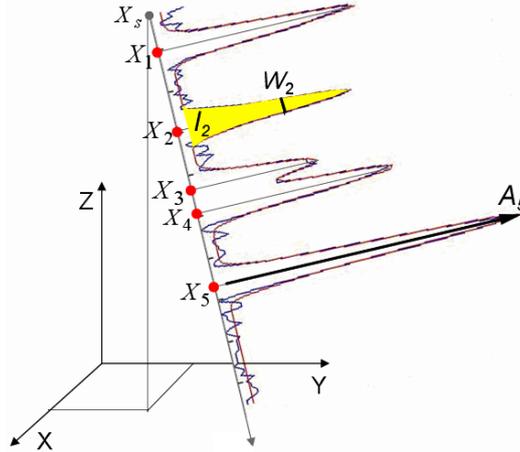


Abbildung 2.5: Ableitung von 3D Punkten und deren Attributen

| Klasse | Einzelpunkte (Single) | Erste Punkte (First) | Zwischenpunkte (Middle) | Letzte Punkte (Last) |
|------------|--------------------------|-------------------------|---|---------------------------|
| Definition | $N_P = 1$ $m = 1$ | $N_P \geq 2$ $m = 1$ | $N_P \geq 3$ $m = 2, \dots, N_P - 1$ | $N_P \geq 2$ $m = N_P$ |

Tabelle 2.1: Unterteilung der abgeleiteten Punkte \mathbf{X}_m in Klassen

2.3.2 Kalibrierung von Intensität und Pulsbreite

Das Ziel der Kalibrierung ist es, die Werte von I_m und W_m so zu korrigieren, dass sie die Charakteristiken der Zielobjekte widerspiegeln und möglichst unabhängig sind von anderen Einflüssen der Datenerfassung. Idealerweise sollte das nicht nur innerhalb einer Messkampagne, sondern auch für Daten unterschiedlicher Befliegungen mit verschiedenen Lasersystemen gelten. Hierzu setzt man W_m ins Verhältnis zur Pulsbreite W_S des gesendeten Signals:

$$W_m^c = \frac{W_m}{W_S} \quad (2.14)$$

Somit erhält man einen Wert W_m^c , der die Aufweitung des Pulses repräsentiert und unabhängig von Schwankungen des gesendeten Signals innerhalb einer Befliegung ist. Die Voraussetzung hierfür ist natürlich die Aufzeichnung der einzelnen Sendepulse.

Bei der Kalibrierung der Intensität sollen Werte entstehen, die proportional zur Reflektivität der Oberfläche sind. Das ist insbesondere wichtig, wenn die Intensität für die Klassifikation von Objekten anhand ihrer Materialeigenschaften verwendet wird. In der Gleichung 2.3 kann das Produkt aus Amplitude und Standardabweichung sowohl beim empfangenen als auch beim gesendeten Signal durch die Intensität ersetzt werden:

$$I_m = \frac{I_S D_E^2}{4\pi R_m^4 \beta_S^2} \eta_{\text{sys}} \eta_{\text{atm}} \Gamma_m \quad (2.15)$$

Man kann in (2.15) erkennen, dass I_m nicht nur von den Eigenschaften des Sensors, des Zielobjekts und der Atmosphäre, sondern auch stark von der Distanz R zwischen Sensor und Ziel abhängt. Die systemspezifischen Größen D_E , β_S und η_{sys} sind während einer Messkampagne konstant, so dass

folgender Ausdruck zu einer Konstanten C_1 zusammengefasst werden kann:

$$C_1 = \frac{D_E^2}{4\pi\beta_S^2}\eta_{\text{sys}} \quad (2.16)$$

Der atmosphärische Transmissionsfaktor

$$\eta_{\text{atm}} = 10^{-2Ra/10000} \quad (2.17)$$

repräsentiert den Energieverlust durch Streuung und Absorption der Photonen des Laserstrahls in der Atmosphäre, wobei a [dB/km] als Abschwächungsfaktor bezeichnet wird [Höfle & Pfeifer, 2007]. Der Faktor a kann aus den meteorologischen Daten der Befliegung mit Hilfe von Modellen zur Ausbreitung von Wellen in der Atmosphäre (z.B. MODTRAN [Berk et al., 1998]) berechnet werden. Für die Radargleichung gilt dann:

$$I_m = \frac{I_S}{R^4} C_1 \Gamma_m \eta_{\text{atm}} \quad (2.18)$$

Auch wenn Systeme neben dem reflektierten Signal das gesendete Signal aufzeichnen, kann man daraus nicht automatisch den wirklichen Wert I_S der gesendeten Pulsenergie berechnen. Meist existiert zwischen I_S und dem Wert $I_{S,g}$ aus dem aufgezeichneten Signal ein unbekannter, aber konstanter Umrechnungsfaktor C_S , d.h. $I_S = C_S I_{S,g}$. Kombiniert man die beiden Konstanten C_1 und C_S zu C_2 , so folgt:

$$I_m^c = \frac{I_m}{I_{S,g}\eta_{\text{atm}}} = \frac{1}{R^4} C_2 \Gamma_m \quad (2.19)$$

Hierbei fasst I_m^c die Größen I_m , $I_{S,g}$ und η_{atm} zusammen und ist somit ein Wert, der bezüglich eventueller Schwankungen der gesendeten Laserenergie und der Abschwächung durch die Atmosphäre korrigiert ist. Falls das gesendete Signal nicht aufgezeichnet wurde, muss I_S als konstant angenommen werden. Löst man die Gleichung 2.19 nach Γ_m auf so gilt:

$$\Gamma_m = I_m^c R^4 \frac{1}{C_2} \quad (2.20)$$

Der Streuquerschnitt Γ_m wird z.B. von Wagner et al. [2006] als Zielgröße für die Charakterisierung von Objekten vorgeschlagen. Innerhalb einer Messkampagne ist C_2 konstant, so dass für diesen Fall eine Berechnung von $I_m^c R^4$ ausreicht, um zu Γ_m proportionale Werte zu erhalten. Für sensorunabhängige Ergebnisse muss C_2 mit Hilfe von Referenzflächen, deren Streuquerschnitt bekannt ist, ermittelt werden. Briese et al. [2008] verwenden dazu natürliche Oberflächen und bestimmen deren Streuquerschnitt mit einem Reflektometer. Alternativ können portable Kalibrierflächen, deren Reflexionseigenschaften im Labor bestimmt werden, zum Einsatz kommen [Kaasalainen et al., 2007].

Entscheidend ist die Frage, wie geeignet der Streuquerschnitt für die Charakterisierung von Objekten bezüglich ihrer Reflexionseigenschaften ist. Die Gleichung 2.2 zeigt, dass Γ proportional zur beleuchteten Fläche A ist. Bei ausgedehnten Objekten entspricht A der Größe des Footprints $F = \pi R^2 \beta_S^2 / 4$ und nimmt mit dem Quadrat der Entfernung R zu. In der Abbildung 2.6c sieht man eine ebene Fläche, die von zwei Laserstrahlen mit den unterschiedlich großen Footprints F_1 und F_2 beleuchtet wird. Somit unterscheidet sich Γ für die beiden Fälle, obwohl sich die Materialeigenschaften der Fläche nicht ändern. Ebenso verhält es sich bei einem linienförmigen Objekt (2.6b), wobei hier A und somit auch Γ direkt proportional zu R sind. Der Streuquerschnitt ist nur dann unabhängig vom Footprint, wenn das beleuchtete Objekt kleiner ist als dieser (2.6a). Eine Kalibrierung nach der Gleichung 2.20

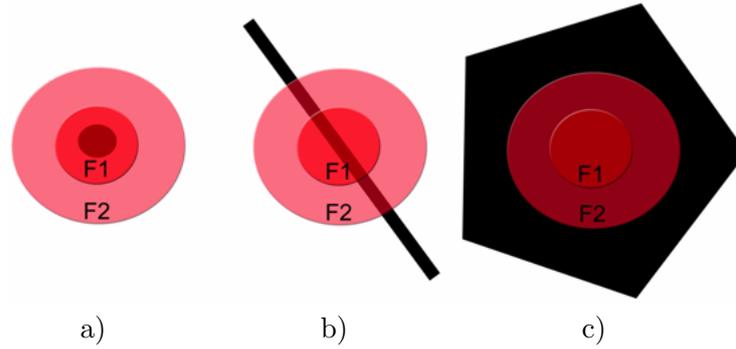


Abbildung 2.6: Überlagerung von Objekten mit unterschiedlich großen Footprints F_1 und F_2 . a) für ein punktförmiges, b) für ein linienförmiges, c) für ein flächenhaftes Objekt

ist also nur für solche Objekte sinnvoll. Bei anderen Objekten muss eine Normalisierung bezüglich A vorgenommen werden. Im Falle einer Fläche gilt für den normalisierten Streuquerschnitt Γ^0 :

$$\Gamma_m^0 = \frac{\Gamma_m}{A_m} = \frac{I_m^c R^4}{R^2} \frac{4}{C_2 \beta_S^2 \pi} = I_m^c R^2 C_3 \quad (2.21)$$

Bei linienförmigen Objekten kann man analog zur Herleitung der Gleichung 2.21 zeigen, dass eine Korrektur von I_m^c mit R^3 notwendig ist. Die aufgezeigte Problematik macht deutlich, dass eine für alle Reflexionen korrekte Kalibrierung nur bei genauer Kenntnis der jeweils beleuchteten Fläche A möglich ist, was eine detaillierte 3D Objektbeschreibung zur Modellierung des Strahlengangs voraussetzt. Da diese Information im Allgemeinen nicht verfügbar ist, sind Annahmen über die Objekteigenschaften notwendig. Häufig wird beim ALS von flächenhaften Zielobjekten ausgegangen, die größer als der Footprint sind und somit eine Kalibrierung nach der Gleichung 2.21 rechtfertigen. Dabei ergibt sich aber eine nachteilige Behandlung der Reflexionen an kleinen Objekten, wie sie beispielsweise im Vegetationsbereich häufig auftreten.

Neben der beschriebenen Kalibrierung, die streng der Radargleichung (2.1) folgt, gibt es auch datengetriebene Ansätze. Dazu verwendet man empirische mathematische Funktionen als Korrekturterme, deren Parameter mit Hilfe von Daten aus verschiedenen Flughöhen geschätzt werden. Höfle & Pfeifer [2007] stellen mehrere solche Funktionen vor und führen einen Vergleich mit dem modellgetriebenen Ansatz durch. Dabei liefert die folgende Korrektur der gemessenen Intensität I Ergebnisse, die dem modellgetriebenen Ansatz äquivalent sind:

$$I^{\text{kor}} = I f(R) = I (a_{\text{kal}} R^2 + b_{\text{kal}} R + (1 - a_{\text{kal}} R_{\text{ref}}^2 - b_{\text{kal}} R_{\text{ref}})) \quad (2.22)$$

Der Korrekturterm $f(R)$ entspricht einem Polynom zweiten Grades und normalisiert den bei der Entfernung R gemessenen Wert I auf eine Referenzentfernung R_{ref} . Ein Vorteil dieses Vorgehens liegt darin, dass die Systemparameter des verwendeten Aufnahmesystems und die atmosphärischen Bedingungen während der Befliegung nicht bekannt sein müssen. Weiterhin besteht hier die Chance, Abweichungen zwischen Modell und Wirklichkeit implizit zu kompensieren. Beispielsweise wird beim Modell der Radargleichung (2.1) zwingend vorausgesetzt, dass die Aufzeichnung des Signals proportional zur Stärke des empfangenen Signals erfolgt. Mögliche Abweichungen davon führen zu Fehlern bei der modellgetriebenen Korrektur der Intensität. Datengetriebene Ansätze hingegen können diesen Effekt berücksichtigen. Ein Nachteil dieser Methode ist jedoch, dass für einen Teil des Befliegungsgebiets Daten aus verschiedenen Flughöhen vorliegen müssen. Zum Beispiel sind für die Bestimmung der

Parameter a_{kal} und b_{kal} in der Gleichung 2.22 Daten aus drei signifikant unterschiedlichen Flughöhen erforderlich.

Eine weitere Möglichkeit zur Kalibrierung der Intensität ist eine Kombination aus modell- und datengetriebener Korrektur. Wenn z.B. Informationen über die gesendeten Signale und die atmosphärischen Bedingungen während der Befliegung vorliegen, so ist es sinnvoll, dies in den Prozess einzubringen. Zusätzlich sollte eine geeignete Datenkonstellation dazu genutzt werden, die modellgetriebene Korrektur zu überprüfen und ggf. zu verbessern. In der Gleichung

$$I^{\text{kor}} = I^c \frac{R^n}{R_{\text{ref}}^n} \quad (2.23)$$

wird die gemessene Intensität I^c , die schon bezüglich Änderungen des gesendeten Signals und der Atmosphäre korrigiert ist, auf die Referenzentfernung R_{ref} normiert. Der Wert des Exponenten n kann entweder festgesetzt oder aus Daten unterschiedlicher Flughöhe optimal bestimmt werden. Für $n = 2$ ist I^{kor} proportional zum normalisierten Streuquerschnitt I^0 aus der Gleichung 2.21 und entspricht somit der modellgetriebenen Kalibrierung für den Fall ausgedehnter Objekte. Die Werte $n = 3$ und $n = 4$ gelten analog für linien- und punktförmige Objekte. Vorteilhaft gegenüber der Gleichung 2.22 ist, dass nur Daten aus zwei unterschiedlichen Höhen zur Bestimmung von n vorliegen müssen.

Kapitel 3

Segmentierung von Einzelbäumen

Für die Segmentierung von Einzelbäumen aus LiDAR Daten wurden im Rahmen dieser Arbeit drei verschiedene Methoden entwickelt und implementiert. Diese werden zunächst kurz vorgestellt und in den folgenden Abschnitten detailliert beschrieben:

- Im ersten Verfahren (Abschnitt 3.1) wird eine Watershed Segmentierung [Vincent & Soille, 1991] auf das Baumhöhenmodell (CHM) angewendet [Reitberger et al., 2008b]. Diese Vorgehensweise hat sich in den letzten Jahren zu einem Standardverfahren entwickelt und ist Gegenstand mehrerer Untersuchungen (z.B. [Persson et al., 2002; Zhao & Popescu, 2007]). Die Methode eignet sich gut für die Erkennung dominanter Bäume, deren Kronen im CHM repräsentiert sind. Jedoch können Strukturen unterhalb des CHM, wie z.B. Verjüngungen, nicht erfasst werden. Zudem werden benachbarte Bäume häufig zu einem Segment zusammengefasst.
- Das im Abschnitt 3.2 vorgestellte Verfahren zur Erkennung von Baumstämmen [Reitberger et al., 2007a] geht einen Schritt weiter und nutzt die Informationen unterhalb des CHM. Im Vergleich zur Watershed Segmentierung können zusätzliche Bäume gefunden, deren Stämme in den Laserdaten erkennbar sind, die aber im CHM kein eigenes lokales Maximum besitzen. Außerdem trägt das Verfahren zur besseren Identifikation benachbarter Bäume bei und führt zu genaueren Baumpositionen. Es findet jedoch keine Zuordnung der Reflexionen eines Baums zum jeweiligen Stamm statt.
- Die im Abschnitt 3.3 beschriebene 3D Segmentierung von Bäumen [Reitberger et al., 2008c,d, 2009b,c] stellt einen weiteren Fortschritt dar. Unabhängig von Saatkpunkten findet eine echte 3D Zuordnung der Reflexionen zu den jeweiligen Bäumen statt. Dadurch können neben den dominanten großen Bäumen auch die dominierte Bäume im Unterstand und die Verjüngungen segmentiert werden. Darüber hinaus ist es möglich, die Ergebnisse der Watershed Segmentierung und der Stammdetektion optional als Vorwissen in das Verfahren einzubringen. In diesem Fall entsteht ein kombiniertes dreistufiges Verfahren, das die Stärken der ersten beiden Methoden nutzt, jedoch nicht an deren Schwächen gebunden ist.

3.1 Segmentierung auf Basis des Baumhöhenmodells

3.1.1 Berechnung des CHM

Für die Watershed Segmentierung ist die Ableitung eines präzisen CHM erforderlich, das die Höhe der Waldoberfläche über dem Gelände enthält und somit die Differenz zwischen dem DOM und dem DGM darstellt. Diese Normalisierung des DOM ist vor allem für die Segmentierung im geneigten Gelände vorteilhaft, weil der Einfluss des Geländes eliminiert wird. Bei der Berechnung des CHM wird das Gebiet in ein Raster mit der Zellgröße c_p unterteilt und innerhalb jeder der N_Z Zellen der höchste Punkt $(x_j, y_j, z_j) (j = 1 \dots N_Z)$ gesucht (Abbildung 3.1). Die Höhe z_j dieser Punkte wird bezüglich

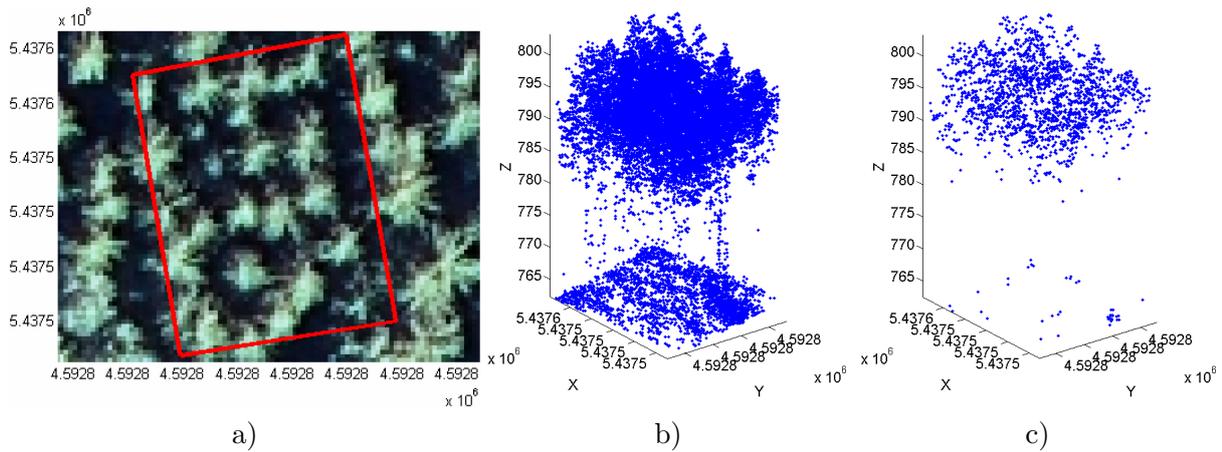


Abbildung 3.1: Filterung der höchsten Punkte. a) Orthofoto mit Gebietsgrenzen, b) alle Punkte im Gebiet, c) die höchsten Punkte pro Rasterzelle

der Geländehöhe z_j^{DGM} an der Position (x_j, y_j) korrigiert:

$$z_j^{\text{CHM}} = z_j - z_j^{\text{DGM}} (j = 1 \dots N_Z) \quad (3.1)$$

Den Wert für z_j^{DGM} erhält man durch bilineare Interpolation im DGM. Im nächsten Schritt werden die gefilterten höchsten Punkte aller Zellen robust in ein Gitter mit $N_{\text{CHM}} = N_X \times N_Y$ Gitterpunkten

$$\mathbf{X}_{\text{Int}}^{\text{CHMT}} = (x_{\text{Int } k,l}^{\text{CHM}}, y_{\text{Int } k,l}^{\text{CHM}}, z_{\text{Int } k,l}^{\text{CHM}}) (k = 1 \dots N_X; l = 1 \dots N_Y) \quad (3.2)$$

und einer Gitterweite g_w interpoliert, wobei N_X und N_Y die Anzahl der Gitterlinien sind (Abbildung 3.2). Zu diesem Zweck wurden alternativ zwei Ansätze implementiert. Die erste Methode interpoliert mit finiten Elementen ein regelmäßiges Rastermodell [Krzystek & Wild, 1992]. Durch Bedingungen an die Krümmung und Torsion an den Gitterpunkten entsteht eine vorgebbare Filterfunktion zur Glättung der Oberfläche. Einzelne Punkte, die das CHM nicht ausreichend repräsentieren, erhalten in Abhängigkeit von der Entfernung zur Oberfläche ein niedrigeres Gewicht und können sogar eliminiert werden. Das iterative Ausgleichungsschema arbeitet wie ein kantenerhaltender Filter, der Ausreißer entfernt, Lücken bei fehlenden Punkten schließt und Unstetigkeiten in der Oberfläche erhält.

Der zweite Ansatz ist das von D'Errico [2006] vorgestellte Verfahren „gridfit“. Hier wird auf jeden Datenpunkt eine bilineare Interpolation angewendet. Gleichzeitig wird versucht, den Gradienten an jeder Stelle so klein wie möglich zu halten, was zu einer Glättung führt. In einer „Kleinste Quadrate“ Ausgleichung wird das optimale Ergebnis geschätzt, wobei die Balance zwischen Interpolation und

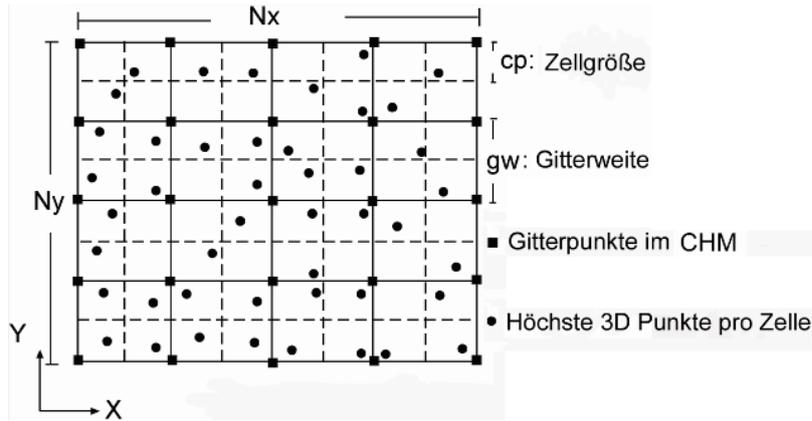


Abbildung 3.2: Interpolation der höchsten Punkte in ein regelmäßiges Gitter

Glättung mit Hilfe des anpassbaren Glättungsfaktors λ gesteuert werden kann. Dazu verwendet man folgende Beobachtungsgleichungen:

$$\begin{bmatrix} \mathbf{A} \\ \lambda \mathbf{B} \end{bmatrix} (z_{\text{Int}}^{\text{CHM}})^{\text{T}} = \begin{pmatrix} (z_1^{\text{CHM}} \dots z_{N_Z}^{\text{CHM}})^{\text{T}} \\ \mathbf{0} \end{pmatrix} \quad (3.3)$$

Die $N_Z \times N_{\text{CHM}}$ Matrix \mathbf{A} enthält die Koeffizienten der bilinearen Interpolation und die $N_{\text{CHM}} \times N_{\text{CHM}}$ Matrix \mathbf{B} umfasst die Koeffizienten der ersten partiellen Ableitung benachbarter Zellen. Der Vektor $z_{\text{Int}}^{\text{CHM}}$ hat N_{CHM} Elemente und repräsentiert die interpolierten Höhen.

Das Ergebnis ist für beide Ansätze ein geglättetes CHM mit N_{CHM} gleichabständigen Stützposten (Abbildung 3.4a). Die Berechnung der lokalen Maxima des CHM liefert erste Werte für die Baumpositionen $(X_{\text{Baum}_i}^{\text{CHM}}, Y_{\text{Baum}_i}^{\text{CHM}})(i = 1, \dots, N_{\text{LokMax}})$.

3.1.2 Watershed Algorithmus

Zur Abgrenzung der einzelnen Baumkronen wird der Watershed Algorithmus von Vincent & Soille [1991] angewandt. Dieses Verfahren, das man auch als Wasserscheidentransformation bezeichnet, stammt aus der digitalen Bildverarbeitung und interpretiert die Grauwertunterschiede als Höhenrelief. Ziel des Verfahrens ist die vollständige Aufteilung des Bildes in disjunkte Einzugsgebiete des Wassers, so dass es zum jeweiligen lokalen Minimum im Gebiet fließt. Zur Identifikation der Wasserscheiden wird folgendes Szenarium simuliert: Ausgehend von den lokalen Minima werden die einzelnen Täler des Grauwertgebirges schrittweise geflutet, so dass Seen entstehen (Abbildungen 3.3a und 3.3b). An den Stellen, an denen das Wasser von zwei Seen aufeinander stößt, befindet sich eine Wasserscheide. Damit das Wasser der verschiedenen Täler nicht ineinander fließen kann, werden an diesen Stellen Dämme errichtet (Abbildung 3.3c). Als Ergebnis erhält man Segmente, deren Grenzen entlang der Spitzen des Grauwertgebirges verlaufen. Da jedoch für die Abgrenzung der Baumkronen im CHM genau das Gegenteil gesucht ist, nämlich der Verlauf entlang der Täler, ist vor der Segmentierung eine Invertierung des CHM notwendig. Ein Beispiel für die Anwendung des Verfahrens sieht man in der Abbildung 3.4. Man kann deutlich erkennen, dass es für jedes lokale Maximum genau ein Segment gibt.

Zur weiteren Analyse der gefundenen Bäume (z.B. Baumartenklassifikation) werden die originalen 3D Punkte innerhalb der Segmentgrenzen verwendet. Die Baumhöhe $Z_{\text{Baum}_i}^{\text{CHM}} = z_i^{\text{max}} - z_i^{\text{DGM}}$ pro

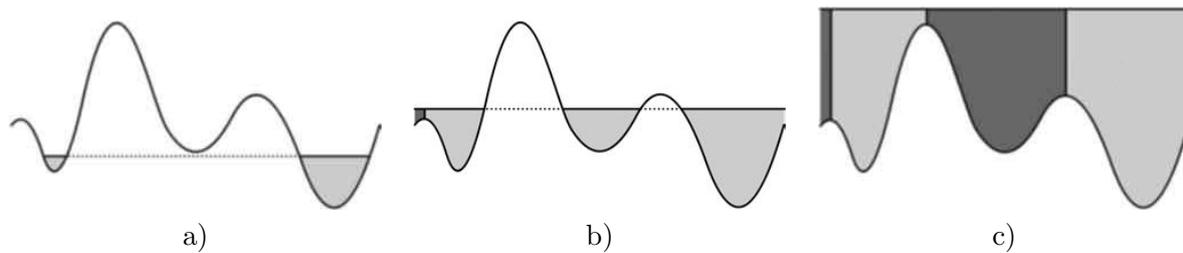


Abbildung 3.3: Prinzip des Watershed Algorithmus. a) und b) Auffinden der Wasserscheiden durch schrittweises Fluten ausgehend von den lokalen Minima, c) Errichten von Dämmen an den Wasserscheiden [Messner, 2007]

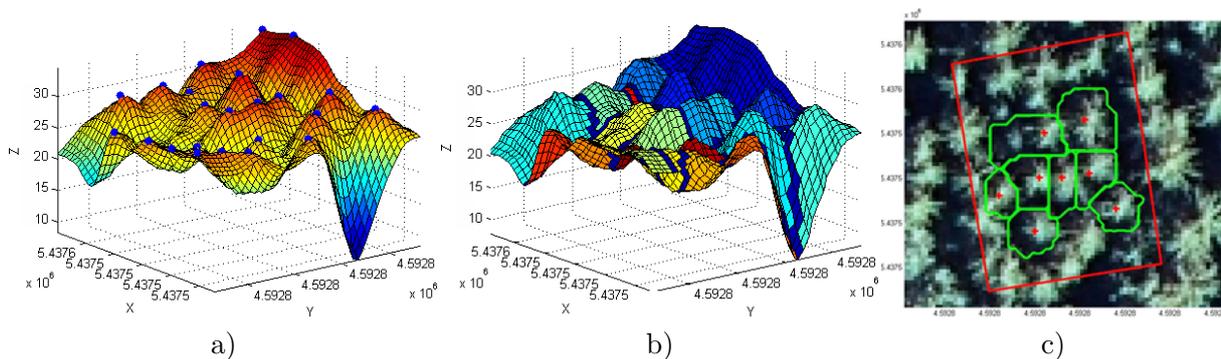


Abbildung 3.4: Anwendung des Watershed Algorithmus für die Segmentierung von Bäumen. a) CHM mit lokalen Maxima für das Gebiet aus Abbildung 3.1, b) Watershed Segmente, c) Orthofoto mit Segmenten und lokalen Maxima

Segment ist die Differenz zwischen der maximalen Höhe z_i^{\max} der Reflexionen im Segment i und der Geländehöhe z_i^{DGM} an dieser Stelle. Alternativ zu z_i^{\max} kann auch die Höhe des lokalen Maximums im CHM verwendet werden. Dies hat jedoch den Nachteil, dass die Glättung des CHM zu einer Unterschätzung der Baumhöhe führt.

3.2 Detektion von Baumstämmen

3.2.1 Nutzung der Information unterhalb des CHM

Mit Hilfe der Watershed Segmentierung können nur die dominanten Bäume mit einem eigenen lokalen Maximum voneinander abgegrenzt werden. Bei Bäumen, die im CHM entweder gar nicht oder nur unzureichend repräsentiert sind, versagt diese Methode. Die Verschmelzung benachbarter Bäume zu einem Segment wird durch die Glättung des CHM noch verstärkt. Auf diese kann jedoch nicht verzichtet werden, weil ansonsten eine Übersegmentierung innerhalb der einzelnen Baumkronen auftritt. Es entstehen also häufig Segmente, die Baumgruppen anstelle von Einzelbäumen enthalten. Zum Beispiel zeigt die Abbildung 3.5a das CHM eines dichten Fichtenbestandes, wobei die schwarzen Linien die Positionen und Höhen von bekannten Bäumen (= Referenzbäumen) darstellen. Offensichtlich gibt es für viele Referenzbäume kein eigenes lokales Maximum. Ein weiteres Beispiel dafür ist in der Abbildung 3.5b dargestellt. Hier enthält das zentrale Segment drei Bäume (weiße Punkte), die nicht voneinander getrennt werden können. Betrachtet man die Laser-Reflexionen innerhalb dieses Segments (Abbildung

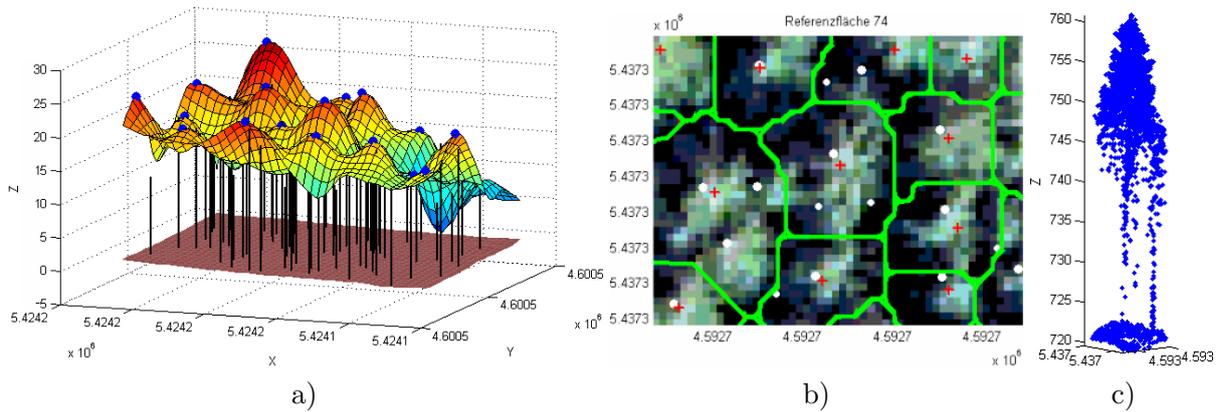


Abbildung 3.5: Beispiele für Segmente mit Baumgruppen anstelle von Einzelbäumen. a) CHM mit lokalen Maxima und Referenzbäumen (schwarze Linien), b) Orthofoto mit Watershed Segmenten (grün), Referenzbäumen (weiß) und lokalen Maxima (rot), c) Laserpunkte für das zentrale Segment von b)

3.5c), dann kann man einen dominanten Baum erkennen (oben mittig im Segment), in dessen Nähe sich das lokale Maximum (rotes Kreuz) befindet. Die beiden unteren Bäume sind kleiner und tragen deshalb kaum zum CHM bei. In den Laserpunkten ist jedoch deren Struktur sichtbar, wobei insbesondere der rechte Baum sehr viele Reflexionen an den Stämmen besitzt. Die Reflexionen des linken Baums befinden sich in der Abbildung 3.5c wegen der Drehung gegenüber der Abbildung 3.5b zwischen dem dominanten und dem rechten Baum. Das Beispiel macht deutlich, dass die hohe räumliche Punktdichte der Full Waveform Technologie bei der Segmentierung im CHM größtenteils ungenutzt bleibt.

Das hier beschriebene Verfahren nutzt die Information unter der Waldoberfläche, um benachbarte Bäume besser trennen zu können und die Genauigkeit der Baumpositionen zu steigern. Aus folgenden Gründen wurde der Fokus auf die Erkennung von Baumstämmen gelegt:

- Jeder Baum hat in den meisten Fällen genau einen Stamm, der dessen Position markiert
- Die Form des Stamms ist innerhalb gewisser Grenzen geometrisch definierbar
- Zumindest im unteren Stammbereich sehen die Stämme der verschiedenen Baumarten ähnlich aus, so dass nur ein Verfahren für alle Arten entwickelt werden muss
- Stämme sind im Gegensatz zu anderen Baumelementen (z.B. Äste, Zweige) groß genug, um in ALS Daten als Einzelobjekte erkannt zu werden

Die Vorgehensweise zur Extraktion der Stämme wird in den nächsten Abschnitten beschrieben:

3.2.2 Filterung von Stammpunkten

Im ersten Schritt werden die N_{Seg} Reflexionen $\mathbf{X}_{\text{Seg}_j}$ ($j = 1, \dots, N_{\text{Seg}}$) innerhalb eines Watershed Segments in Boden-, Stamm- und Kronenpunkte aufgeteilt. Als Bodenpunkte werden Punkte mit einem geringen Abstand (z.B. 1 m) zu einem DGM betrachtet, das zuvor flächendeckend für das ganze Auswertungsgebiet abgeleitet wurde. Die verbleibenden N_{Baum} Baumpunkte werden bis zur sog. Kronenansatzhöhe H_{KtA} als Stammpunkte, und ab dieser Höhe als Kronenpunkte bezeichnet. Ein

geeigneter Wert für H_{KrA} wird ermittelt, indem die Baumpunkte in l Höhengschichten mit der Höhe H_{Schicht} (z.B. 0.5 m) aufgeteilt werden (Abbildung 3.6a). Aus der Anzahl N_i der Punkte pro Schicht wird der Vektor $\mathbf{N}_P = \{N_i/N_{\text{Baum}}\} (i = 1, \dots, l)$ gebildet und mit einem 3×1 Gauss-Filter geglättet. Dann sucht man das erste Element in \mathbf{N}_P , das einen festgelegten Schwellwert S_{NP} überschreitet. Die zu diesem Element korrespondierende Höhe definiert schließlich H_{KrA} (Abbildung 3.6b). Die N_{Stamm} Stammpunkte (Abbildung 3.6c) in einem Watershed Segment können dabei zu einem oder mehreren Stämmen gehören. Natürlich können auch Reflexionen vom Unterwuchs oder einzelnen Ästen darin enthalten sein.

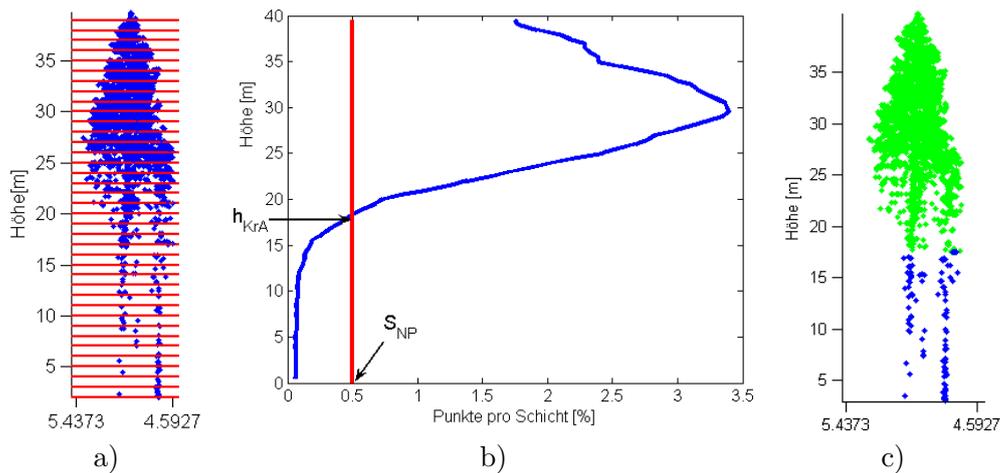


Abbildung 3.6: Vorgehensweise bei der Filterung von Stammpunkten. a) Aufteilung der Baumpunkte in Höhengschichten, b) Bestimmung von H_{KrA} , c) Stammpunkte (blau) und Kronenpunkte (grün)

3.2.3 Hierarchisches Clustering

Im zweiten Schritt werden die Stammpunkte bezüglich ihrer horizontalen Abstände zu Clustern zusammengefasst, um eine Zuordnung der Punkte zu den einzelnen Stämmen und eine erste Abschätzung der Stammzahl zu bekommen. Nach Berechnung der Euklidischen Distanzmatrix $\mathbf{D}_{\text{Stamm}} = \{D_{ij} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2}; i = 1, \dots, N_{\text{Stamm}}; j = 1, \dots, N_{\text{Stamm}}; i \neq j\}$ wird das folgende hierarchische Clustering-Schema angewandt [van der Heijden et al., 2004]:

1. Jedem Punkt wird ein Cluster zugeordnet, so dass es N_{Stamm} Cluster gibt.
2. Die zwei Cluster mit dem kleinsten Abstand zueinander werden gesucht und zu einem Cluster vereinigt, so dass sich die Anzahl der Cluster um eins reduziert.
3. Der Abstand des neuen Clusters zu allen übrigen Cluster wird berechnet.
4. Die Schritte 2 und 3 werden so lange wiederholt, bis alle Punkte in einem Cluster vereinigt sind oder eine vorgegebene Anzahl von Clustern erreicht ist.

Dieses Verfahren führt zu einem Dendrogramm, das die Abstände aufzeigt, bei welchen die einzelnen Cluster vereinigt werden. Durch Vorgabe eines Mindestabstands D_{min} kann der Prozess an der Stelle angehalten werden, wo alle Abstände dieses Kriterium erfüllen. Zum Beispiel zeigt die Abbildung 3.7a

das Dendrogramm für die Stammpunkte aus der Abbildung 3.6c. Die rote Linie kennzeichnet den Abbruch bei $D_{\min} = 1.2$ m, so dass vier Cluster entstehen (Abbildung 3.7b).

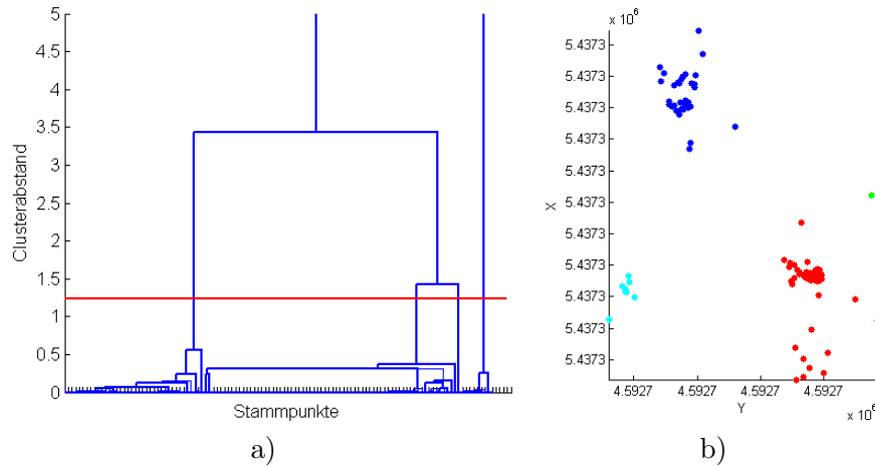


Abbildung 3.7: Hierarchisches Clustering von Stammpunkten. a) Dendrogramm für die Stammpunkte aus der Abbildung 3.6c, b) Ergebnis des Clusterings (vertikale Sicht auf die Punkte)

3.2.4 Nachbearbeitung der Stammcluster

Im dritten Schritt werden die entstandenen Cluster anhand bestimmter Kriterien überprüft und ggf. aussortiert. So führt die Existenz von weniger als drei Punkten zum Ausschluss, weil hier die Stammrekonstruktion sehr unsicher ist. An die Punkte der verbleibenden Cluster werden 3D-Linien angepasst, wobei das robuste RANSAC-Verfahren zum Einsatz kommt, das Ausreißer mit einem großen Abstand zur Stammgeraden eliminiert. Dann werden die Neigungswinkel dieser Geraden gegenüber der Vertikalen bestimmt und nur solche mit einer geringeren Neigung als S_{Neigung} beibehalten. Der Grund für dieses Kriterium liegt in der - von Ausnahmen abgesehen - nahezu senkrechten Ausrichtung der Baumstämme. Um zu vermeiden, dass Reflexionen vom Unterstand oder von Ästen, die zufällig das Neigungskriterium erfüllen, zu Stämmen deklariert werden, gelten weitere Bedingungen. So darf die unterste Stammreflexion nicht höher als H_{maxUnten} über dem Boden liegen. Die oberste Stammreflexion muss mindestens H_{minOben} über dem Boden liegen und die Länge des Stamms muss mindestens L_{min} betragen. Nur dann werden die Geraden endgültig als Stammgeraden G_{Stamm} verwendet.

Die neuen Baumpositionen $(X_{\text{Baum } i}^{\text{StDet}}, Y_{\text{Baum } i}^{\text{StDet}})(i = 1, \dots, N_{\text{StDet}})$ berechnen sich aus den Schnittpunkten von G_{Stamm} mit dem DGM. Zur Bestimmung der Baumhöhen $Z_{\text{Baum } i}^{\text{StDet}}$ werden die jeweils höchsten Punkte im Zylinder V_{Stamm} mit G_{Stamm} als Mittelgerade verwendet. Der Radius von V_{Stamm} muss dabei so gewählt werden, dass die Spitze des zu G_{Stamm} gehörigen Baums darin enthalten ist, jedoch keine eventuell höher liegenden Punkte benachbarter Bäume. Beim Test des Algorithmus erweisen sich Werte in der Größenordnung von 1 m für den Radius von V_{Stamm} als geeignet. Weil diese Vorgehensweise zur Höhenbestimmung bei kleineren Bäumen fehlschlägt, die direkt unterhalb der Krone dominanter Bäume stehen, wird ein zusätzliches Kriterium eingeführt: Besitzen die Kronenpunkte innerhalb von V_{Stamm} vertikale Lücken mit einer bestimmten Ausdehnung, so werden nur die Punkte unterhalb der Lücke für die Bestimmung der Baumhöhe verwendet. Die Punkte oberhalb der Lücke gehören mit großer Wahrscheinlichkeit zu dem darüber stehenden Baum. Bei Tests erweist sich ein Schwellwert von ca. 3 m für die Mindesthöhe dieser Lücken als wirksam.

3.2.5 Vorteile und Grenzen der Stammerkennung

Ein Beispiel für drei erfolgreich gefundene Stämme innerhalb eines Watershed Segments sieht man in der Abbildung 3.8. Der Vergleich von $(X_{\text{Baum}}^{\text{StDet}}, Y_{\text{Baum}}^{\text{StDet}})$ mit den Referenzpositionen zeigt, dass

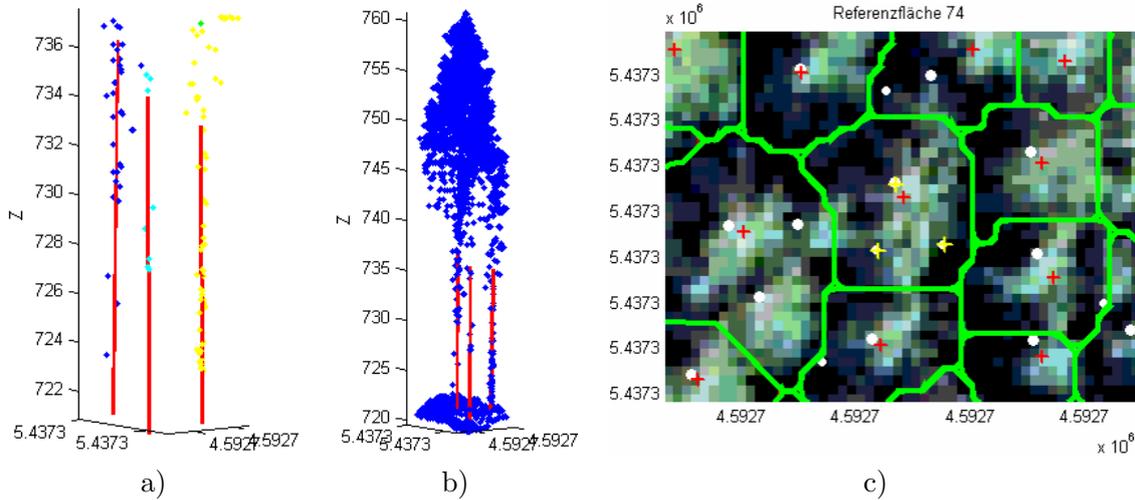


Abbildung 3.8: Erfolgreiche Detektion von Baumstämmen. a) Clusterpunkte mit G_{Stamm} für Punkte aus Abbildung 3.5c, b) Gefundene Stämme überlagert mit allen Punkten des Watershed-Segments, c) Vergleich von Stammpositionen (gelb) mit den Referenzpositionen (weiß) für das zentrale Segment

alle Bäume innerhalb des Segments mit einer Abweichung von weniger als 20 cm gefunden werden können. Der Vorteil der Stammerkennung liegt also in der Detektion von Bäumen, die im CHM nicht als Einzelbäume auflösbar sind. Außerdem passen die Baumpositionen $(X_{\text{Baum}}^{\text{StDet}}, Y_{\text{Baum}}^{\text{StDet}})$ besser zu den Referenzpositionen als die Positionen $(X_{\text{Baum}}^{\text{CHM}}, Y_{\text{Baum}}^{\text{CHM}})$ aus dem CHM, weil die Lage der Baumspitzen meist vom Fußpunkt des Baumstamms abweicht, der die Referenz darstellt.

Die erfolgreiche Detektion von Baumstämmen hängt stark von der jeweiligen Baum- und Waldstruktur ab. Damit eine ausreichende Anzahl von Stammreflexionen isoliert werden kann, muss eine klare Aufteilung der Bäume in einen Stamm- und einen Kronenbereich möglich sein. Diese Trennung ist schwierig, wenn die Äste der Bäume weit nach unten reichen oder wenn kleinere Bäume direkt neben den Stämmen stehen. Zur Veranschaulichung ist in der Abbildung 3.9a ein Waldbereich zu sehen, der gute Voraussetzungen für eine erfolgreiche Stammdetektion besitzt und dem auch das Beispiel aus der Abbildung 3.8 entnommen ist. Im Gegensatz dazu können in Gebieten wie in der Abbildung 3.9b dargestellt kaum Stämme gefunden werden. Bei Anwendung dieser Methode ist also je nach Waldstruktur mit einer sehr unterschiedlichen Qualität der Ergebnisse zu rechnen.

Ein weiterer Nachteil dieses Verfahrens besteht darin, dass die Kronenpunkte innerhalb der Watershed Segmente nicht den einzelnen Stämmen zugeordnet werden. Aus diesem Grund kann man die Stammdetektion nicht als eigenständiges Segmentierungsverfahren bezeichnen, sondern eher als optionales Verfahren, das jedoch bei Vorliegen der genannten Bedingungen sehr präzise Baumpositionen liefert. Neben der Positionsbestimmung kann diese Methode auch dazu genutzt werden, Stammtreffer zu isolieren und diese bezüglich der Attribute Intensität und Pulsbreite zu analysieren.



Abbildung 3.9: Unterschiedliche Voraussetzungen für die Detektion von Stämmen. a) Beispiel für einen Waldbestand mit astfreien und gut isolierbaren Stämmen, b) Beispiel für einen Bestand, in dem die Trennung zwischen Stamm- und Kronenbereich schwierig ist

3.3 Segmentierung auf Basis der attributierten 3D Punktwolke

3.3.1 Anforderung an das Verfahren

Ein Verfahren, das die Nachteile der Watershed Segmentierung und der Stammdetektion überwinden soll, muss folgende Anforderungen erfüllen:

1. Bei der Segmentierung sollen möglichst alle Reflexionen verwendet werden. Somit geht vorab keine Information verloren, wie es im Falle der Watershed Segmentierung bei der Reduktion auf das CHM geschieht.
2. Die Segmentierung muss dazu in der Lage sein, Bäume zu erkennen, die im CHM nicht sichtbar sind.
3. Die Segmentierung muss vollständig und überdeckungsfrei sein, d.h. ein Baumsegment enthält im Idealfall genau die Reflexionen, die von diesem Baum stammen.
4. Es darf keine Einschränkung bezüglich der Waldstruktur geben, d.h. das Verfahren muss allgemein anwendbar sein
5. Die Anzahl der Segmente muss automatisch bestimmt werden, so dass keine Initialisierung erforderlich ist.
6. Es soll Vorwissen eingebracht werden können, um z.B. die Vorteile der Watershed Segmentierung und der Stammdetektion nutzen zu können.

Ein einfacher Ansatz, der bereits von [Morsdorf et al. \[2003\]](#) für die 3D Segmentierung von Bäumen verwendet wurde, ist der K-Means Algorithmus. Hier wird die Summe der Distanzen der Punkte im Merkmalsraum zu den Clusterzentren iterativ minimiert. Der Nachteil hierbei ist, dass Startpositionen für die Clusterzentren notwendig sind und somit die Anzahl der Segmente bekannt sein muss. Außerdem sind die Ergebnisse stark von der Wahl dieser Anfangswerte abhängig. [Morsdorf et al. \[2003\]](#)

verwenden die lokalen Maxima im CHM zur Initialisierung. Somit erhält man zwar echte 3D Segmente als Ergebnisse, deren Anzahl und Positionen sich jedoch auf die lokalen Maxima beziehen. Gegenüber der 2D Watershed Segmentierung wird somit nicht viel gewonnen. Wang et al. [2008] gehen einen Schritt weiter und unterteilen den Waldbereich in horizontale Schichten. In jeder Schicht wird eine 2D Segmentierung mit morphologischen Methoden durchgeführt. Die Ergebnisse der einzelnen Schichten werden dann zu einem 3D Modell gruppiert. Dadurch können auch Bäume gefunden werden, die im CHM kein eigenes lokales Maximum besitzen. Das limitierende Element bei dieser Methode ist eine korrekte Detektion der Baumspitzen als Voraussetzung für eine erfolgreiche Segmentierung.

Über den Einsatz graphentheoretischer Algorithmen zur Segmentierung von Bäumen ist aus der Literatur bis jetzt nichts bekannt, obwohl diese insbesondere im „Computer Vision“ Bereich weit verbreitet sind. Bei diesen Verfahren wird das Segmentierungsproblem mit Hilfe eines graphenbasierten Modells gelöst, das sich aus Knoten und Kanten zusammensetzt. Dabei wird der Gesamtgraph an Hand vorgegebener Kriterien in Subgraphen unterteilt, welche die einzelnen Segmente repräsentieren. Die Herausforderung besteht in der Festlegung geeigneter Kriterien, nach denen entschieden wird, welche Knoten zu welchen Subgraphen gehören. Ein Beispiel hierfür ist das sog. „Minimum Cut“ Verfahren [Wu & Leahy, 1993], in dem die Segmentierung so erfolgt, dass die Ähnlichkeit zwischen den entstehenden Segmenten minimal ist. Da hier jedoch die Bildung kleiner, isolierter Segmente bevorzugt wird, ist diese Methode für die Unterteilung von Waldstrukturen nicht geeignet. Beim sog. „Normalized Cut“ Verfahren hingegen tritt dieser Nachteil nicht auf, weil hier neben der Minimierung der Ähnlichkeit zwischen den Segmenten eine Maximierung der Ähnlichkeit innerhalb der Segmente angestrebt wird. Das von [Shi & Malik, 2000] sehr allgemein formulierte Verfahren ist dazu in der Lage, die oben genannten Anforderungen für die Segmentierung von Bäumen zu erfüllen. Jedoch ist eine Erweiterung und Anpassung an das konkrete 3D Problem notwendig, weil das Verfahren für den 2D Fall konzipiert wurde.

3.3.2 Grundlagen der Normalized Cut Segmentierung

Bei dieser graphenbasierten Segmentierung wird die Menge von Punkten in einem beliebigen Merkmalsraum als gewichteter, ungerichteter Graph $G = (V, E)$ dargestellt. Hierbei bezeichnet V die Menge aller Knoten und E die Menge aller Kanten, wobei pro Knotenpaar ij eine Kante mit dem Kantengewicht w_{ij} existiert. Bei einem digitalen Bild entsprechen die Knoten den Bildpixeln und w_{ij} beschreibt die Ähnlichkeit zwischen den entsprechenden Pixeln (Abbildung 3.10). Im 3D Fall sind die Pixel durch Voxel zu ersetzen.

Die Berechnung des Kantengewichts kann auf unterschiedliche Weise erfolgen und hängt von der Anwendung ab. Zum Beispiel wird w_{ij} für die Segmentierung von Grauwertbildern so berechnet, dass dieser Wert mit zunehmender Distanz zwischen den Pixeln oder höherem Grauwertunterschied abnimmt. Sehr kleine Gewichte werden häufig auf Null gesetzt, um eine sparsamere Repräsentation des Graphen hinsichtlich der programmtechnischen Umsetzung zu erreichen.

Das Ziel der Normalized Cut Segmentierung ist die Aufteilung von V in disjunkte Teilmengen A und B (Abbildung 3.11a), wobei die Ähnlichkeit der Elemente innerhalb von A und B maximal und die Ähnlichkeit zwischen A und B minimal sein soll. Diese beiden Kriterien lassen sich nach Shi & Malik [2000] in einer Kostenfunktion folgendermaßen formulieren:

$$NCut(A, B) = \frac{Cut(A, B)}{Assoc(A, V)} + \frac{Cut(A, B)}{Assoc(B, V)} \quad (3.4)$$

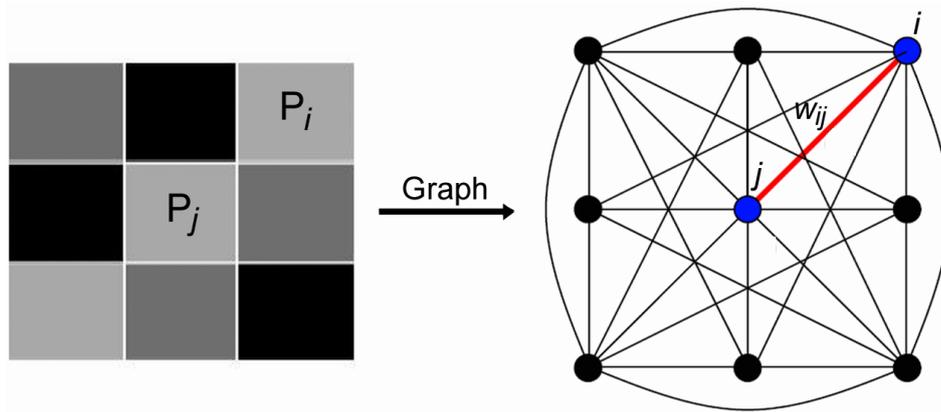
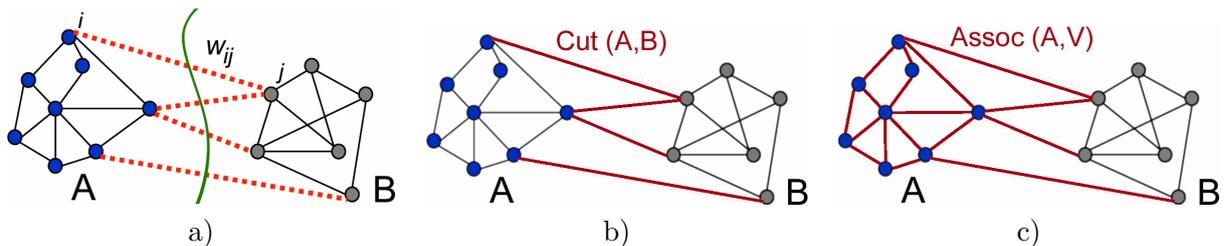


Abbildung 3.10: Repräsentation eines Bildes als voll verbundener Graph mit Knoten und Kanten

Hierbei ist $Cut(A, B) = \sum_{i \in A, j \in B} w_{ij}$ die Summe der Gewichte zwischen den Segmenten A und B

(Abbildung 3.11b). Der Term $Assoc(A, V) = \sum_{i \in A, j \in V} w_{ij}$ repräsentiert die Summe der Gewichte

aller Kanten, die im Segment A mindestens einen Endpunkt haben (Abbildung 3.11c). $Assoc(B, V)$ ist entsprechend für das Segment B definiert. Das Problem der Minimierung von $NCut(A, B)$ ist

Abbildung 3.11: Bildung von Segmenten beim Normalized Cut Verfahren. a) Aufteilung von V in A und B , b) Gewichte zwischen A und B , c) Gewichte mit Endpunkt im Segment A

nach Shi & Malik [2000] NP-vollständig. Jedoch kann eine Näherungslösung effizient mit Hilfe einer Eigenwertaufgabe berechnet werden. Dazu muss das $NCut$ Kriterium mit Hilfe von Matrizen formuliert werden. Benötigt werden dabei folgende Komponenten:

- Indikatorvektor \mathbf{x} mit $n = |V|$ Elementen, wobei gilt: $\mathbf{x}_i = \begin{cases} +1, & \mathbf{x}_i \in A \\ -1, & \mathbf{x}_i \in B \end{cases}$

Die Elemente von \mathbf{x} zeigen für jeden Knoten binär an, welchem Segment der Knoten zugeordnet werden soll.

- Gewichtsmatrix \mathbf{W} mit Dimension $n \times n$, wobei $\mathbf{W}(i, j) = w_{ij}$

In den Zeilen und Spalten von \mathbf{W} sind die Knoten 1 bis n aufgetragen. \mathbf{W} enthält somit das Gewicht jedes Knotens zu jedem anderen Knoten. Die Zeile i enthält beispielsweise alle Kantengewichte, die vom Knoten i ausgehen. \mathbf{W} ist von Natur aus symmetrisch und positiv semidefinit. Wenn die Gewichte nur in einer festen lokalen Umgebung zur Kante berechnet werden, ist \mathbf{W} dünn besetzt.

- Degreematrix \mathbf{D} mit Dimension $n \times n$, wobei $\mathbf{D}(i, i) = \mathbf{d}_i = \sum_j w_{ij}$

Die Matrix \mathbf{D} ist eine Diagonalmatrix, welche den Grad jedes Knotens auf dem entsprechenden Diagonalelement speichert. \mathbf{D} kann direkt aus \mathbf{W} berechnet werden.

Mit Hilfe der Definitionen von \mathbf{x} und \mathbf{d} kann die Gleichung 3.4 umgeschrieben werden:

$$NCut(A, B) = \frac{\sum_{(\mathbf{x}_i > 0, \mathbf{x}_j < 0)} -w_{ij} \mathbf{x}_i \mathbf{x}_j}{\sum_{\mathbf{x}_i > 0} \mathbf{d}_i} + \frac{\sum_{(\mathbf{x}_i < 0, \mathbf{x}_j > 0)} -w_{ij} \mathbf{x}_i \mathbf{x}_j}{\sum_{\mathbf{x}_i < 0} \mathbf{d}_i} \quad (3.5)$$

Sei nun $\mathbf{1}$ ein n -dimensionaler Vektor mit allen Elementen gleich 1 und

$$k = \frac{\sum_{\mathbf{x}_i > 0} \mathbf{d}_i}{\sum_i \mathbf{d}_i}, \quad (3.6)$$

dann lässt sich das $NCut$ Kriterium folgendermaßen formulieren:

$$NCut(A, B) = \frac{(\mathbf{1} + \mathbf{x})^T (\mathbf{D} - \mathbf{W}) (\mathbf{1} + \mathbf{x})}{k \mathbf{1}^T \mathbf{D} \mathbf{1}} + \frac{(\mathbf{1} - \mathbf{x})^T (\mathbf{D} - \mathbf{W}) (\mathbf{1} - \mathbf{x})}{(1 - k) \mathbf{1}^T \mathbf{D} \mathbf{1}} \quad (3.7)$$

Zahlreiche mathematische Umformungen nach Shi & Malik [2000] führen zu folgender Schreibweise:

$$NCut(A, B) = \frac{\mathbf{y}^T (\mathbf{D} - \mathbf{W}) \mathbf{y}}{\mathbf{y}^T \mathbf{D} \mathbf{y}}, \quad \text{mit } \mathbf{y} = (\mathbf{1} + \mathbf{x}) - b(\mathbf{1} - \mathbf{x}) \text{ und } b = \frac{k}{1 - k} \quad (3.8)$$

Zur Formulierung der Gleichung 3.8 sind die beiden folgenden Randbedingungen notwendig:

$$1: \mathbf{y}_i \in \{1, -b\}; \quad 2: \mathbf{y}^T \mathbf{D} \mathbf{1} = 0 \quad (3.9)$$

Der Vorteil der Gleichung 3.8 liegt darin, dass die Minimierung von $NCut(A, B)$ durch Lösung des allgemeinen Eigenwertsystems

$$(\mathbf{D} - \mathbf{W}) \mathbf{y} = \lambda \mathbf{D} \mathbf{y} \quad (3.10)$$

erreicht werden kann und somit eine effiziente Berechnung der Segmentierungsergebnisse möglich wird. In [Shi & Malik, 2000] wird gezeigt, dass der zum zweit kleinsten Eigenwert λ_1 gehörige Eigenvektor \mathbf{y}_1 der Lösungsvektor des Minimierungsproblems ist und hierbei die zweite Randbedingung von 3.9 exakt erfüllt wird. Die erste Randbedingung fordert, dass \mathbf{y}_1 nur zwei diskrete Werte annehmen darf und somit ein Indikatorvektor für die Zuordnung der Knoten zu den Segmenten ist. Diese Bedingung ist nicht erfüllt, weil \mathbf{y}_1 bei der Lösung des Eigenwertsystems reellwertig wird. Somit minimiert diese Lösung das $NCut$ Kriterium nicht exakt, sondern nur näherungsweise. Um eine eindeutige Zuordnung der Knoten zu den unterschiedlichen Segmenten zu ermöglichen, ist eine nachträgliche Diskretisierung von \mathbf{y}_1 notwendig. Einzelheiten zur Diskretisierung sind im Abschnitt 3.3.5 erläutert.

An dieser Stelle soll noch näher darauf eingegangen werden, welche Bedeutung die Wahl der Kostenfunktion (Gleichung 3.4) im Hinblick auf das Segmentierungsergebnis hat. Wie oben schon erwähnt, wird bei der Normalized Cut Segmentierung die Ähnlichkeit zwischen den Segmenten minimiert, wobei gleichzeitig die Ähnlichkeit innerhalb der Segmente maximiert wird. Das Minimum Cut Verfahren [Wu & Leahy, 1993] hingegen minimiert lediglich die Ähnlichkeit zwischen den Segmenten. Die Kostenfunktion ist in diesem Fall einfach $Cut(A, B) = \sum_{i \in A, j \in B} w_{ij}$, also die Summe der Gewichte zwischen den Segmenten. Der Nachteil hierbei ist, dass bevorzugt kleine Segmente gebildet werden, die aus

isolierten Knoten bestehen, weil $Cut(A, B)$ naturgemäß mit der Anzahl der Kanten zwischen den Segmenten steigt. Dies wird beim Normalized Cut Kriterium durch die Normalisierung mit $Assoc(A, V)$ bzw. $Assoc(B, V)$ überwunden, da nun die Kostenfunktion zusätzlich durch eine steigende Summe der Gewichte, bzw. eine hohe Ähnlichkeit innerhalb der Segmente, reduziert wird. Die Abbildung 3.12 verdeutlicht diesen Unterschied. Bei einer Gewichtung der Kanten invers proportional zum Knotenabstand gliedert das Minimum Cut Verfahren die beiden rechten Knoten als eigene Segmente aus. Das Normalized Cut Verfahren hingegen trennt die dichten von den weniger dichten Punkten, was ein wesentlich besseres Segmentierungsergebnis ist. Bei der Entscheidung für ein Verfahren zur Seg-

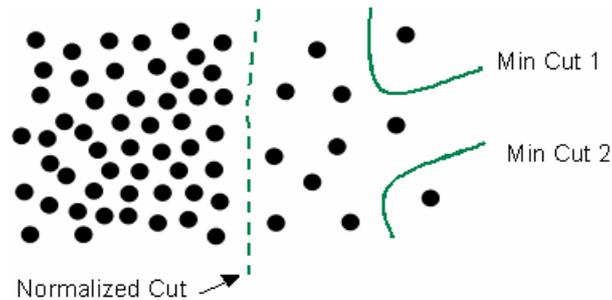


Abbildung 3.12: Vergleich von „Minimum Cut“ und „Normalized Cut“ anhand eines Beispiels [Shi & Malik, 2000]

mentierung von Bäumen spricht gerade dieses Verhalten sehr für das NCut Verfahren. Denn es sollen keine einzelnen Laserpunkte abgetrennt werden, sondern Laserreflexionen mit ähnlichen Eigenschaften zu Baumsegmenten zusammengefasst werden.

3.3.3 Voxelbildung

Für die Anwendung des Normalized Cut Verfahrens zur Baumsegmentierung wird der Waldbereich in eine Voxelstruktur mit $N_V = N_{V_x} \times N_{V_y} \times N_{V_z}$ Voxel aufgeteilt. Für jedes Voxel mit der Kantenlänge L_V wird nach darin enthaltenen Reflexionen $\mathbf{X}_i^T = (x_i, y_i, z_i, W_i, I_i)$ gesucht, was zu einer binären Unterteilung der N_V Voxel in belegte und unbelegte führt. Die belegten Voxel werden in das Segmentierungsverfahren als Knoten V eingeführt. Da die entstehenden Segmente nur Reflexionen von Bäumen beinhalten sollen, werden die Bodenpunkte analog zu Abschnitt 3.2.2 gefiltert und bleiben unberücksichtigt. Als Beispiel ist in der Abbildung 3.13 die Voxelbildung und eine Aufteilung der belegten Voxel in einzelne Segmente zu sehen. Zur besseren Visualisierung der Voxelkanten ist L_V in der Abbildung 3.13a auf einen höheren Wert gesetzt (2 m) als bei der Segmentierung verwendet. In 3.13b und 3.13c beträgt L_V nur 0.5 m, was sich in einer detaillierten Abbildung der Bäume widerspiegelt.

Theoretisch könnte das Normalized Cut Verfahren sogar direkt die Rohdatenpunkte verarbeiten, so dass die Aufteilung in Voxel nicht notwendig wäre. Die Voxel haben jedoch den Vorteil, dass lokale Schwankungen der Punktdichte auf Grund der Geometrie bei der Datenerfassung weitgehend reduziert werden. Außerdem kann die Datenmenge je nach notwendigem Detaillierungsgrad durch die Wahl von L_V gesteuert und verringert werden.

Nach Abschluss der Segmentierung können den Voxeln in gleicher Weise wieder die Reflexionen \mathbf{X} zugeordnet werden, so dass insgesamt bei der Segmentierung kein Datenverlust entsteht und die Originaldaten für eine Ableitung forstlicher Parameter aus den Segmenten verwendet werden können.

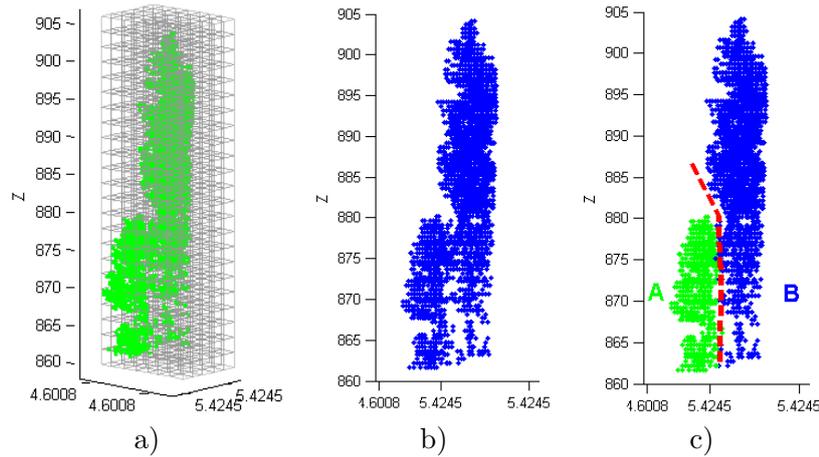


Abbildung 3.13: Voxelbildung und Aufteilung in Segmente. a) Reflexionen zweier Bäume überlagert mit dem Voxelgitter, b) Voxel, die Reflexionen enthalten, c) Aufteilung der Voxel in Segmente

3.3.4 Ähnlichkeitsfunktion

Entscheidend für den Erfolg der Segmentierung ist das Vorhandensein geeigneter Gewichte w_{ij} zwischen den Voxeln i und j . Dabei soll w_{ij} für Voxel, die zu demselben Baum gehören, möglichst groß und für Voxel verschiedener Bäume möglichst klein sein. Um dies zu erreichen wurde folgende Ähnlichkeitsfunktion formuliert, die w_{ij} innerhalb eines Zylinders mit Radius R_{XY} um das Voxel i berechnet:

$$w_{ij} = \begin{cases} e^{-\mathbf{X}(i,j)} \times e^{-\mathbf{Z}(i,j)} \times e^{-\mathbf{F}(i,j)} \times e^{-\mathbf{G}(i,j)} & \text{falls } D_{XY_{ij}} < R_{XY} \\ 0 & \text{andernfalls} \end{cases} \quad (3.11)$$

Hierbei ist:

$$\mathbf{X}(i, j) = \left(\frac{D_{XY_{ij}}}{\sigma_{xy}}\right)^2, \quad \mathbf{Z}(i, j) = \left(\frac{D_{Z_{ij}}}{\sigma_z}\right)^2, \quad \mathbf{F}(i, j) = \left(\frac{|\mathbf{f}_i - \mathbf{f}_j|}{\sigma_f}\right)^2, \quad \mathbf{G}(i, j) = \left(\frac{G_{ij}^{\max}}{\sigma_G}\right)^2 \quad (3.12)$$

Hinter der Funktion 3.11 steckt die Idee, verschiedene Einflüsse auf die Gewichtung multiplikativ zu kombinieren. Durch die Verwendung der Exponentialfunktionen ergibt sich für w_{ij} ein Wertebereich zwischen 0 und 1.

Die Komponenten $e^{-\mathbf{X}(i,j)}$ und $e^{-\mathbf{Z}(i,j)}$ gewichten - ähnlich wie im Beispiel der Abbildung 3.12 - den Euklidischen Abstand zwischen den Voxeln, wodurch ein steigender Abstand zu einer Verkleinerung von w_{ij} führt. Die horizontale Distanz $D_{XY_{ij}}$ und die vertikale Distanz $D_{Z_{ij}}$ werden getrennt behandelt, weil Bäume in der Regel höher sind als breit, und somit eine Vergrößerung des vertikalen Abstands zu einer geringeren Abschwächung von w_{ij} führen muss wie die gleiche Vergrößerung des horizontalen Abstands. Hier wird also implizit Wissen über das Aussehen von Bäumen verwendet.

Die Komponente $e^{-\mathbf{F}(i,j)}$ gewichtet den Euklidischen Abstand zwischen zwei beliebigen Merkmalsvektoren \mathbf{f}_i und \mathbf{f}_j der Voxel i und j . Es werden also Merkmale benötigt, die eine Unterscheidung der einzelnen Bäume unterstützen. Verwendet werden hierzu die Attribute Intensität und Pulsbreite, aus denen die Mittelwerte

$$I_M = \frac{1}{N} \sum_{k \in U} I_k \quad \text{und} \quad W_M = \frac{1}{N} \sum_{k \in U} W_k, \quad (3.13)$$

für N Reflexionen innerhalb einer bestimmten Umgebung U um das jeweilige Voxel berechnet werden. Da I_k und W_k wegen der inhomogenen Struktur eines Baums von Reflexion zu Reflexion stark variieren,

sollte U ausreichend groß gewählt werden, um einen Glättungseffekt zu erzielen. Um die Merkmale mit ihren unterschiedlichen Wertebereichen in dem gemeinsamen Merkmalsvektor vergleichbar machen zu können, ist eine Normierung der Merkmale auf denselben Wertebereich notwendig. Sinnvoll ist z.B. eine lineare Anpassung auf das Intervall $[0, 1]$.

Der letzte Term $e^{-G(i,j)}$ macht es möglich, bekannte Baumpositionen $\mathbf{X}_{\text{apriori}}$ als Vorwissen in das Verfahren einfließen zu lassen. Die Idee dahinter ist, Ergebnisse der Watershed Segmentierung und der Stammdetektion vorteilhaft zu nutzen. Die mit diesen Verfahren gefundenen Baumpositionen sind wegen der oben genannten Beschränkungen dieser Verfahren nicht vollständig, aber sehr zuverlässig. Beispielsweise ist von der Watershed Segmentierung her bekannt, dass bei einem lokalen Maximum im CHM mit hoher Wahrscheinlichkeit ein dominanter Baum steht. Ebenso deutet ein gefundener Stamm auf eine richtige Baumposition hin. Um zu modellieren, dass Voxel in der Nähe von $\mathbf{X}_{\text{apriori}}$ höchstwahrscheinlich zu einem Baum gehören, werden zwei Voxel i und j in Abhängigkeit ihrer maximalen horizontalen Entfernung G_{ij}^{\max} zu $\mathbf{X}_{\text{apriori}}$ gewichtet (Abbildung 3.14).

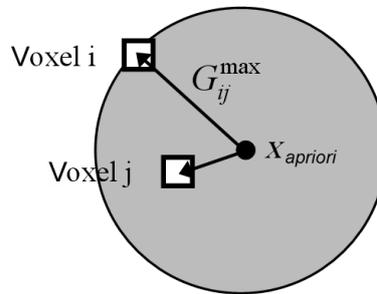


Abbildung 3.14: Gewichtung in Abhängigkeit von der Entfernung zu $\mathbf{X}_{\text{apriori}}$

Die Parameter σ_{xy} , σ_z , σ_f und σ_G dienen zur Kontrolle der Sensitivität von $D_{XY_{ij}}$, $D_{Z_{ij}}$, $|\mathbf{f}_i - \mathbf{f}_j|$ und G_{ij}^{\max} gegenüber den einzelnen Faktoren der Funktion 3.11 und somit auch gegenüber w_{ij} . Zum Beispiel wird in der Abbildung 3.15 der Einfluss verschiedener Werte für σ_f auf $e^{-\mathbf{F}(i,j)}$ dargestellt. Je höher die Werte für σ_f sind, desto langsamer nimmt das Gewicht bei steigender Merkmalsdifferenz ab. Auf diese Weise wird auch eine unterschiedliche Gewichtung von $D_{XY_{ij}}$ und $D_{Z_{ij}}$ erreicht.

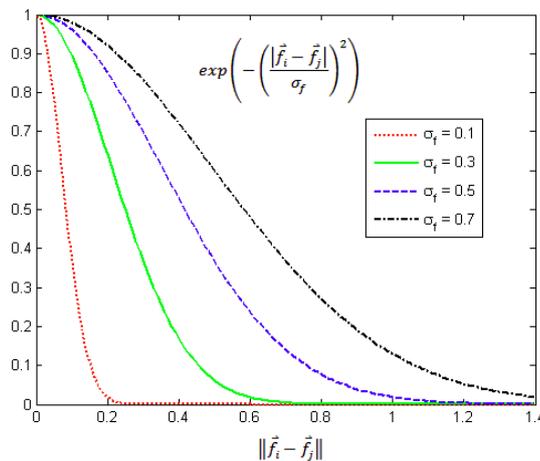


Abbildung 3.15: Einfluss von σ_f auf die Werte von $e^{-\mathbf{F}(i,j)}$

3.3.5 Diskretisierung des Lösungsvektors

Nach Berechnung der Gewichte zwischen den Voxeln können die Matrizen \mathbf{D} und \mathbf{W} aufgestellt werden. Die Lösung des Eigenwertsystems 3.10 führt zum gesuchten Eigenvektor \mathbf{y}_1 , der jedoch reellwertig ist und so diskretisiert werden muss, dass dessen Elemente nur zwei unterschiedliche Werte annehmen. Nur mit Hilfe dieses Indikatorvektors ist eine eindeutige Zuordnung der Voxel zu den Segmenten A und B möglich. In der Arbeit von Shi & Malik [2000] werden folgende Möglichkeiten für die Wahl eines geeigneten Schwellwertes y_{split} zur Aufspaltung von \mathbf{y}_1 genannt: Am einfachsten ist es, y_{split} auf 0 oder den Median von \mathbf{y}_1 zu setzen. Man kann jedoch auch verschiedene Werte für y_{split} testen und den Wert auswählen, der den kleinsten Wert für $NCut(A, B)$ verursacht. Hierfür eignet sich ein schrittweises Vorgehen im Wertebereich von \mathbf{y}_1 . Zur Berechnung von $NCut(A, B)$ kann z.B. die Gleichung 3.8 verwendet werden. Die Abbildung 3.16 veranschaulicht die zuletzt genannte Vorgehensweise anhand eines realen Beispiels für die Segmentierung zweier Bäume. In den Grafiken der

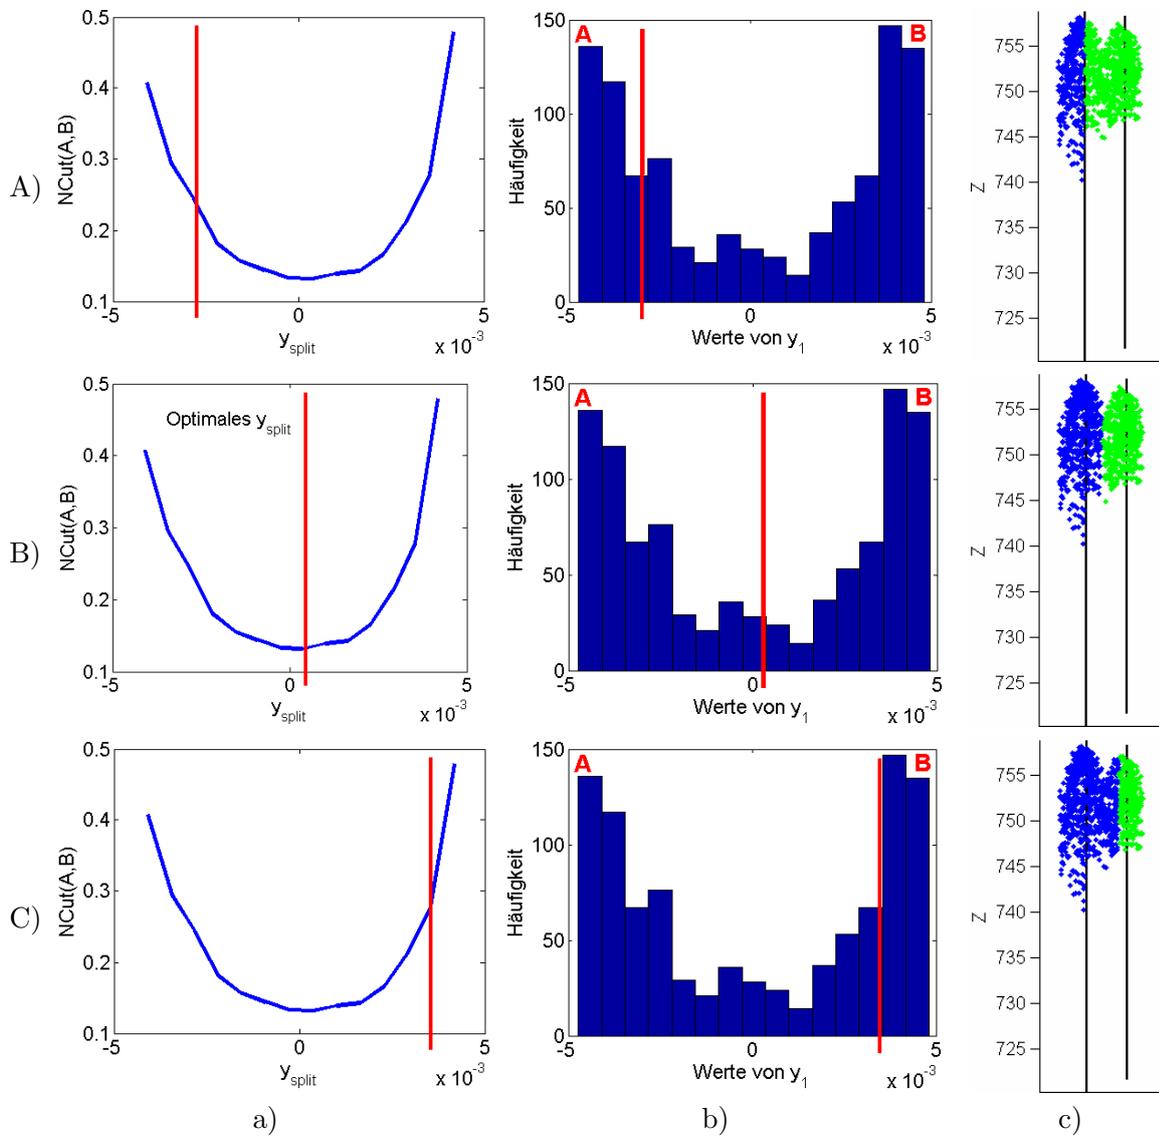


Abbildung 3.16: Beispiel für die optimale Wahl von y_{split} bei der Diskretisierung von \mathbf{y}_1

Spalte a) ist $NCut(A, B)$ in Abhängigkeit von y_{split} aufgetragen. Für die Berechnung von $NCut(A, B)$ werden 15 Werte für y_{split} verwendet, die gleichmäßig über den Wertebereich von y_1 verteilt sind. Die Spalte b) enthält das Histogramm von y_1 bei derselben Aufteilung des Wertebereichs. In der Spalte c) sieht man die Reflexionen der beiden Bäume und deren Trennung in zwei Segmente. Hierbei sind in den Zeilen A) bis C) drei Fälle mit einer unterschiedlichen Wahl von y_{split} dargestellt. Der jeweilige Wert von y_{split} ist in a) und b) durch einen roten Balken markiert. Man sieht, dass nur in der Zeile B) ein gutes Ergebnis erzielt wird, also wenn y_{split} beim Minimum von $NCut(A, B)$ liegt.

Bei dem Beispiel der Abbildung 3.16 ist die Segmentierung auch dann erfolgreich, wenn y_{split} einfach auf 0 gesetzt wird. Es treten jedoch auch Fälle auf, bei denen das optimale y_{split} deutlich von 0 abweicht (Abbildung 3.17). Der schrittweise Test von y_{split} ist daher die bessere Lösung.

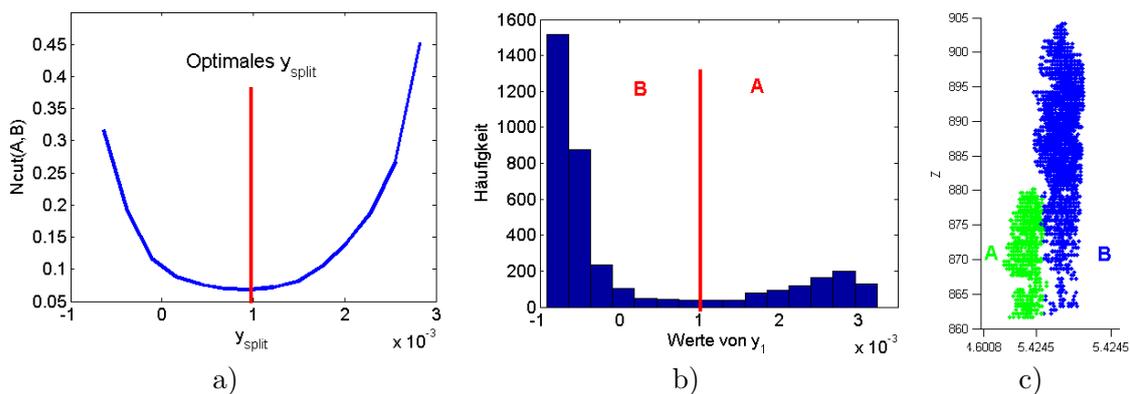


Abbildung 3.17: Beispiel für einen von Null abweichenden Parameter y_{split}

3.3.6 Hierarchisches Ablaufschema

In den bisherigen Betrachtungen wurde die optimale Aufteilung der Knoten V in zwei Teilmengen A und B behandelt. Bei der Anwendung im Waldbereich ist jedoch eine Zweiteilung nicht ausreichend, da die Segmentierung auf ein Gebiet mit unbekannter Anzahl von Bäumen angewandt wird. Das Verfahren muss also mehr als zwei Segmente bilden können und deren Anzahl automatisch bestimmen. Für die Erzeugung mehrerer Segmente bietet das Normalized Cut Verfahren zwei Möglichkeiten. Zum einen können neben y_1 auch die zu den nächstgrößeren Eigenwerten gehörigen Eigenvektoren y_2 bis y_n genutzt werden. Hierbei splittet der Vektor $y_k (k = 2 \dots n)$ jeweils die mit dem Vektor y_{k-1} erzeugten Segmente in zwei Teile auf, so dass insgesamt 2^n Segmente entstehen. Der Vorteil dabei ist, dass die Lösung des Eigenwertsystems (3.10) nur einmal erforderlich ist. Nachteilig ist jedoch, dass sich die Diskrepanzen zwischen reellwertiger und diskreter Lösung bei jeder Zweiteilung aufsummieren, so dass die Ergebnisse der höheren Eigenvektoren immer unzuverlässiger werden. In [Shi & Malik, 2000] wird deshalb die zweite Möglichkeit, der sog. „rekursive Two-Way Ncut“ empfohlen. Hier wird das Eigenwertsystem für jede Teilung neu gelöst und nur jeweils y_1 verwendet. Das bedeutet zwar auf den ersten Blick einen viel höheren Rechenaufwand, jedoch gibt es Lösungsmethoden für Eigenwertaufgaben, die darauf ausgerichtet sind, nur ein paar ausgewählte Eigenwerte effizient zu bestimmen. Da W symmetrisch, positiv semidefinit und meist nur schwach besetzt ist, eignet sich das Lanczos Verfahren hierfür. Eine Implementierung dieser Methode wird von Baglama et al. [2003] beschrieben. Die Segmentierung eines bestimmten Waldbereichs läuft dann nach folgendem hierarchischen Schema ab:

1. Aufteilung des Bereichs in Voxel (Abschnitt 3.3.3)
2. Erzeugung des Graphen G durch Berechnung der Matrizen \mathbf{W} und \mathbf{D} (Abschnitte 3.3.2 und 3.3.4).
3. Lösung des allgemeinen Eigenwertsystems (3.10).
4. Diskretisierung des Lösungsvektors \mathbf{y}_1 (Abschnitt 3.3.5), so dass zwei Segmente und somit zwei neue Graphen G_1 und G_2 entstehen
5. Berechnung von $NCut(A, B)$ z.B. mit der Gleichung 3.8 und Test, ob ein vorgegebener Schwellwert $NCut_{max}$ unterschritten wird
6. Je nach Zutreffen obiger Bedingung werden folgende Fälle unterschieden:
 - a) $NCut_{max}$ wird überschritten: Entstandene Segmente werden nicht akzeptiert, die Voxel vor der Teilung bilden das Ergebnis
 - b) $NCut_{max}$ wird unterschritten: Entstandene Segmente werden akzeptiert und getestet, ob sie eine bestimmte Mindestzahl N_{minV} von Voxel beinhalten
 - i. Segmente mit weniger als N_{minV} Voxel werden nicht weiter bearbeitet und bilden das Ergebnis
 - ii. Segmente mit mehr oder gleich N_{minV} Voxel werden weiter bearbeitet. Das Schema wird ab dem 3. Schritt auf die Graphen dieser Segmente angewandt.
7. Endgültigen Segmenten werden die ursprünglichen Reflexionen \mathbf{X} wieder zugeordnet (Abschnitt 3.3.3)

Die Anzahl der entstehenden Segmente kann im Wesentlichen mit dem Schwellwert $NCut_{max}$ gesteuert werden. Die Bedingung von mindestens N_{minV} Voxel im Segment soll verhindern, dass sehr kleine Segmente nochmals geteilt werden.

In der Abbildung 3.18 ist ein Beispiel für die Anwendung des obigen Schemas auf einen Bereich mit fünf Bäumen dargestellt, deren Referenzpositionen und -höhen durch schwarze Linien repräsentiert werden. Die Grafiken der ersten Zeile zeigen die Segmentierungsergebnisse für jede Rekursion. In der zweiten Zeile markiert der untere Balken den jeweils resultierenden Wert für $NCut(A, B)$ und der obere Balken den Wert für $NCut_{max}$. Beim ersten Durchlauf des Schemas (Spalte b) entstehen zwei Segmente, von denen das eine zwei und das andere drei Bäume enthält. Anschließend wird jedes dieser Segmente nochmal geteilt, so dass sich vier Segmente ergeben (Spalte d). Bei einer nochmaligen Teilung wird mit $NCut(A, B) = 0.12$ nur beim rechten Segment von d) der Schwellwert $NCut_{max} = 0.16$ unterschritten. Es entstehen somit fünf Segmente (Spalte e), die gut zu den Referenzbäumen passen. Die Wahl von $NCut_{max}$ ist für das Ergebnis entscheidend, weil bei einem zu kleinen Wert mehrere Bäume zusammengefasst werden, ein zu großer Wert jedoch eine Übersegmentierung verursacht. In diesem Beispiel entsteht eine korrekte Segmentierung, wenn $NCut_{max}$ zwischen 0.12 und 0.22 liegt, weil innerhalb dieses Bereichs keine Teilung stattfindet. Erst bei 0.22 würde ein sechstes Segment entstehen.

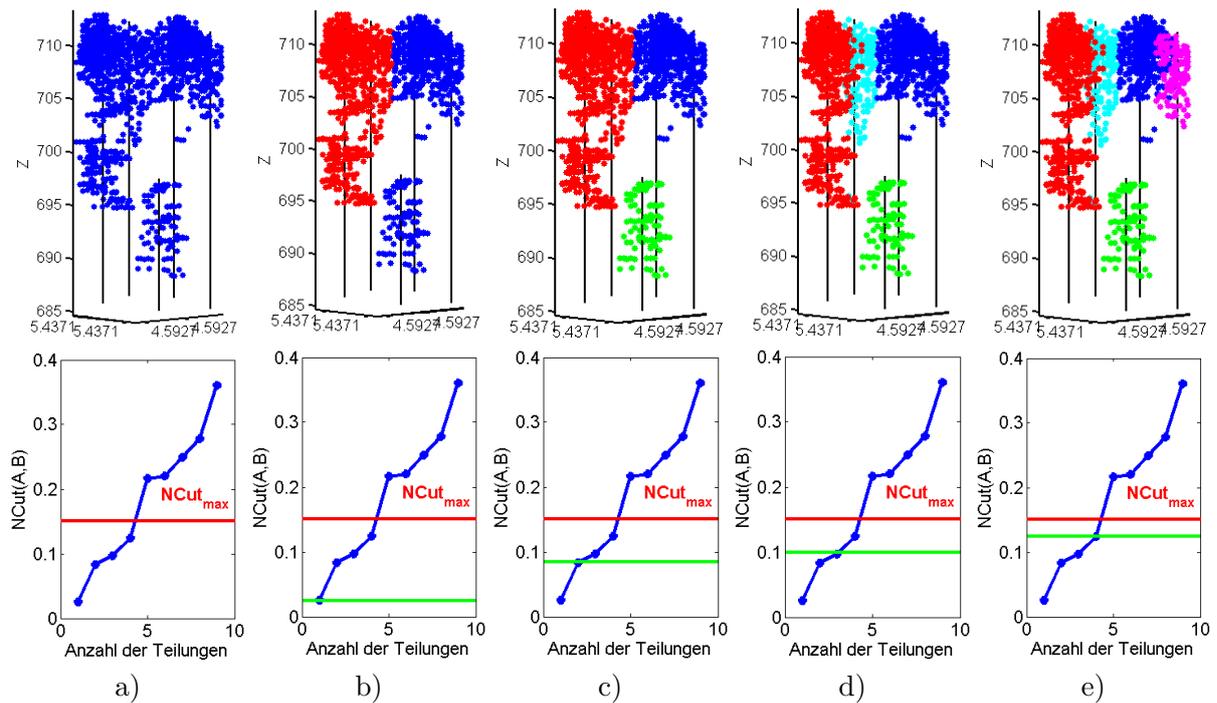


Abbildung 3.18: Beispiel für rekursiven Two-Way Ncut

3.3.7 Nachbearbeitung der Segmente

Die Ergebnisse der Normalized Cut Segmentierung werden noch in einfacher Weise nachbearbeitet. Zum einen werden Segmente, die viel zu klein sind, um einen eigenen Baum zu repräsentieren, eliminiert. Als Kriterium wird eine Mindestanzahl von Voxel verwendet, die von der Höhe des Segments abhängig ist. Für Segmente unter einer Höhe von H_{V1V2} gilt der Schwellwert $S_{\min V1}$ und für höhere Segmente der Schwellwert $S_{\min V2}$. Zum anderen werden die Segmente auf vertikale Lücken überprüft. Besitzt ein Segment innerhalb eines Höhenbereichs von $H_{\text{Lücke}}$ keine Reflexionen, so werden die Reflexionen oberhalb der Lücke aus dem Segment entfernt. Der Grund für diese Vorgehensweise ist, dass manchmal Reflexionen überhängender Äste in den Segmenten darunter stehender kleinerer Bäume enthalten sind und diese verfälschen. Diese Methode wird nur ab einer Höhe von $H_{\min L}$ angewendet, weil im unteren Baumbereich solche Lücken häufiger auftreten und dort normal sind.

3.3.8 Vorteile der 3D Segmentierung gegenüber der Watershed Segmentierung und der Stammdetektion

Die 3D Segmentierung der Bäume bietet gegenüber der Watershed Segmentierung und der Stammdetektion wichtige methodische Erweiterungen. Es lassen sich dadurch Bäume segmentieren, die kein eigenes lokales Maximum im CHM besitzen, weil sie kaum im CHM repräsentiert sind oder die Glättung ein eigenes Maximum unterdrückt. Beispiele dafür sind in der Abbildung 3.19 dargestellt. Mit der Stammdetektion können zwar auch solche Bäume teilweise gefunden werden, aber es erfolgt keine Zuordnung der Kronenpunkte zum Stamm. Außerdem ist die Stammdetektion nur bei Bäumen mit einer ausreichenden Anzahl gut isolierbarer Stammreflexionen möglich. Mit dem Normalized Cut Verfahren ist sogar die Segmentierung von Bäumen möglich, die nicht in das CHM eingehen. Die Abbildung 3.20 zeigt Beispiele für korrekte Segmente von Verjüngungen und verdeckten Bäumen. Ein weiterer

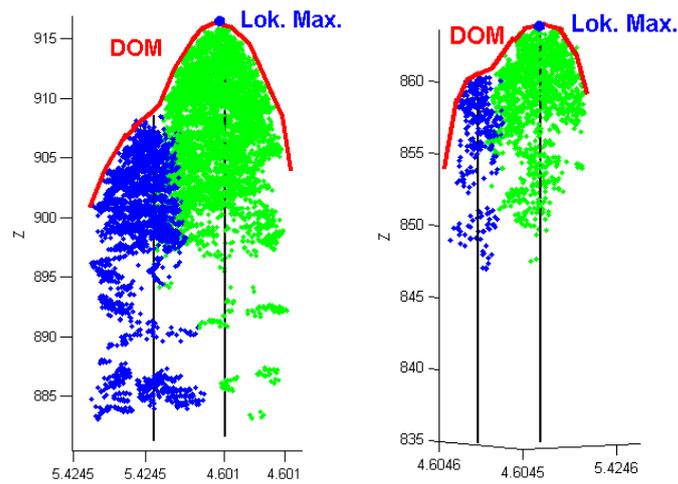


Abbildung 3.19: Segmentierung von Bäumen ohne eigenes lokales Maximum

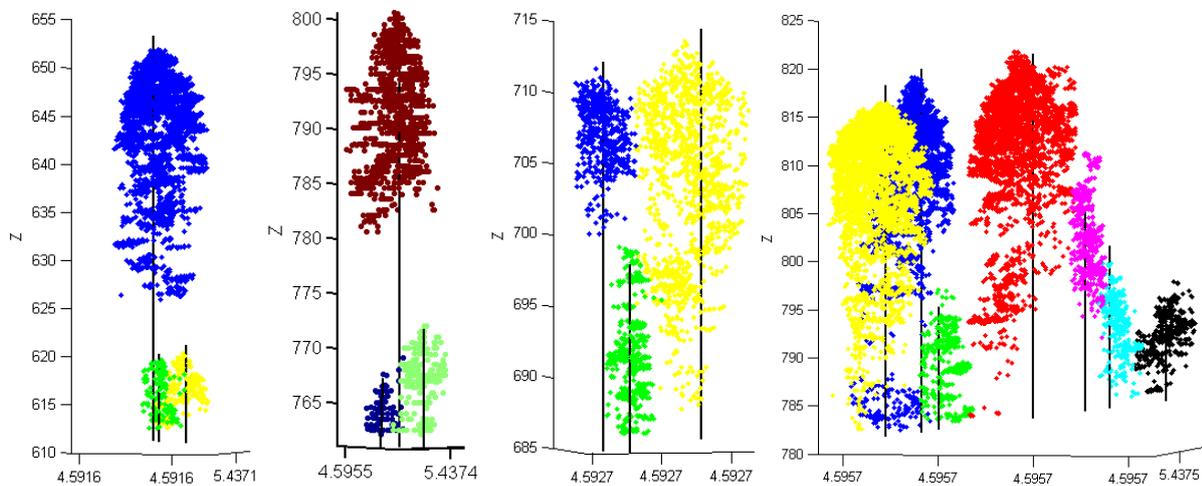


Abbildung 3.20: Segmentierung von Verjüngung und verdeckten Bäumen

Vorteil ist, dass die Bäume durch die 3D Segmente viel detaillierter abgebildet werden. Dies sollte sich positiv auf die Ableitung forstlicher Parameter, wie z.B. Kronenvolumen, Holzvolumen oder Biomasse auswirken. Da die Ergebnisse der Stammdetektion und der Watershed Segmentierung als Vorwissen in das 3D Verfahren eingebracht werden können, ist eine Nutzung dieser Methoden im Rahmen einer mehrstufigen Segmentierung möglich.

Kapitel 4

Baumartenklassifikation

Nach der Segmentierung der einzelnen Bäume können nun die für forstliche Auswertungen notwendigen Einzelbauminformationen aus den Segmenten abgeleitet werden (Abbildung 1.2b). Die Bestimmung der Baumart steht hierbei an erster Stelle, weil diese Information als Eingangsgröße für die Berechnung weiterer Baumparameter (z.B. Stammdurchmesser, Holzvolumen) benötigt wird. In diesem Kapitel wird daher die Ableitung der Baumart aus den Reflexionen X_{Seg} im Segment beschrieben, was sich in zwei Hauptschritte gliedert. Zuerst werden geeignete Merkmale berechnet, die eine Unterscheidung der Baumarten mit Hilfe der Laserdaten erlauben [Reitberger et al., 2006b, 2008b]. Anschließend folgt eine Klassifikation unter Verwendung dieser Merkmale [Reitberger et al., 2008a, 2009a]. Das Ziel ist eine möglichst genaue Trennung zwischen Laub- und Nadelbäumen sowohl im belaubten als auch im unbelaubten Zustand unter Nutzung der Zusatzinformationen aus den Waveforms. Bei Verwendung von First/Last-Pulse Daten gelingt das bisher nur im unbelaubten Zustand [Heurich, 2006]. Die in diesem Kapitel beschriebenen Methoden können ebenso für eine Feinunterscheidung von Baumarten, wie zwischen Tanne und Fichte oder zwischen Buche und Ahorn, eingesetzt werden. Jedoch dürfen hier die Erwartungen nicht zu hoch angesetzt werden, weil sich diese Baumarten sehr ähnlich sind.

4.1 Extraktion von Merkmalen

Für die Berechnung geeigneter Merkmale müssen Kriterien gefunden werden, die eine Unterscheidung der Baumarten mit Hilfe der Laserdaten erlauben. Baumartspezifische Eigenschaften von Bäumen, die aus Daten luftgestützter Full Waveform Laserscanner abgeleitet werden können, lassen sich in fünf Kategorien unterteilen:

- Die äußere Baumgeometrie kann mit den Merkmalen $S_g = \{S_g^1, S_g^2\}$ beschrieben werden. Hierbei steht S_g^1 für die Parameter eines Paraboloids, das an die Baumkrone angepasst wird. Die horizontale Ausdehnung der Baumkrone bei verschiedenen Höhenschichten wird durch das Merkmal S_g^2 charakterisiert.
- Die vertikale Verteilung des Baummaterials, hier auch als interne Baumstruktur bezeichnet, wird mit Hilfe der Merkmale $S_i = \{S_i^h, S_i^d\}$ ausgedrückt. Diese Merkmale stammen ursprünglich von Naesset [2004] und beschreiben die Höhen- und Dichteverteilung der Reflexionen im Segment.
- Die Reflexionseigenschaften des Materials spiegeln sich in den Merkmalen $S_r = \{S_r^1, S_r^2\}$ wider, welche sich aus der Intensität der Reflexionen im Segment zusammensetzen.

- Die Größe und Form der einzelnen Bauelemente wird durch das Merkmal S_W ausgedrückt, das die Pulsbreite der Reflexionen enthält.
- Die Durchdringbarkeit des Baums kann mit den Merkmalen $S_n = \{S_n^1, S_n^2\}$ beschrieben werden, welche die Anzahl der Reflexionen pro Waveform nutzen.

Die Berechnung der Merkmale $S_{\text{Baum}} = \{S_g, S_i, S_I, S_W, S_n\}$ pro Baumsegment wird in den folgenden Abschnitten näher erläutert.

4.1.1 Äußere Baumgeometrie

Zur Beurteilung der äußeren Baumgeometrie werden die beiden Merkmale S_g^1 und S_g^2 herangezogen. Hierbei besteht S_g^1 aus den Parametern a_1 und a_2 eines elliptischen Paraboloids (Gleichung 4.1), das an die Hüllpunkte der Baumkrone angepasst wird.

$$z = a_1(x - x_0)^2 + a_2(y - y_0)^2 + z_0 \quad (4.1)$$

Dazu müssen zuerst die Kronenpunkte von den übrigen Punkten im Segment abgetrennt werden. Das geschieht über die Identifikation der Kronenansatzhöhe H_{Kra} wie es im Abschnitt 3.2.2 beschrieben ist. Dann wird die konvexe Hülle [Barber et al., 2006] dieser Punkte berechnet, deren Facetten die Hüllpunkte der Krone bilden. Die Schätzung von a_1 und a_2 erfolgt über eine „Kleinste Quadrate“ Ausgleichung mit 4.1 als Beobachtungsgleichung. Der Ursprung (x_0, y_0, z_0) des Paraboloids kann entweder im Zuge der Ausgleichung mitgeschätzt oder fest vorgegeben werden. Für die Stabilität der Ausgleichung ist es vorteilhaft, die Position der Baumspitze aus dem Segment abzuleiten und diese als Wert für (x_0, y_0, z_0) zu verwenden. In der Abbildung 4.1 sind Beispiele für angepasste Paraboloiden dargestellt. Man sieht deutlich, dass die Krone der Fichte spitzer und rotationssymmetrischer ist als die

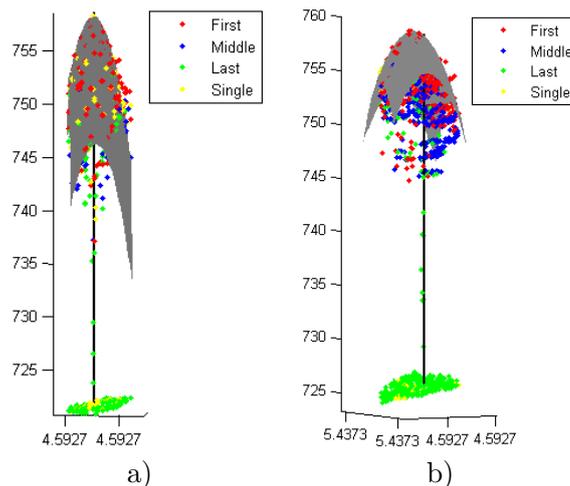


Abbildung 4.1: Anpassung eines Paraboloids an die Baumkrone a) einer Fichte, b) einer Buche

der Buche, was sich in den Werten von a_1 und a_2 widerspiegelt. So betragen $a_1 = 0.91$ und $a_2 = 0.94$ für die Fichte und $a_1 = 1.35$ und $a_2 = 1.61$ für die Buche.

Zur Berechnung des zweiten Merkmals S_g^2 wird das Baumsegment in l Höhengschichten (= Layer) unterteilt (Abbildung 4.2a) und für jede Schicht $k = 1 \dots l$ die mittlere horizontale Entfernung

$$r_k = \frac{1}{N_k} \sum_{i=1}^{N_k} \sqrt{(x_i - x_0)^2 + (y_i - y_0)^2} \quad (4.2)$$

aller N_k Layer-Punkte zur Stammposition (x_0, y_0) bestimmt. Weil r_k naturgemäß von der Baumhöhe Z_{Baum} abhängt, findet eine Normierung bezüglich dieser statt, so dass gilt: $S_g^2 = \left\{ \frac{r_k}{Z_{\text{Baum}}} \right\} (k = 1 \dots l)$. Bei der Klassifikation können entweder alle l Werte oder nur eine Teilmenge, die sich für die Unterscheidung der Baumarten als besonders signifikant erweist, verwendet werden. Im Gegensatz zu S_g^1 , das die Gesamtform der Baumkrone beschreibt, ermöglicht S_g^2 detaillierte Aussagen über die Ausdehnung des Baums an einer bestimmten Höhe.

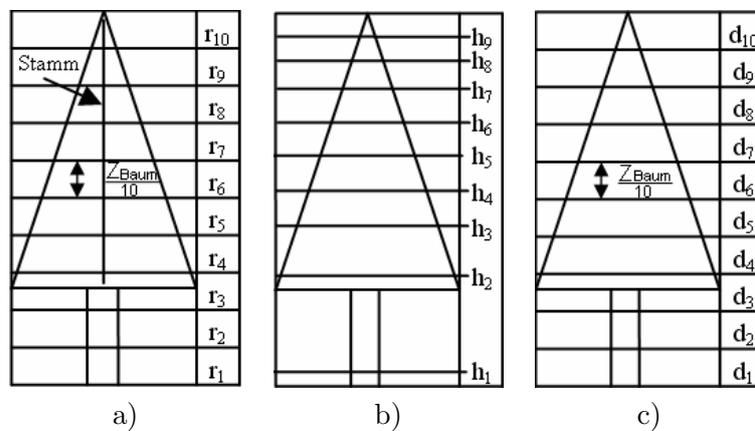


Abbildung 4.2: Unterteilung der Baumsegmente in Höhengschichten nach [Naesset, 2004]. a) zur Berechnung von S_g^2 , b) zur Berechnung von S_i^h , c) zur Berechnung von S_i^d

4.1.2 Interne Baumstruktur

Die Merkmalsgruppe $S_i = \{S_i^h, S_i^d\}$ zur Beschreibung der internen Baumstruktur ist aus Metriken abgeleitet, die Naesset [2004] zur Waldinventur auf Bestandesebene verwendet. So umfasst $S_i^h = \left\{ \frac{h_k}{Z_{\text{Baum}}} \right\} (k = 1 \dots l)$ die Perzentile der Höhenverteilung der Reflexionen eines Segments, was man auch als höhenabhängige Variablen bezeichnet (Abbildung 4.2b). Wegen der Abhängigkeit von der absoluten Baumhöhe Z_{Baum} findet eine Normalisierung statt. Allgemein gilt, dass der Abstand benachbarter h_k -Werte in einem bestimmten Höhenbereich umso geringer ist, desto mehr Punkte dort vorhanden sind. Für die Berechnung des zweiten Merkmals $S_i^d = \{d_k\} (k = 1 \dots l)$ wird das Segment wieder in l gleichabständige Höhengschichten zerlegt (Abbildung 4.2c). Die Werte d_k stellen dabei die Anzahl von Reflexionen pro Schicht relativ zur Gesamtzahl der Punkte im Segment dar und werden als dichteabhängige Variablen bezeichnet. In der Abbildung 4.3 sind die Merkmale S_i^h und S_i^d beispielhaft für je fünf Fichten und Buchen im belaubten Zustand dargestellt, wobei l in beiden Fällen auf 10 gesetzt wurde. An beiden Merkmalen sieht man, dass bei den Buchen mehr Reflexionen im oberen Bereich der Krone stattfinden als bei den Fichten.

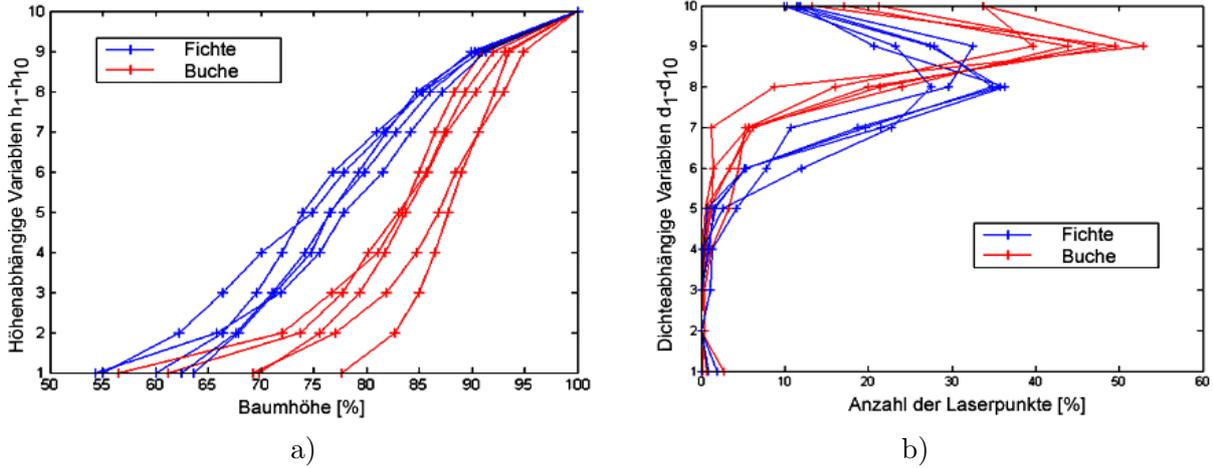


Abbildung 4.3: Merkmale der internen Baumstruktur für fünf Fichten und fünf Buchen. a) höhenabhängige (S_i^h), b) dichteabhängige (S_i^d) Variablen

4.1.3 Merkmale aus den Attributen der Reflexionen

Bei der dritten Merkmalsgruppe $\mathcal{S}_I = \{S_I^1, S_I^2\}$ wird die Intensität I^{korr} der Reflexionen genutzt, um die Baumarten auf Grund unterschiedlicher Reflexionseigenschaften ihres Materials zu unterscheiden. Das Merkmal S_I^1 umfasst die mittleren Intensitäten

$$I_k^{korr} = \frac{1}{N_k} \sum_{i=1}^{N_k} I_i^{korr} \quad (k = 1 \dots l) \quad (4.3)$$

pro Höhenschicht k und repräsentiert somit einen höhenabhängigen Intensitätsverlauf im Segment. Zusätzlich wird das Merkmal S_I^2 eingeführt, das die mittlere Intensität I_M^{korr} für das gesamte Segment als einzigen Wert enthält.

Analog wird die Pulsbreite W^c der Reflexionen im Segment verwendet, die hauptsächlich von der Form des reflektierenden Materials abhängt. Das Merkmal $\mathcal{S}_W = \{W_{M_{Single}}^c, W_{M_{First}}^c\}$ setzt sich aus den mittleren Pulsbreiten der Einzelreflexionen und der ersten Reflexionen für das gesamte Segment zusammen. Die Verwendung von W^c ist auf diese beiden Reflexionsklassen beschränkt, weil im Allgemeinen nur dort die reflektierende Fläche A groß genug für eine repräsentative Pulsaufweitung ist.

Die letzte Merkmalsgruppe $\mathcal{S}_n = \{S_n^1, S_n^2\}$ nutzt die Anzahl von Reflexionen pro Waveform und charakterisiert somit die Durchdringbarkeit des Baums. Das Merkmal $S_n^1 = \frac{N_{Middle}}{N_{First}}$ enthält das Verhältnis der N_{Middle} Zwischenpunkte zu den N_{First} ersten Punkten für das gesamte Segment und entspricht somit der durchschnittlichen Anzahl von Zwischenpunkten pro Mehrfachreflexion. Das Merkmal $S_n^2 = \frac{N_{Single}}{N_{First}}$ berechnet sich aus dem Verhältnis der N_{Single} Einzelpunkte zu den N_{First} ersten Punkten im Baumsegment und beschreibt damit die Proportion zwischen Lasermessungen mit nur einer Reflexion und Messungen mit mehreren Reflexionen.

Am Ende der Merkmalsbeschreibung muss noch auf den differenzierten Umgang mit den Bodenreflexionen im Baumsegment hingewiesen werden. Für die Berechnung der Merkmale \mathcal{S}_I und \mathcal{S}_n werden die Bodenpunkte verwendet, weil deren Anzahl für die Beurteilung der Durchdringbarkeit des Baums entscheidend ist. Bei den Merkmalen \mathcal{S}_I und \mathcal{S}_W hingegen, die den Baum auf Grund seiner Materialeigenschaften charakterisieren, wirken sich die Bodenpunkte nachteilig aus und werden deshalb

ausgeschlossen. Da für die Berechnung des Merkmals S_g nur Kronenpunkte verwendet werden, spielen hier die Bodenpunkte ohnehin keine Rolle.

4.2 Unüberwachte und überwachte Klassifikation

Wenn die Merkmale S_{Baum} für die zu klassifizierenden Baumsegmente vorliegen, wird eine Normierung auf einen einheitlichen Wertebereich (z.B. $[0,1]$) durchgeführt. Dies ist erforderlich, damit die einzelnen Merkmale direkt miteinander vergleichbar sind. Die anschließende Klassifikation kann entweder unüberwacht oder überwacht erfolgen. Bei der unüberwachten Klassifikation werden die Merkmale mittels Cluster-Analyse in eine vorgegebene oder während des Verfahrens dynamisch bestimmte Anzahl von Clustern aufgeteilt. Die Zuordnung der einzelnen Cluster zur jeweiligen Baumart erfolgt im Nachhinein über die bekannte Baumart einiger Segmente. Bei der überwachten Klassifikation sind schon zu Beginn repräsentative Trainingsdaten notwendig, mit deren Hilfe die Cluster statistisch beschrieben werden. Die Merkmale der Segmente mit unbekannter Baumart werden dann den Clustern zugeordnet, denen sie am ähnlichsten sind. Sowohl für die unüberwachte als auch für die überwachte Klassifikation wurden zahlreiche mathematische Ansätze entwickelt, die z.B. in den Büchern von Niemann [2003] und van der Heijden et al. [2004] detailliert dargestellt sind. Im Folgenden werden nur die drei Verfahren kurz vorgestellt, die in dieser Arbeit für die Baumartenklassifikation eingesetzt werden:

- Eine einfache und häufig eingesetzte Methode der unüberwachten Klassifikation ist das sog. „K-Means“ Clustering, das folgendermaßen abläuft:
 1. Festlegung der Anzahl s der Klassen
 2. Die Objekte $S_u (u = 1 \dots N_S)$ werden den Clustern $C_m (m = 1 \dots s)$ zufällig zugeordnet, wobei N_S die Anzahl der Objekte darstellt
 3. Für jedes Cluster wird ein Vektor der Mittelwerte μ_m aus den N_m Objekten des Clusters berechnet:

$$\mu_m = \frac{1}{N_m} \sum_{S_u \in C_m} S_u \quad (4.4)$$
 4. Jedes Objekt wird dem Cluster zugeordnet, zu dessen Mittelpunkt μ_m die Distanz am kleinsten ist.
 5. Wiederholung der Schritte 3 und 4, bis sich μ_m nicht mehr ändert oder eine vorgegebene maximale Anzahl von Iterationen überschritten wird
- Der EM-Algorithmus von Dempster et al. [1977] arbeitet auch unüberwacht und ist komplexer als die „K-Means“ Methode. Hier wird jedes Cluster C_m nicht nur durch den Mittelwertvektor μ_m , sondern auch durch eine Kovarianzmatrix Σ_m charakterisiert. Dazu wird die Wahrscheinlichkeitsdichte für den Merkmalsraum S bestimmt. In einer Maximum-Likelihood-Schätzung werden die Parameter des Dichtemodells

$$p(S) = \sum_{m=1}^s \pi_m N(S | \mu_m, \Sigma_m) \quad (4.5)$$

an die Daten angepasst. Geschätzt werden neben den Parametern μ_m und Σ_m der multivariaten Gaußverteilung $N(S | \mu_m, \Sigma_m)$ auch die Mischkoeffizienten π_m , mit $\sum_{m=1}^s \pi_m = 1$ und $\pi_m \geq 0$. Dieser Prozess hat folgenden Ablauf [van der Heijden et al., 2004]:

1. Zufällige Auswahl von Anfangswerten $\pi_m^{(0)}$, $\boldsymbol{\mu}_m^{(0)}$ und $\boldsymbol{\Sigma}_m^{(0)}$
2. Berechnung von Erwartungswerten („Expectation“)

$$q_{u,m} = \frac{\pi_m^{(i)} N(\mathbf{S}_u | \boldsymbol{\mu}_m^{(i)}, \boldsymbol{\Sigma}_m^{(i)})}{\sum_{j=1}^s \pi_j^{(i)} N(\mathbf{S}_u | \boldsymbol{\mu}_j^{(i)}, \boldsymbol{\Sigma}_j^{(i)})} \quad (4.6)$$

für die Zugehörigkeit des Objekts \mathbf{S}_u zur m -ten Klasse

3. Optimierung der Modellparameter („Maximization“) in einer Maximum-Likelihood-Schätzung unter Verwendung folgender Gleichungen, wobei d die Anzahl der verwendeten Merkmale darstellt:

$$\pi_m = \frac{1}{N_S} \sum_{u=1}^{N_S} q_{u,m} \quad (4.7)$$

$$\boldsymbol{\mu}_m = \frac{1}{N_S \pi_m} \sum_{u=1}^{N_S} q_{u,m} \mathbf{S}_u \quad (4.8)$$

$$\boldsymbol{\Sigma}_m = \frac{1}{N_S \pi_m} \sum_{u=1}^{N_S} q_{u,m} (\mathbf{S}_u - \boldsymbol{\mu}_m)(\mathbf{S}_u - \boldsymbol{\mu}_m)^T \quad (4.9)$$

$$N(\mathbf{S}_u | \boldsymbol{\mu}_m, \boldsymbol{\Sigma}_m) = \frac{1}{(2\pi)^{\frac{d}{2}} \sqrt{|\boldsymbol{\Sigma}_m|}} \exp\left(-\frac{1}{2}(\mathbf{S}_u - \boldsymbol{\mu}_m)^T \boldsymbol{\Sigma}_m^{-1} (\mathbf{S}_u - \boldsymbol{\mu}_m)\right) \quad (4.10)$$

4. Wiederholung der Schritte 2 und 3, bis sich die Ergebnisse nicht mehr signifikant ändern

Im Vergleich zur „K-Means“ Methode wird für eine zuverlässige Bestimmung der Parameter eine höhere Anzahl von Daten benötigt. Andererseits ermöglicht das EM Verfahren durch die flexiblere Form der Cluster eine bessere Approximation der Daten. Der EM Algorithmus wird hauptsächlich für die Clusteranalyse verwendet, findet aber auch Eingang in andere Anwendungen. So nutzen z.B. [Persson et al. \[2005\]](#) dieses Verfahren für die Anpassung von Gauß-Funktionen an Waveforms von Full Waveform Scannern.

- Das Maximum-Likelihood (ML) Verfahren ist eine weit verbreitete Methode der überwachten Klassifikation. Hier wird die Wahrscheinlichkeitsdichte für jede der s Klassen aus möglichst repräsentativen Trainingsdaten geschätzt. Unter der Annahme Gauß'scher Verteilungen entspricht der Erwartungswert $\hat{\boldsymbol{\mu}}_m (m = 1 \dots s)$ dem Mittelwertvektor, der nach der Gleichung 4.4 berechnet wird. Die Kovarianzmatrix $\hat{\boldsymbol{\Sigma}}_m$ ergibt sich dann wie folgt:

$$\hat{\boldsymbol{\Sigma}}_m = \frac{1}{N_m - 1} \sum_{n=1}^{N_m} (\mathbf{S}_n - \hat{\boldsymbol{\mu}}_m)(\mathbf{S}_n - \hat{\boldsymbol{\mu}}_m)^T \quad (4.11)$$

Hierbei ist N_m die Anzahl der Objekte in der Klasse m . Mit Hilfe von $\hat{\boldsymbol{\mu}}_m$ und $\hat{\boldsymbol{\Sigma}}_m$ werden die noch nicht klassifizierten Objekte \mathbf{S} derjenigen Klasse zugeordnet, für deren Zugehörigkeit die Wahrscheinlichkeit nach der Gleichung (4.10) maximal ist.

Kapitel 5

Messkampagnen

5.1 Referenzflächen

Für die experimentelle Untersuchung der vorgestellten Methoden wurde als Testgebiet der Nationalpark Bayerischer Wald ausgewählt. Dieser liegt im Südosten Bayerns entlang der deutsch-tschechischen Grenze ($49^{\circ} 3' 19''$ N, $13^{\circ} 12' 9''$ E) und umfasst eine Fläche von 24369 ha. Es gibt dort vier Teilgebiete mit einer Größe von 596 ha bis 955 ha, welche die drei Hauptwaldgesellschaften Bergfichtenwald, Bergmischwald und Aufichtenwald enthalten (Abbildung 5.1). Die Gebiete haben einen hangparallelen

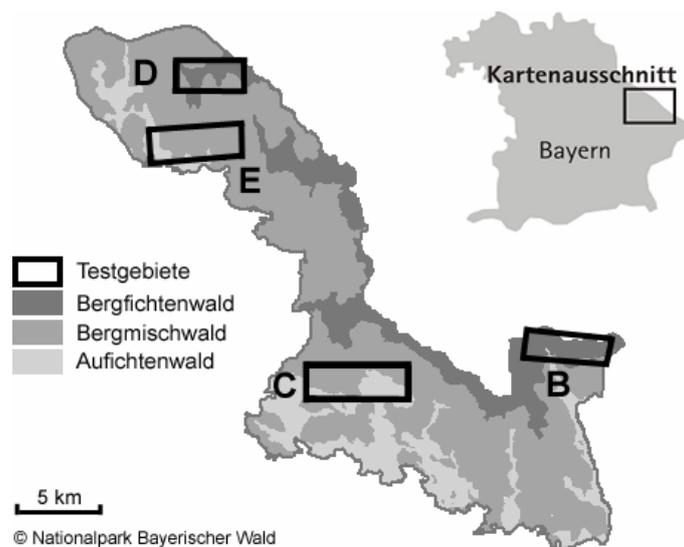


Abbildung 5.1: Lage der Teilgebiete im Nationalpark Bayerischer Wald

Verlauf und sind so geformt, dass eine kostengünstige Befliegung möglich ist. Innerhalb dieser Gebiete liegen Referenzflächen, deren Baumbestand manuell erfasst wurde. Teilweise handelt es sich bei diesen Flächen um waldkundliche Dauerbeobachtungsflächen des Lehrstuhls für Waldwachstumskunde der Technischen Universität München. Zusätzliche Flächen wurden im Rahmen der High-Tech-Offensive Bayern für das Projekt „Forschung über Waldökosysteme“ angelegt. Details hierzu können bei [Heurich \[2006\]](#) nachgelesen werden.

Für die Auswertungen in dieser Arbeit wurden 18 Referenzflächen in den Gebieten E und C mit einer Größe von 1000 m^2 bis 3600 m^2 herangezogen (Abbildungen 5.2 und 5.3). Beim Großteil dieser Flächen handelt es sich um Bergmischwald mit einer komplexen mehrschichtigen Waldbauform. Eine

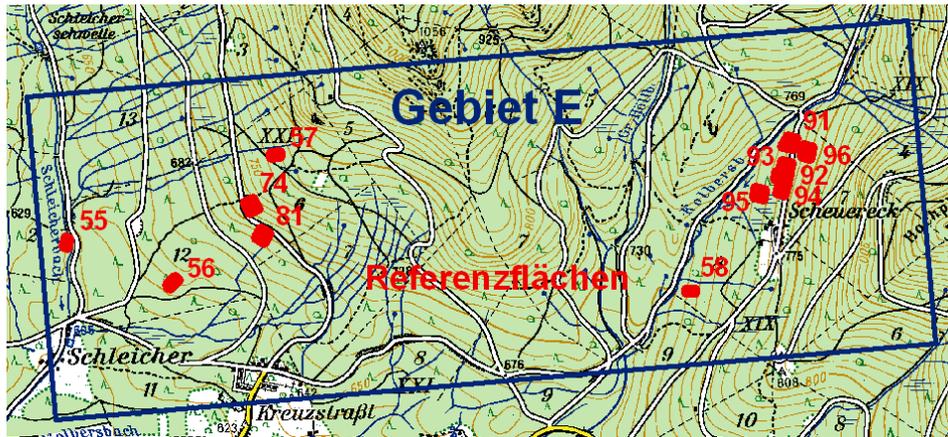


Abbildung 5.2: Teilgebiet E mit Referenzflächen

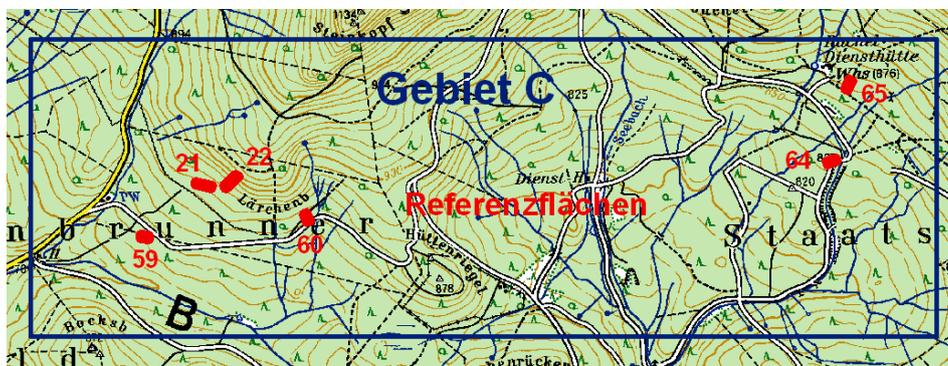


Abbildung 5.3: Teilgebiet C mit Referenzflächen

genaue Beschreibung der einzelnen Referenzflächen ist in der Tabelle 5.1 zu finden. Auf diesen Flächen wurde die genaue Position aller Bäume mit einem Brusthöhendurchmesser (BHD) von mehr als 7 cm mit Hilfe von differentiellm GPS und Tachymetrie erfasst. Außerdem wurde die Baumart bestimmt, der BHD mittels Maßband oder Kluppe gemessen und die Baumhöhe mit dem Höhenmessgerät „Vertex III“ ermittelt, das nach dem trigonometrischen Prinzip arbeitet. Diese Daten wurden bei jeder ALS Befliegung aktualisiert, um Veränderungen im Baumbestand zu berücksichtigen. Bei der letzten Erfas-

| Bezeichnung | 21 | 22 | 55 | 56 | 57 | 58 | 59 | 60 | 64 | 65 | 74 | 81 | 91 | 92 | 93 | 94 | 95 | 96 |
|----------------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|
| Gebiet | C | C | E | E | E | E | C | C | C | C | E | E | E | E | E | E | E | E |
| Größe [ha] | 0.20 | 0.20 | 0.15 | 0.23 | 0.10 | 0.10 | 0.10 | 0.10 | 0.12 | 0.12 | 0.30 | 0.30 | 0.36 | 0.25 | 0.28 | 0.29 | 0.25 | 0.30 |
| Alter [a] | 160 | 160 | 240 | 170 | 100 | 85 | 40 | 110 | 100 | 100 | 85 | 70 | 110 | 110 | 110 | 110 | 110 | 110 |
| Höhenlage [m] | 860 | 885 | 610 | 640 | 765 | 710 | 810 | 890 | 835 | 875 | 720 | 690 | 764 | 767 | 766 | 768 | 750 | 781 |
| Bäume/ha | 500 | 540 | 830 | 340 | 450 | 440 | 2150 | 380 | 430 | 810 | 700 | 610 | 260 | 170 | 240 | 250 | 240 | 200 |
| N Untersch. | 37 | 19 | 77 | 31 | 0 | 10 | 76 | 8 | 13 | 53 | 11 | 29 | 31 | 13 | 7 | 15 | 6 | 30 |
| N Zwischensch. | 14 | 60 | 21 | 19 | 4 | 4 | 85 | 22 | 4 | 26 | 33 | 59 | 11 | 3 | 2 | 4 | 0 | 3 |
| N Obersch. | 48 | 29 | 20 | 27 | 41 | 30 | 54 | 27 | 35 | 35 | 165 | 96 | 54 | 27 | 59 | 54 | 53 | 26 |
| Laubholz [%] | 66 | 79 | 5 | 10 | 0 | 14 | 1 | 100 | 87 | 96 | 29 | 100 | 75 | 100 | 66 | 97 | 10 | 86 |

Tabelle 5.1: Eigenschaften der Referenzflächen

sung im Sommer 2007 waren insgesamt 688 Fichten (*Picea abies*), 812 Buchen (*Fagus sylvatica*), 70 Tannen (*Abies alba*), 71 Bergahorne (*Acer pseudoplatanus*), 21 Spitzahorne (*Acer platanoides*) und zwei Linden (*Tilia europaea*) vorhanden. Für die Analyse der Segmentierungsergebnisse wurden diese Bäume auf drei verschiedene Höhenschichten aufgeteilt. Hierfür ist die Oberhöhe H_{100} der jeweiligen Referenzfläche maßgebend, welche als die mittlere Höhe der 100 stärksten Bäume je Hektar definiert ist [Heurich, 2006]. Zur Oberschicht gehören die Bäume, deren Höhe mindestens 80 % der Oberhöhe beträgt, zur Zwischenschicht die Bäume mit 50 % - 80 % der Oberhöhe und zur Unterschicht die Bäume mit weniger als 50 % der Oberhöhe. In der Tabelle 5.1 ist die Anzahl der Bäume pro Schicht für jede Referenzfläche angegeben.

Die Referenzbäume wurden zur Veranschaulichung bereits in einigen Abbildungen (z.B. 3.5, 3.16, 3.18, 3.19, 3.20, 4.1) verwendet, wobei deren Lage und Höhe meist als schwarze Linien dargestellt sind.

5.2 Laserdaten

In den Teilgebieten stehen Daten mehrerer ALS Kampagnen zur Verfügung (Tabelle 5.2). Die ers-

| Datensatz | I | II | III | IV | V | VI |
|---------------------------|-----------|------------|--------------|----------------|---------|----------|
| Zeitpunkt | April '02 | Sept. '02 | Sept. '04 | Mai '06 | Mai '07 | Mai '07 |
| Belaubung | unbelaubt | belaubt | belaubt | unbelaubt | belaubt | belaubt |
| Scanner | TopoSys I | TopoSys II | TopEye MK II | Riegl LMS-Q560 | | |
| Flughöhe [m] | 850 | 850 | 200 | 400 | 400 | 500 |
| Messpunkte/m ² | 10 | 10 | 25 | 25 | 25 | 10 |
| Footprint [cm] | 85 | 85 | 20 | 20 | 20 | 25 |
| Scanwinkel [°] | ±7.15 | ±7.15 | 14-20 | ±22.5 | ±30 | ±30 |
| Referenzflächen | alle | alle | 74,81 | alle | alle | Gebiet E |

Tabelle 5.2: Charakteristiken der verschiedenen ALS Kampagnen

ten beiden Befliegungen wurden im Jahr 2002 mit den Sensoren TopoSys Falcon I und II (Tabelle 5.3) durchgeführt und von Heurich [2006] zur Erfassung von Waldparametern auf Einzelbaum- und Bestandesebene genutzt. Der im laublosen Zustand erfasste Datensatz I diente außerdem zur Be-

| Scanner | TopoSys I | TopoSys II | TopEye MK II | Riegl LMS-Q560 |
|---------------------------|---------------|-----------------------------|---------------------------|-----------------------------|
| Scannerart | Faserlaser | | Palmer Scanner | Rotationsspiegel |
| Datenerfassung | First o. Last | First u. Last Intensität | First u. Last Waveform | Waveform gesendeter Puls |
| Scanwinkel [°] | ±7.15 | ±7.15 | 14-20 | ±22.5 oder ±30 |
| Wellenlänge [nm] | 1560 | 1560 | 1064 | 1550 |
| Pulsdauer (FWHM) [ns] | 5 | 5 | 5 | 4 |
| Abtastrate [GHz] | - | - | 1 | 1 |
| Abstand Abtastpunkte [cm] | - | - | 14.9896 | 14.9855 |
| Strahldivergenz [mrad] | 1 | 1 | 1 | 0.5 |
| Max. Pulsrate (PRF) [kHz] | 83 | 83 | 50 | 200 |
| Max. Flughöhe [m] | 1000 | 1600 | 1000 | 1500 |

Tabelle 5.3: Spezifikationen der verwendeten Scanner: TopoSys Falcon I und II (<http://www.toposys.com>), TopEye MK II (<http://www.topeye.com>) und Riegl LMS-Q560 (www.riegl.com)

rechnung eines DGMs mit einer Gitterweite von 1 m. Dessen absolute Genauigkeit wurde mit Hilfe von Referenzpunkten überprüft und beträgt 25 cm [Fischer & Knörzer, 2003]. Der Datensatz II wurde Anfang September im belaubten Zustand aufgenommen, um die Vegetationsoberfläche und die Bestandesstrukturen zu beschreiben.

Die erste Full Waveform Befliegung fand Ende September 2004 statt (Datensatz III), wobei die erste Version des damals neu auf den Markt gekommenen TopEye Mark II Scanners (Tabelle 5.3) eingesetzt wurde. Da es sich um einen unentgeltlich durchgeführten Testflug handelte, ist nur ein Teil des Teilgebiets E abgedeckt, der die Referenzflächen 74 und 81 beinhaltet. Wegen der späten Befliegszeit waren die Blätter der Laubbäume schon verfärbt, aber größtenteils noch an den Bäumen. Da dieser Scanner neben den Waveforms auch die First/Last-Pulse Punkte aufzeichnet, ist ein direkter Vergleich der beiden Verfahren unter exakt denselben Aufnahmebedingungen möglich. Durch die niedrige Flughöhe von 200 m über Grund wurde eine Dichte von 25 Messpunkten/m² und ein Footprint von 20 cm erreicht. Die Anzahl der Abtastpunkte ist bei diesem Gerät auf 128 begrenzt, so dass die maximale Länge der Waveforms ca. 19 m beträgt. Hierbei kann gewählt werden, ob die Aufzeichnung mit dem ersten Puls beginnt oder ob der letzte Puls und die vorhergehenden Abtastpunkte aufgezeichnet werden. Beim Datensatz III war die erste der beiden Optionen eingestellt, d.h. eine Überschreitung der Distanz zwischen erster und letzter Reflexion von 19 m führt zu einem Wegfall der bodennahen Reflexionen.

Eine vollständige Erfassung der beiden Teilgebiete mit Full Waveform Daten fand Anfang Mai 2006 mit dem Riegl LMS-Q560 Scanner (Tabelle 5.3) statt. Die Daten dieser Kampagne werden in der Tabelle 5.2 als Datensatz IV bezeichnet. Ursprünglich war die Befliegung schon für Mitte April geplant, um die Vegetation im vollständig unbelaubten Zustand zu erfassen. Da jedoch zu diesem Zeitpunkt noch viel Schnee lag, musste der Termin verschoben werden, was zu einem beginnenden Blattaustrieb zur Befliegszeit führte. Wegen der geringen Ausprägung der Belaubung wird die Vegetation jedoch als unbelaubt eingestuft. Die Flughöhe war mit 400 m doppelt so hoch wie bei der TopEye Befliegung, jedoch führte die geringere Strahldivergenz von 0.5 mrad ebenfalls zu einem Footprint von 20 cm. Die Punktdichte beträgt auch 25 Messpunkte/m², wobei unter dem Term Punktdichte immer der nominale Wert, beeinflusst durch die Pulsrate, Flughöhe, Fluggeschwindigkeit und Überlappung der Streifen, und nicht die Anzahl der abgeleiteten Punkte X_m verstanden wird. Der Riegl Scanner verwendet ebenfalls eine Abtastrate von ca. 1 GHz bei der Aufzeichnung der Waveforms. Die Beschränkung auf 128 Abtastpunkte liegt beim Riegl Scanner nicht vor, so dass die Länge der Waveforms praktisch unbegrenzt ist. Ein weiterer Vorteil dieses Systems ist die Aufzeichnung des gesendeten Signals, das zusätzlich zum empfangenen Signal in einer zweiten Waveform registriert wird und für die Kalibrierung der Messungen nützlich ist.

Um auch vollständige Full Waveform Daten für den belaubten Zustand zu erhalten, wurden Ende Mai 2007 die Teilgebiete C und E erneut mit dem Riegl LMS-Q560 Scanner befliegen (Datensatz V in der Tabelle 5.2). Die Aufnahmeparameter waren wegen der Vergleichbarkeit der Daten dieselben wie ein Jahr zuvor. Lediglich der Scanwinkel wurde diesmal auf den maximal möglichen Wert von $\pm 30^\circ$ eingestellt. Damit auch ein Vergleich zwischen den First/Last Pulse Daten (Datensatz II in der Tabelle 5.2) und den Full Waveform Daten möglich ist, wurde das Gebiet E separat mit einer niedrigeren Punktdichte von 10 Messpunkten/m² befliegen (Datensatz VI in der Tabelle 5.2). Dazu wurde die Flughöhe auf 500 m erhöht und die Überlappung der benachbarten Streifen verringert. Zusätzlich ist damit ein Vergleich zwischen den Datensätzen V und VI möglich, um Aussagen über die Sensitivität der angewandten Methoden bezüglich der Punktdichte treffen zu können.

Kapitel 6

Experimente

Im Folgenden werden die Methoden der Kapitel 2 bis 4 auf die Daten des Kapitels 5 angewandt, um die Wirksamkeit dieser Methoden zu untersuchen. Die Reihenfolge ist dabei analog zur Beschreibung der Methoden:

- Im Abschnitt 6.1 werden die Daten der beiden Full Waveform Scanner durch eine Anpassung von Gauß-Funktionen zerlegt. In ausgewählten Bereichen findet ein Vergleich der Ergebnisse mit diskret im Lasersystem erfassten ersten und letzten Reflexionen statt. Zusätzlich werden die Attribute Intensität und Pulsbreite kalibriert und bezüglich ihrer Werte für verschiedenartige Reflexionen im Waldbereich analysiert.
- Unter Nutzung der abgeleiteten Punkte werden im Abschnitt 6.2 die drei Methoden zur Einzelbaumerkennung angewandt. Die Ergebnisse werden mit Hilfe der Referenzdaten evaluiert und für die drei Verfahren miteinander verglichen. Die zur Verfügung stehenden Datensätze erlauben Tests für verschiedene Vegetationszustände und Punktdichten bei der Befliegung. Außerdem findet sowohl ein Vergleich zwischen First/Last-Pulse und Full Waveform Daten als auch zwischen den beiden Full Waveform Systemen von TopEye und Riegl statt.
- Für die berechneten Baumsegmente werden im Abschnitt 6.3 überwachte und unüberwachte Baumartenklassifikationen durchgeführt und mit Hilfe der Referenzdaten überprüft. Dabei werden die Ergebnisse für die verschiedenen Datensätze miteinander verglichen und die eingesetzten Merkmale auf Wirksamkeit getestet. Neben der Unterscheidung zwischen Laub- und Nadelbäumen wird auch die weitere Auftrennung in einzelne Laub- und Nadelbaumarten untersucht.

6.1 Auswertung der Waveforms

6.1.1 Ableitung von Punkten und Attributen

Überprüfung der Signale auf Gaußförmigkeit

Im ersten Schritt muss überprüft werden, ob die im Abschnitt 2.2.1 beschriebene Modellierung der Waveforms auf die Daten der beiden Scanner TopEye MK II und Riegl LMS-Q560 überhaupt anwendbar ist. Die Voraussetzung hierfür ist, dass die Waveform des ausgesendeten Signals gaußförmig ist [Wagner et al., 2006]. Dazu werden für beide Scanner die Differenzen zwischen Waveform und Modell exemplarisch untersucht (Abbildungen 6.1 und 6.2). Weil der TopEye Scanner die ausgesendeten Signale nicht aufgezeichnet, wird stattdessen eine Reflexion von einer ebenen Straßenfläche mit sehr

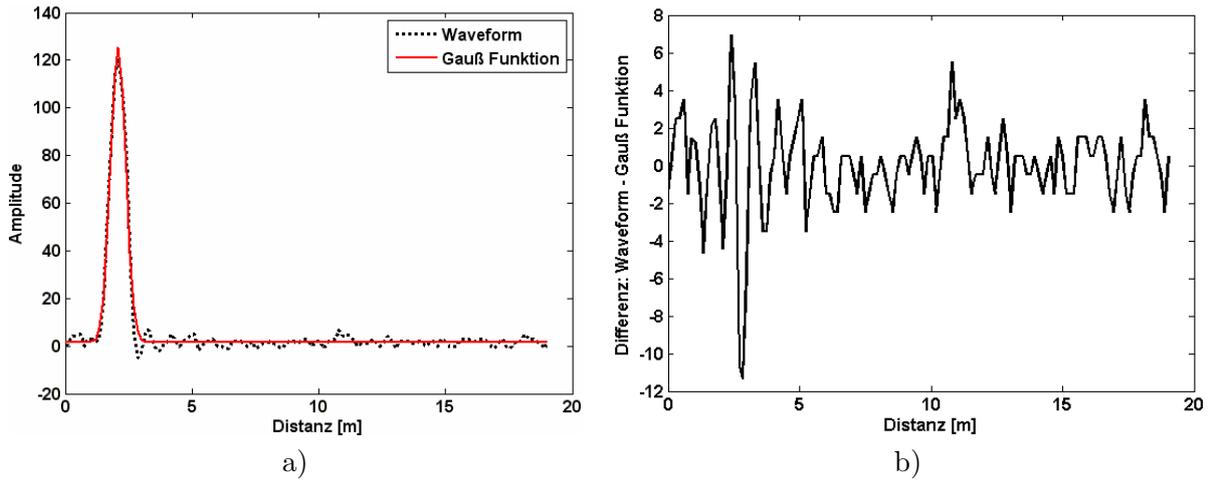


Abbildung 6.1: Überprüfung des TopEye Scanners auf gaußförmige Signale. a) Empfangene Wavform überlagert mit einer Gauß-Funktion, b) Differenz zwischen Wavform und Gauß-Funktion

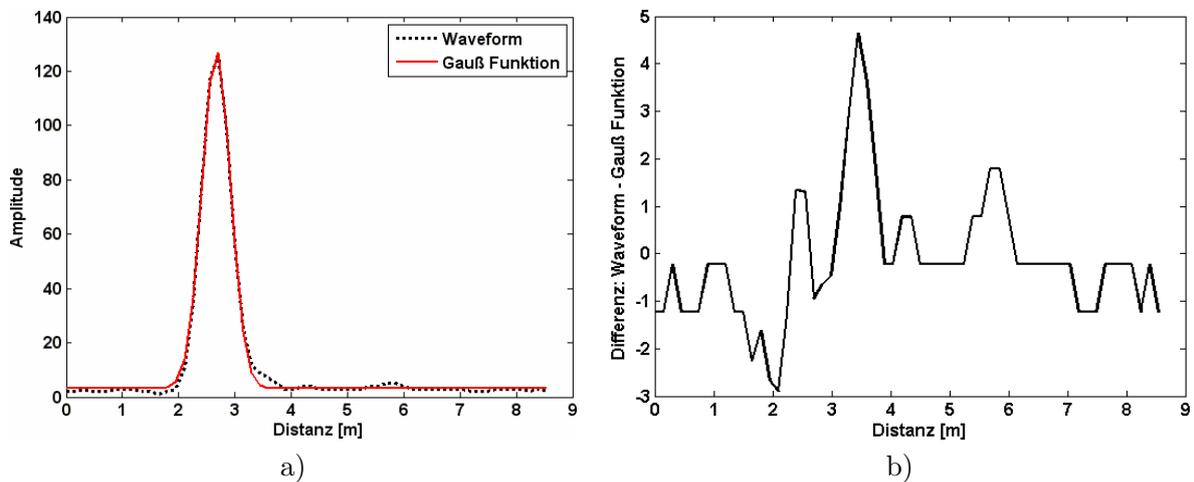


Abbildung 6.2: Überprüfung des Riegl Scanners auf gaußförmige Signale. a) Ausgesendete Wavform überlagert mit einer Gauß-Funktion, b) Differenz zwischen Wavform und Gauß-Funktion

geringem Einfallswinkel verwendet. Wie man sieht, lassen sich die Waveforms sehr gut durch Gauß-Funktionen approximieren. Die Differenzen liegen bis auf den Bereich direkt nach der Reflexion in der Größenordnung des Rauschens, das bei der TopEye Wavform maximal 6 Digitalzahlen (engl.: Digital Number (DN)) und bei der Riegl Wavform maximal 3 DN beträgt. Die größeren Abweichungen von ca. 11 DN bei TopEye und ca. 5 DN bei Riegl direkt nach der Reflexion sind auf einen Effekt der begrenzten Bandbreite der Empfängerelektronik zurückzuführen. Dieser Effekt ist umso ausgeprägter, je stärker die Reflexion ist und kann sogar zu Nachschwingern führen (siehe Abschnitt 2.2.3).

Schätzung der Modellparameter

Da das Gauß-Modell für die eingesetzten Scanner geeignet ist, wird die Schätzung der Modellparameter für alle Waveforms (Datensätze III - VI) durchgeführt. Die für die Ausgleichung benötigten Näherungswerte \hat{b} , \hat{A}_m , $\hat{\sigma}_m$ und \hat{t}_m werden analog zu Abschnitt 2.2.2 bestimmt, wobei es folgende Unterschiede

für die verwendeten Scanner gibt: Beim Riegl Scanner ist der Rauschpegel konstant, so dass für alle Waveforms die empirisch ermittelten Werte $\hat{b} = 3$ und $S_{A_m} = 6.5$ verwendet werden können. Beim TopEye Scanner hingegen variiert der Rauschpegel, so dass diese Werte auf dem Median und dem „Median Absolute Deviation (MAD)“ Wert basierend individuell für jede Waveform berechnet werden. Für $\hat{\sigma}_m$ kann beim Riegl Scanner direkt die halbe Pulsbreite des gesendeten Signals verwendet werden, weil dieses für jeden Laserschuss aufgezeichnet wird. Beim TopEye Scanner wird nur das reflektierte Signal aufgezeichnet, so dass $\hat{\sigma}_m$ aus Reflexionen auf ebenen Flächen mit möglichst senkrechtem Einfallswinkel abgeleitet wird. Alternativ kann $\hat{\sigma}_m$ aus der Pulsdauer des gesendeten Signals berechnet werden (Tabelle 5.3), welche die Breite des Signals auf der Höhe des halben Maximums (FWHM) darstellt. Für den TopEye Scanner ergibt dies einen Wert für $\hat{\sigma}_m$ von 2 ns oder 30 cm. Beim Riegl Scanner ist der Wert wegen der niedrigeren Pulsdauer kleiner und beträgt 1.7 ns oder 25 cm.

Vor der Ableitung der 3D Punkte werden die Genauigkeitsmaße aus der Ausgleichung für eine interne Qualitätskontrolle genutzt. Bei jeder Gauß-Funktion wird getestet, ob die Standardabweichung σ_{t_m} für den geschätzten Zeitpunkt t_m der Reflexion den Schwellwert $S_{\sigma_{t_m}}$ unterschreitet. $S_{\sigma_{t_m}}$ wird dabei umgerechnet ins metrische Maß auf 10 cm gesetzt, was die Ausgleichungsergebnisse bis auf wenige Ausnahmen erfüllen. Im Mittel liegt σ_{t_m} bei ungefähr 2 cm für beide Scanner und beträgt sogar nur ca. $\frac{1}{7}$ der Auflösung der Messwerte von ca. 15 cm.

Ringling Effekt

Wie die Abbildung 6.3a zeigt, müssen die Auswirkungen des Ringing Effekts (Abschnitt 2.2.3) berücksichtigt werden. Die aus den TopEye Daten abgeleiteten Punkte eines Hauses enthalten ohne Berücksichtigung

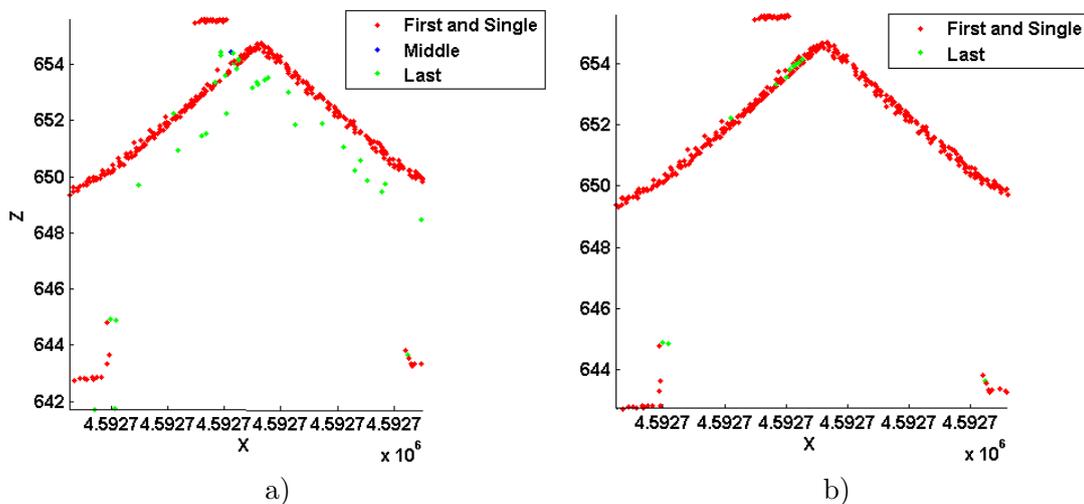


Abbildung 6.3: Beispiel für die Auswirkungen des Ringing Effekts. a) Querprofil von einem Haus ohne Berücksichtigung des Effekts, b) mit Berücksichtigung des Effekts

sichtigung des Ringing Effekts eindeutig falsche Punkte unterhalb des Dachs und der Bodenoberfläche. Nach der Modellierung des Effekts mit Hilfe der empirisch festgesetzten Schwellwerte $S_{\Delta t} = 1.5$ m und $S_{V_A} = \frac{1}{5}$ sind diese fehlerhaften Punkte nicht mehr vorhanden (Abbildung 6.3b). Im Vegetationsbereich fallen solche Fehler nicht so einfach auf, wie bei Objekten, deren Geometrie bekannt ist. Doch auch hier ist eine Korrektur notwendig. So enthält z.B. die Waveform in der Abbildung 6.6a, die von einem Baum stammt, eindeutig einen Nachschwinger direkt nach der starken Reflexion. Ver-

gleicht man die beiden Full Waveform Scanner bezüglich dieses Effekts, so stellt man fest, dass solche Nachschwinger beim TopEye System häufiger auftreten als beim Riegl System und im Vergleich zur eigentlichen Reflexion eine höhere Amplitude A_m aufweisen.

Vergleich mit der diskreten Erfassung im Lasersystem

Nach der Ableitung der 3D Punkte aus den Waveforms stellt sich die Frage, welche Vorteile diese Vorgehensweise gegenüber der diskreten Erfassung von Punkten im Lasersystem bietet. Beim Datensatz III gibt es die Möglichkeit, beide Verfahren miteinander zu vergleichen, weil neben den Waveforms auch die vom TopEye System direkt aufgezeichneten First/Last-Pulse Punkte vorliegen. In der Abbildung 6.4 werden die Punkte des TopEye Systems den Punkten aus den Waveforms für vier Bereiche exemplarisch gegenübergestellt. Diese Bereiche enthalten a) einen belaubten Strauch, b) einen freistehenden, unbelaubten Laubbaum, c) einen freistehenden Nadelbaum und d) eine Baumgruppe mitten im Wald, bestehend aus einem belaubten Laubbaum und einem Nadelbaum. Vergleicht man 6.4B mit 6.4C, so kann man erkennen, dass die Zerlegung der Waveforms zu einer dichteren Beschreibung der Baumkronen führt. Die Tabelle 6.1 enthält die zugehörige Anzahl der Punkte, aufgeteilt in die verschiedenen Punktklassen der Tabelle 2.1. Im Bereich a) ist die Erhöhung der Gesamtpunktzahl mit 16 % am

| Bereich | | a) | b) | c) | d) |
|--------------------------------------|---------------|----------------------|-------------------------|--------------------|-------------------------------------|
| Baumart | | Strauch (belaubt) | Laubbaum (unbelaubt) | Nadelbaum | Laubbaum (belaubt) und Nadelbaum |
| Größe [m ²] | | 22 | 73 | 28 | 33 |
| Anzahl der Punkte des TopEye Systems | Single | 232 | 2654 | 690 | 529 |
| | First | 272 | 1510 | 331 | 250 |
| | Last | 227 | 1457 | 270 | 184 |
| | Gesamt | 731 | 5621 | 1291 | 1013 |
| Anzahl der Punkte aus den Waveforms | Single | 235 | 2629 | 456 | 357 |
| | First | 281 | 1572 | 576 | 479 |
| | Middle | 109 | 1345 | 236 | 223 |
| | Last | 223 | 1595 | 506 | 430 |
| | Gesamt | 848 (+16%) | 7141 (+27%) | 1774 (+37%) | 1489 (+47%) |

Tabelle 6.1: Vergleich der First/Last-Pulse Punkte des TopEye Systems mit den Punkten aus der Waveform-Zerlegung

niedrigsten, weil hier viele Bodenpunkte vorhanden sind, deren Anzahl sich durch die Auswertung der Waveforms kaum erhöht. Dennoch verbessern die zusätzlichen Zwischenpunkte aus den Waveforms die 3D Beschreibung des Strauchs erheblich. Die größte Steigerung von 47 % findet im Bereich d) statt, der in einem älteren, durchschnittlich dichten Waldbestand liegt. In der zugehörigen Abbildung 6.4Cd macht sich diese Steigerung insbesondere im unteren Kronenbereich durch vollständiger erfasste Baumkronen bemerkbar.

Beim Vergleich von 6.4Bd mit 6.4Cd stellt man erstaunlicherweise fest, dass hier die Waveforms weniger Bodenpunkte liefern als das System. Offensichtlich macht sich bei diesen über 30 m hohen Bäumen die Begrenzung der Waveforms auf eine Länge von 19 m bemerkbar. Wegen der Dichte des Bestandes ist auch ein seitliches Erreichen des Bodens ohne Durchdringung der Bäume kaum möglich. Ohne diese Beschränkung, die ja nur beim TopEye Scanner vorliegt, wäre die Steigerung der Punktzahl noch größer.

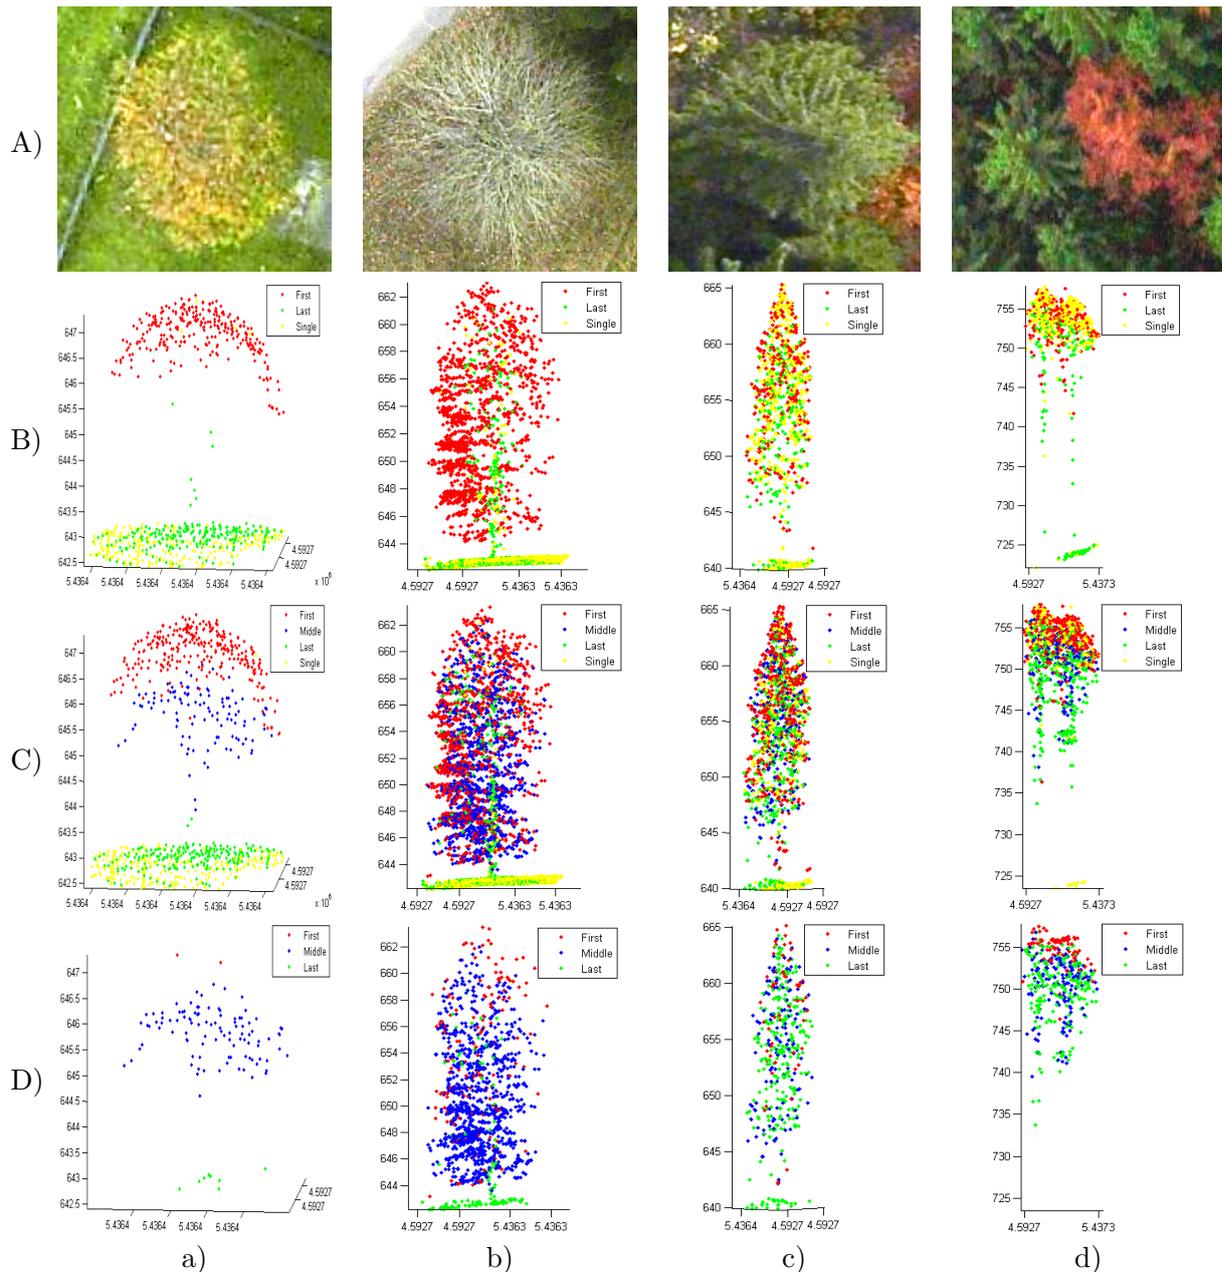


Abbildung 6.4: Vergleich von First/Last-Pulse und Full Waveform anhand von Beispielen. A) Luftbilder von vier Bereichen im Gebiet des Datensatz III, B) First/Last-Pulse Punkte des TopEye Systems, C) Punkte aus der Waveform Zerlegung, D) Nur zusätzliche Punkte aus der Waveform Zerlegung

Insgesamt kann man also beobachten, dass durch die Auswertung der Waveforms eine viel höhere räumliche Punktdichte entsteht als bei der diskreten Erfassung von First/Last-Pulse Punkten im System. Dafür gibt es folgende Erklärungen:

- Die Waveforms enthalten neben der ersten und letzten Reflexion auch alle dazwischen liegenden Reflexionen, die vom System vernachlässigt werden. Zum Beispiel können aus den Waveforms in der Abbildung 6.5 vier zusätzliche Punkte abgeleitet werden, die sich zwischen dem ersten

und dem letzten Peak befinden. Bei Betrachtung der Abbildung 6.4D sieht man, dass diese Zwischenpunkte in den Bereichen a) und b) hauptsächlich für die Erhöhung der Gesamtpunktzahl verantwortlich sind. Daraus kann man schließen, dass die Strukturen dieser beiden Bäume gut durchdringbar sind und mehrere Reflexionen pro Laserschuss erzeugen. Im Bereich b) führt das zu einer realen Punktdichte von 98 Punkten/m².

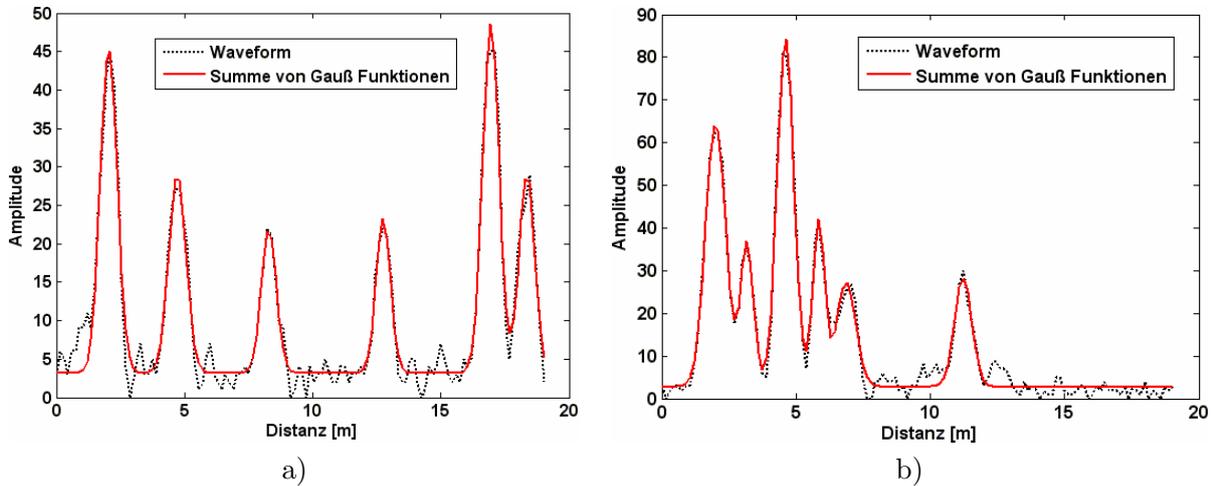


Abbildung 6.5: Waveforms mit vielen Reflexionen

- Bei der diskreten Erfassung im System bleiben schwache Reflexionen häufig unberücksichtigt, wofür vermutlich ein interner Schwellwert verantwortlich ist. Die Abbildung 6.6a zeigt beispielsweise eine Waveform, bei der das System nur einen Einzelpunkt bei der dominanten Reflexion ausgibt.

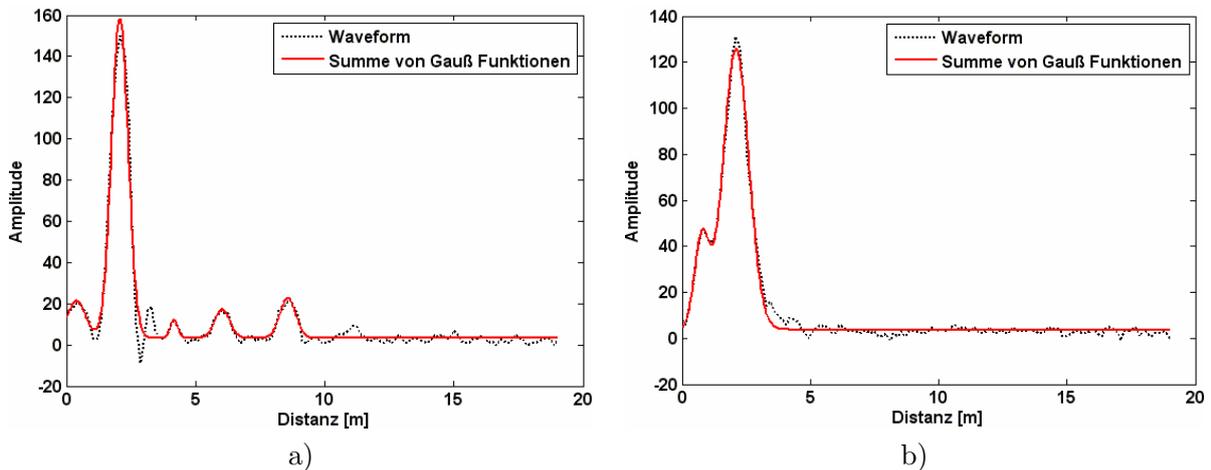


Abbildung 6.6: Waveforms mit nur einem Einzelpunkt bei der diskreten Aufzeichnung im TopEye System

- Die diskreten Systeme können erst wieder ein Echo detektieren, wenn das vorangegangene Echo vollständig abgeklungen ist. Diese Abklingzeit kann Werte bis zur dreifachen Pulsdauer annehmen, so dass eine Totzeit von mehreren Metern entsteht. Zum Beispiel kann das System bei

der Waveform in der Abbildung 6.6b nur einen Einzelpunkt finden, während die Anpassung von Gauß-Funktionen zur einem ersten und einem letzten Punkt führt.

Bei der Zerlegung der Waveforms können dank der robusten Levenberg-Marquardt Iteration auch stark überlappende Reflexionen noch getrennt werden, wie die Beispiele in der Abbildung 6.7 zeigen. In 6.7a beträgt der Abstand zwischen den Peaks der einzelnen Reflexionen nur 0.5 m und 0.8 m. Da für die Bestimmung der Näherungswerte \hat{t}_m neben den lokalen Maxima auch Terrassenpunkte verwendet werden, können sogar Reflexionen aufgelöst werden, die schon zu einem Peak verschmolzen sind. Die Abbildung 6.8 zeigt Beispiele hierfür. Zur Verdeutlichung sind neben der Summe auch noch die einzelnen Gauß-Funktionen dargestellt. In 6.8a beträgt der Abstand zwischen den beiden Funktionen nur 0.4 m.

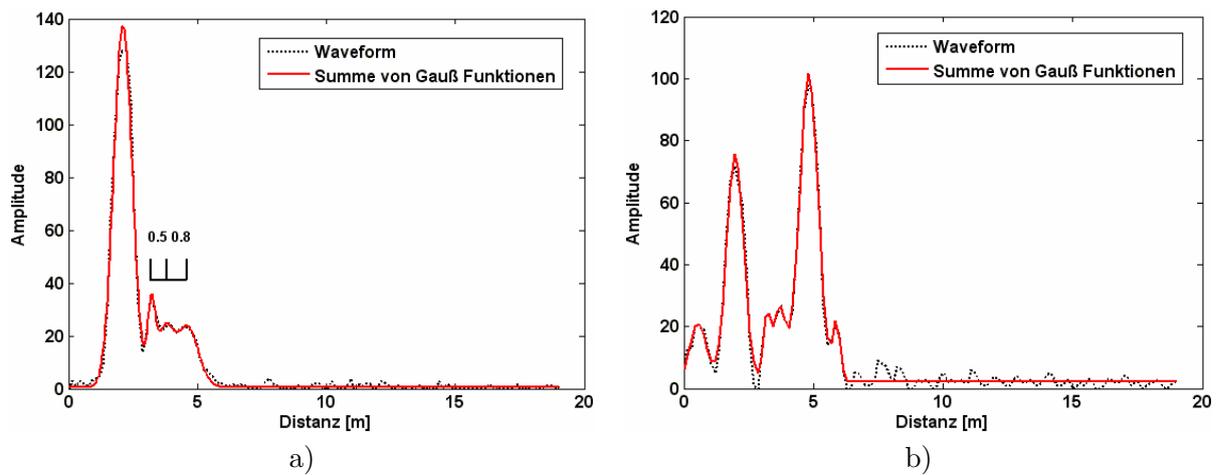


Abbildung 6.7: Trennung stark überlagernder Reflexionen

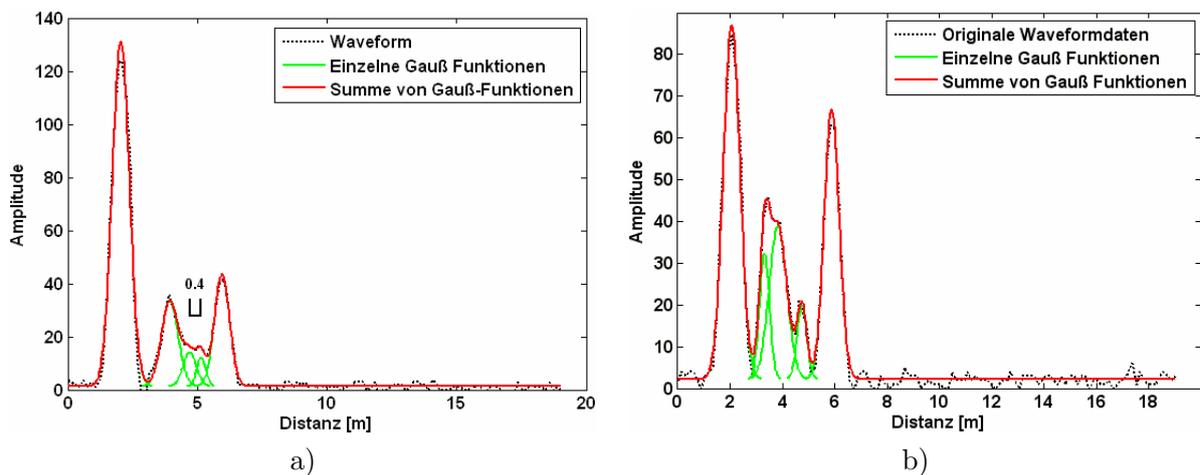


Abbildung 6.8: Trennung von Reflexionen ohne eigenes lokales Maximum

Die Erfassung schwacher und nahe beieinander liegender Reflexionen kann man auch in dem durchgeführten Vergleich (Abbildung 6.4 und Tabelle 6.1) beobachten. Besonders in den Bereichen c) und d) findet eine starke Zunahme der ersten und letzten Punkte zu Lasten der Einzelpunkte statt. Wo also

bei der diskreten Aufzeichnung von First/Last-Pulse Daten im TopEye System nur ein Punkt erfasst wurde, entstehen bei der Auswertung der Waveforms häufig zwei oder mehr Punkte.

Grenzen des Verfahrens

Wie man an den Abbildungen 6.5 bis 6.8 sieht, werden die einzelnen Reflexionen in den Waveforms auch bei komplexen Situationen gut gefunden. Bei zu starkem Verschmelzen der Reflexionen aber stößt auch dieser Ansatz an seine Grenzen. Die Abbildung 6.9 zeigt Waveforms des TopEye Scanners, bei denen die dominante Reflexion mit einer unmittelbar folgenden schwächeren Reflexion vereinigt ist, die nicht gefunden wird. Das hat zur Folge, dass auch die starke Reflexion nicht optimal modelliert wird, weil das

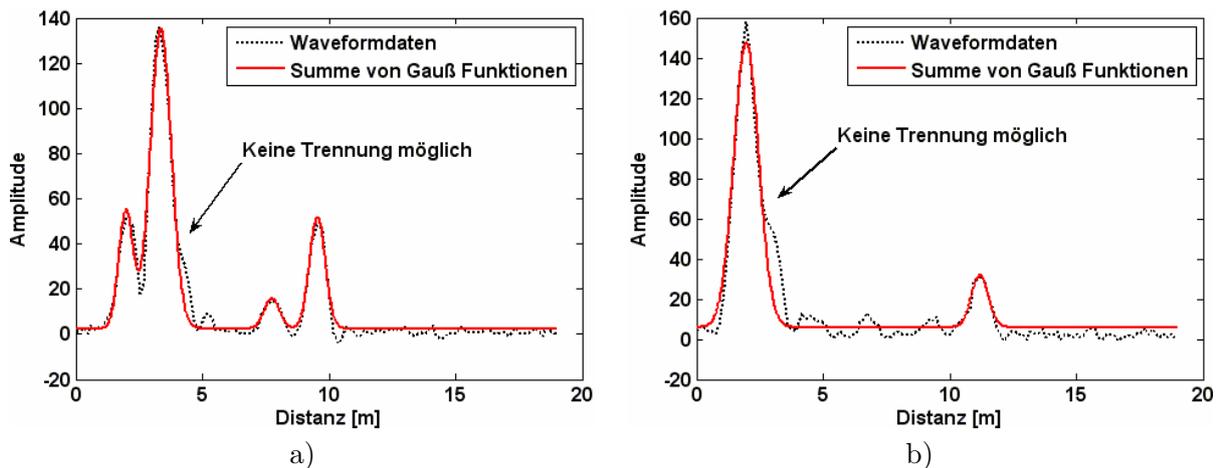


Abbildung 6.9: Keine Trennung überlagernder Reflexionen

Gauß-Modell nicht für unsymmetrische Kurven geeignet ist. Anhand dieser zwei Waveforms sieht man auch die Schwierigkeit, echte Reflexionen vom Rauschen zu unterscheiden. In der Waveform 6.9a gibt es einen und in der Waveform 6.9b sogar drei kleinere Peaks, die man eventuell noch als sehr schwache Reflexionen werten könnte. Der Schwellwert $S_{\hat{A}_m}$ wurde jedoch absichtlich so hoch angesetzt, dass auf keinen Fall falsche Reflexionen durch fehlerhaft interpretiertes Rauschen entstehen.

6.1.2 Kalibrierung von Intensität und Pulsbreite

Nach der Ableitung von 3D Punkten und deren Attributen wird eine Kalibrierung der Intensität I_m und der Pulsbreite W_m basierend auf den Ausführungen im Abschnitt 2.3.2 durchgeführt. Weil bei den Datensätzen IV bis VI neben dem empfangenen Signal auch das gesendete Signal vorliegt, können hier I_m und W_m ins Verhältnis zu den Werten des gesendeten Signals gesetzt werden und sind somit frei von eventuellen Schwankungen des Sendepulses. Beim Datensatz III ist dies wegen des fehlenden Sendesignals nicht möglich, so dass ein konstanter Sendepuls angenommen werden muss.

Bei den Messkampagnen wurden keine detaillierten meteorologischen Daten aufgezeichnet, um den atmosphärischen Transmissionsfaktor η_{atm} genau ermitteln zu können. Da aus den Flugprotokollen stets das Vorherrschen klarer Sichtbedingungen hervorgeht, wird für den Abschwächungsfaktor a ein Standardwert von 0.2 dB/km verwendet und η_{atm} nach der Gleichung 2.17 für jede Reflexion berechnet. Die Intensitäten der Datensätze III bis VI werden dann mit diesem Faktor korrigiert, so dass die im Abschnitt 2.3.2 als I^c bezeichneten Werte vorliegen. Betrachtet man die Größenordnung der atmosphärischen Dämpfung, so liegt diese bei ca. 1 % pro 100 m Entfernung.

Im nächsten Schritt werden die unterschiedlichen Laufzeiten der einzelnen Lasersignale korrigiert, die der Hauptgrund für unerwünschte Variationen der Intensität sind. Dazu wird die Gleichung 2.23 angewandt, die sich sowohl für eine modellgetriebene als auch für eine datengetriebene Korrektur eignet. Beim Datensatz III ist lediglich der modellgetriebene Ansatz möglich, weil keine geeigneten Daten aus unterschiedlicher Flughöhe vorliegen, um daraus einen Wert für den Exponenten n zu ermitteln. Aus diesem Grund wird n unter der Annahme ausgedehnter Zielobjekte auf 2 gesetzt. Bei den Datensätzen IV bis VI hingegen können Kalibrierflüge genutzt werden, die vor den Messkampagnen zur geometrischen Kalibrierung des Systems jeweils nach dem gleichen Schema durchgeführt wurden. Hierbei wurden auf dem Flugplatz in Straubing (Niederbayern) mehrere Spuren bei zwei unterschiedlichen Flughöhen (200 m und 400 m) längs und quer zum Rollfeld erfasst (Abbildung 6.10). Zur Kalibrierung

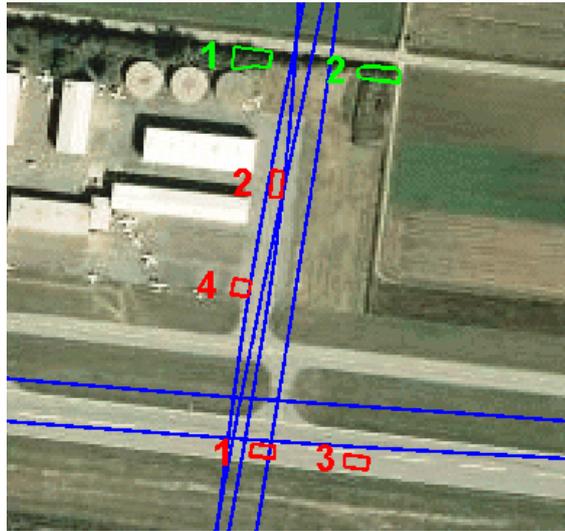


Abbildung 6.10: Flugplatz in Straubing mit Flugspuren (blau), vier ebenen Flächen mit jeweils homogener Oberfläche (rot) und zwei Flächen mit Vegetation (grün)

der Intensität werden vier ebene Flächen ($122 \text{ m}^2 - 133 \text{ m}^2$) mit homogener Oberfläche ausgewählt, die nur Einzelreflexionen enthalten. Pro Fläche und Spur werden die mittleren Intensitäten I_M^c und die mittleren Entfernungen R_M berechnet. Um den Einfluss unterschiedlicher Einfallswinkel zu reduzieren, werden nur Messungen mit einem Scanwinkel kleiner als 10° verwendet. Mit Hilfe der Gleichung

$$I_{M_i}^c R_{M_i}^n = I_{M_j}^c R_{M_j}^n \quad (6.1)$$

wird für jede Fläche und jede Kombination zweier Flugspuren i und j , die eine unterschiedliche Flughöhe aufweisen, numerisch ein optimaler Wert für n ermittelt. Insgesamt erhält man 24 Einzelergebnisse pro Kalibrierflug, deren Mittelwerte und Standardabweichungen in der Tabelle 6.2 dargestellt sind. Wie man sieht, liegt n unter dem theoretischen Wert von 2, der nach der Radargleichung für

| | Datensatz IV (2006) | Datensätze V und VI (2007) |
|-------------------------------------|-----------------------|----------------------------|
| Parameter n für ebene Flächen | 1.902 (± 0.050) | 1.736 (± 0.089) |
| Parameter n im Vegetationsbereich | 1.853 (± 0.108) | 1.886 (± 0.087) |

Tabelle 6.2: Parameter n und deren Standardabweichungen für die vier ebene Flächen mit Einzelreflexionen und die beiden Vegetationsbereiche in der Abbildung 6.10

Einzelreflexionen auf ausgedehnten Zielobjekten gilt. Unter Verwendung dieser Ergebnisse wird die Gleichung 2.23 auf alle Intensitäten I^c der Datensätze IV bis VI angewendet. Die Referenzentfernung R_{ref} , die nur zur Skalierung der Daten dient, wird dabei auf einen mittleren Entfernungswert gesetzt.

Da diese Kalibrierung nur für Reflexionen ausgedehnter Objekte gilt, muss die Übertragbarkeit auf den Vegetationsbereich überprüft werden. Dazu werden auf dem Flugplatz zwei Bereiche mit 4 m bis 8 m hoher Vegetation ausgewählt (Abbildungen 6.10 und 6.11) und analog zu obiger Vorgehensweise die Exponenten n bestimmt. An den Ergebnissen in der Tabelle 6.2 sieht man geringe Differenzen zu den obigen Werten, wobei der Wert bei der Befliegung 2006 knapp unter dem Wert für ebene Flächen liegt. Bei der Befliegung 2007 hingegen ist der Wert im Vegetationsbereich etwas höher. Für dieses Verhalten könnten die unterschiedlichen Vegetationszustände bei den beiden Befliegungen verantwortlich sein. Wie man in der Abbildung 6.11 sieht, treten bei der Befliegung 2006 wegen der noch nicht voll entfalteten Belaubung eine viel größere Anzahl von Mehrfachreflexionen auf. Insgesamt ist aber zumindest bei diesen Beispielen die mittlere Entfernungskorrektur im Vegetationsbereich der Korrektur im freien Gelände sehr ähnlich.

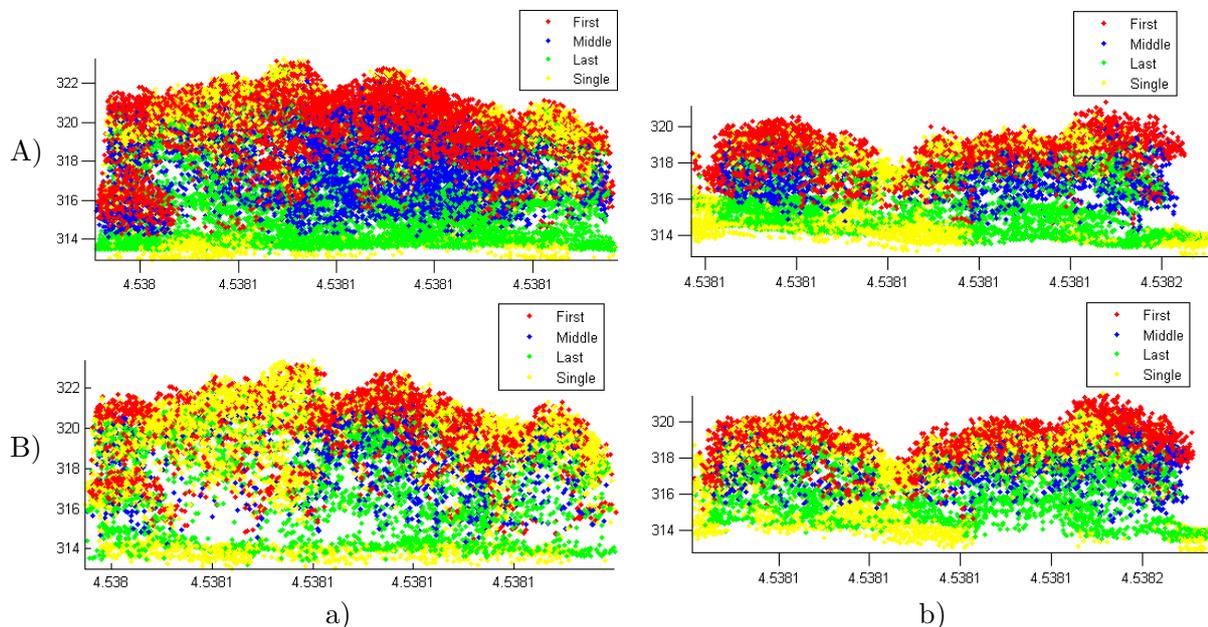


Abbildung 6.11: Laserpunkte von den beiden Vegetationsbereichen (a=Bereich 1; b=Bereich 2) in der Abbildung 6.10, A) für die Befliegung 2006, B) für die Befliegung 2007

6.1.3 Analyse von Intensität und Pulsbreite

Nach der Berechnung und Kalibrierung der Punktattribute Intensität und Pulsbreite soll untersucht werden, wie sich diese Größen für verschiedene Reflexionen im Waldbereich verhalten. Dazu werden die Laserpunkte des Datensatz IV auf 11 Referenzflächen des Gebiets E in die drei Kategorien Bodenpunkte, Stammpunkte und Kronenpunkte unterteilt [Reitberger et al., 2007b]. Als Bodenpunkte werden Punkte mit einem Abstand von weniger als 1 m zu einem bestehenden DGM betrachtet. Die Stammpunkte sind das Ergebnis der im Abschnitt 3.2.2 beschriebenen Methode zur Stammerkennung. Bei der Bestimmung der Kronenpunkte reicht es nicht aus, nur diese Stammpunkte von der Gesamtmenge der Baumpunkte zu entfernen, weil auch Stammtreffer oberhalb der Kronenansatzhöhe H_{KrA}

vorhanden sind und bei der Stammerkennung nicht alle Stämme gefunden werden. Deshalb nutzt man die Referenzdaten und berechnet für jeden Baum einen Zylinder V_{StRef} mit einem Radius von 1 m um die bekannte Baumposition und mit der bekannten Baumhöhe. Um sicher zu sein, dass keine Stammunkte in den Kronenpunkten vorhanden sind, werden nur die Punkte außerhalb von V_{StRef} als Kronenpunkte betrachtet.

Anschließend folgt eine Analyse der Intensität und Pulsbreite in Abhängigkeit vom Scanwinkel der Lasermessungen, welcher beim Datensatz IV maximal 22.5° beträgt. Weil die einzelnen Werte stark streuen, werden die Mittelwerte und Standardabweichungen in einem Intervall von 5° berechnet. Dies wird separat für die in der Tabelle 2.1 aufgeführten Punktklassen durchgeführt, um eventuellen Unterschieden Rechnung zu tragen. Die beiden aussagekräftigsten Ergebnisse sind in den Abbildungen 6.12a und 6.12b grafisch dargestellt. Offensichtlich unterscheiden sich die Bodenpunkte von den Stamm- und

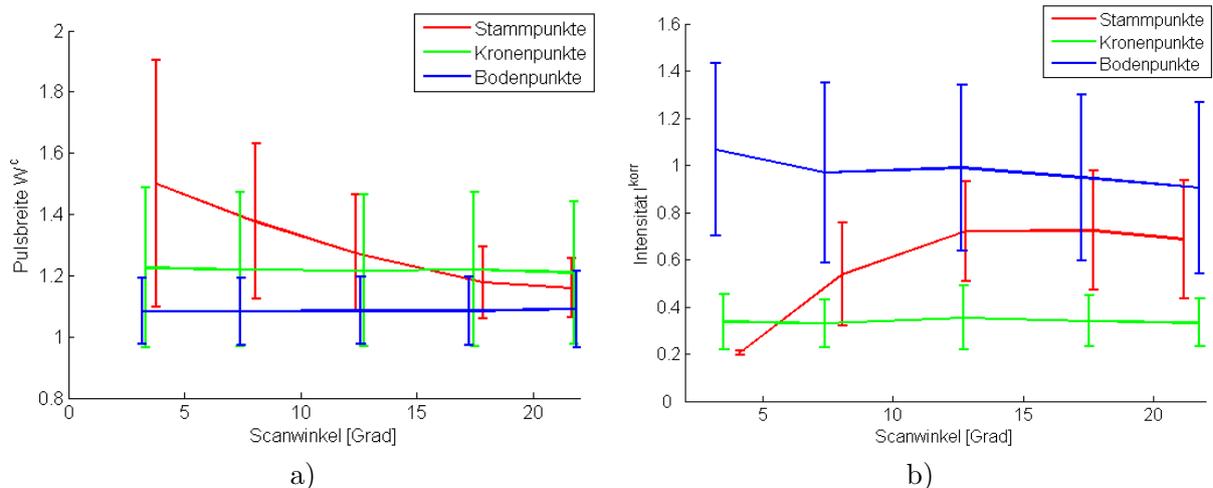


Abbildung 6.12: Analyse von Pulsbreite und Intensität für Stamm-, Kronen- und Bodenpunkte. a) Pulsbreite (nur Einzelpunkte und letzte Punkte) und b) Intensität (nur Einzelpunkte) in Abhängigkeit vom Scanwinkel. Die senkrechten Balken kennzeichnen den Wert der Standardabweichung.

Kronenpunkten deutlich durch eine niedrigere Pulsbreite und eine höhere Intensität. Kronenpunkte und Bodenpunkte zeigen keine Abhängigkeit vom Einfallswinkel. Bei den Stammpunkten hingegen nimmt die Pulsbreite bei steigendem Scanwinkel ab, was hauptsächlich für Einzelreflexionen und letzte Reflexionen zu beobachten ist. Die Intensität der Stammpunkte steigt bei größer werdendem Scanwinkel für alle Punktklassen. Besonders signifikant ist dieser Anstieg bei Einzelpunkten. Bei einem Scanwinkel im Bereich von 10° bis 22.5° lassen sich Stammpunkte und Kronenpunkte gut voneinander unterscheiden. In der Abbildung 6.12b sieht man, dass sich die einfachen Standardabweichungen in diesem Bereich nicht überlappen. Noch deutlicher ist der Unterschied zwischen Bodenpunkten und Kronenpunkten für alle Scanwinkel.

Eine wesentliche Fragestellung ist, ob sich die unterschiedlichen Baumarten in den Werten für die Intensität und Pulsbreite widerspiegeln. Hierzu werden die Kronen- und Stammpunkte mit Hilfe der Referenzdaten den beiden Baumarten Laubbaum und Nadelbaum zugeordnet. In den Abbildungen 6.13 und 6.14 sind wiederum die Mittelwerte und Standardabweichungen in Abhängigkeit vom Scanwinkel dargestellt. Man sieht, dass sich die mittlere Pulsbreite und Intensität der Kronenpunkte für die beiden Baumarten unterscheidet (Abbildungen 6.13a und 6.13b). Bei der Pulsbreite ist der Unterschied für

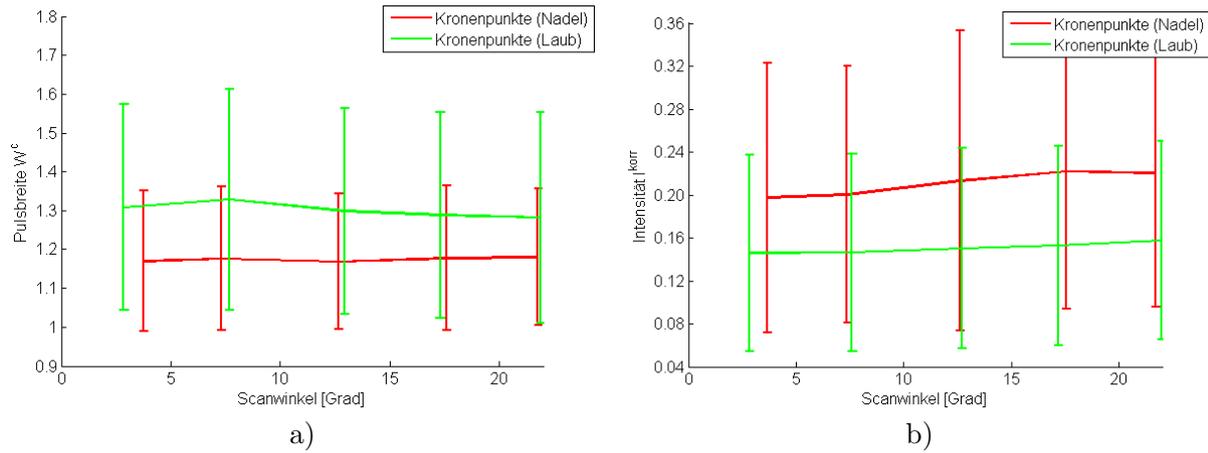


Abbildung 6.13: Analyse von Pulsbreite und Intensität für die Kronenpunkte von Laub- und Nadelbäumen. a) Pulsbreite (nur Einzelpunkte) und b) Intensität (alle Punkte) in Abhängigkeit vom Scanwinkel

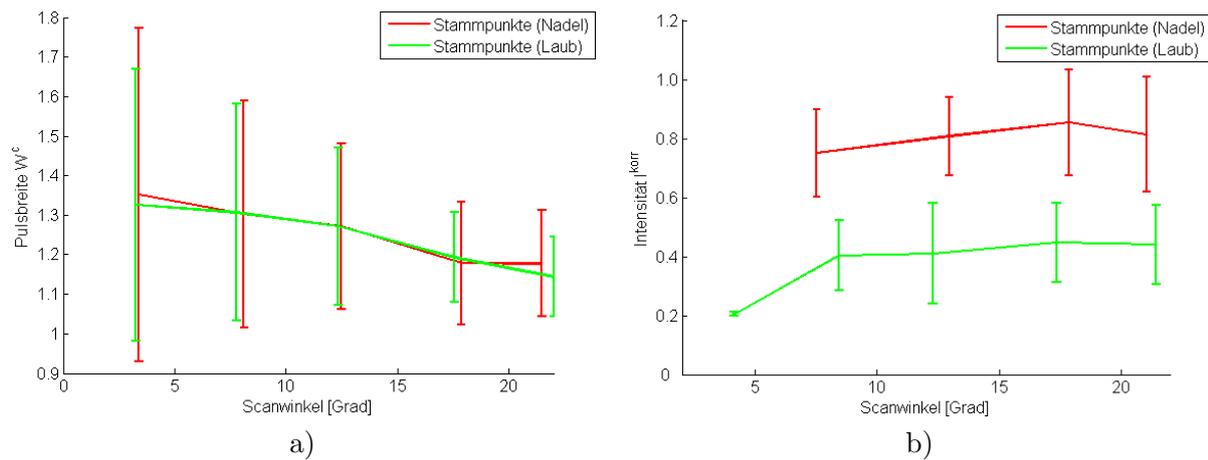


Abbildung 6.14: Analyse von Pulsbreite und Intensität für die Stammpunkte von Laub- und Nadelbäumen. a) Pulsbreite (alle Punkte) und b) Intensität (nur Einzelpunkte) in Abhängigkeit vom Scanwinkel

die Einzelpunkte am deutlichsten, wohingegen der Unterschied in der Intensität für alle Punktklassen in gleichem Maße auftritt. An den großen Standardabweichungen kann man erkennen, dass die Einzelwerte sehr stark streuen. Für eine Klassifikation sind deshalb nur Mittelwerte über ein bestimmtes Gebiet aussagekräftig. Betrachtet man die Stammpunkte für Laub- und Nadelbäume, so zeigt sich bei der Pulsbreite kein Unterschied für alle Punktklassen (Abbildung 6.14a). Die mittlere Intensität hingegen unterscheidet sich für beide Baumarten. Besonders ausgeprägt ist das bei den Einzelpunkten zu beobachten (Abbildung 6.14b).

6.2 Segmentierung

6.2.1 Evaluierung der Ergebnisse

Die Genauigkeit und Zuverlässigkeit der Methoden zur Einzelbaumerkennung werden mit Hilfe der Referenzdaten überprüft. Hierzu wird jeder Baum aus der Segmentierung mit dem entsprechenden Referenzbaum verlinkt, wenn bestimmte Schwellwerte bezüglich der Distanz und der Baumhöhe erfüllt sind. Wegen der Vergleichbarkeit der Ergebnisse werden dieselben Kriterien wie bei Heurich [2006] herangezogen. Damit eine eindeutige und optimale Verknüpfung zwischen Referenzbaum und Segment gewährleistet ist, wird folgendermaßen vorgegangen: Zuerst wird für jeden Referenzbaum geprüft, ob sich ein Baum aus der Segmentierung innerhalb eines Radius von 60 % des für die jeweilige Referenzfläche zutreffenden mittleren Baumabstands befindet und ob der Unterschied in der Baumhöhe kleiner als 15 % der Oberhöhe H_{100} ist. Werden beide Kriterien von mehreren Segmenten erfüllt, so wird das Segment mit dem geringsten Abstand zum Referenzbaum ausgewählt. Anschließend wird überprüft, ob nicht mehreren Referenzbäumen dasselbe Segment zugeordnet wurde. Sollte dies der Fall sein, bleibt nur die Zuordnung mit der geringsten Distanz bestehen. Im letzten Schritt werden nur die Referenzbäume und Segmente ohne Verknüpfung nochmals auf obige Kriterien überprüft. In seltenen Fällen können die Kriterien noch erfüllt sein, was durch die Auflösung nicht eindeutiger Verknüpfungen im vorhergehenden Schritt bedingt ist. Verknüpfte Referenzbäume werden als „erkannte Bäume“ und die restlichen als „nicht erkannte Bäume“ bezeichnet. Segmente ohne Zuordnung zu einem Referenzbaum werden als „falsche Segmente“ (= „false positives“) betrachtet.

6.2.2 Steuerparameter

Die verschiedenen Verfahren zur Einzelbaumerkennung sind von einer Reihe von Steuerparametern abhängig. Unter Verwendung der Referenzdaten werden in einer Sensitivitätsanalyse optimale Werte für diese Parameter ermittelt, die in der Tabelle 6.3 aufgeführt sind. In den folgenden Abschnitten wird auf die Bedeutung der einzelnen Werte eingegangen.

Watershed Segmentierung

Die Ergebnisse der Watershed Segmentierung hängen im Wesentlichen von der Beschaffenheit des CHM ab, da die Implementierung des Watershed Algorithmus keine Parameter zulässt. Für die Konstruktion des CHM ist die Zellgröße c_p bei der Filterung der höchsten Punkte, sowie die Gitterweite g_w und der Glättungsfaktor λ bei der CHM Interpolation entscheidend. Die Bedeutung der Glättung wird in der Abbildung 6.15 deutlich. Dort sind die Segmente verschiedener Glättungsstufen mit den Referenzdaten überlagert, wobei die gelben und blauen Punkte für die Positionen von Buchen bzw. Fichten stehen und die Größe der Punkte den Stammdurchmesser widerspiegelt. Bei geringer Glättung sieht man eine Übersegmentierung. Es entstehen sehr viele kleine Segmente, weil es in vielen Baumkronen mehrere lokale Maxima gibt. Vor allem bei Laubbäumen werden dann einzelne nach oben ragende Äste als eigene Bäume interpretiert. Ist die Glättung hingegen zu stark, werden mehrere Bäume zu einem Segment zusammengefasst. Die Auswirkungen von λ auf die Segmentierungsergebnisse sind in der Abbildung 6.16 beispielhaft für die Datensätze II und IV dargestellt. Man sieht, dass bei einem kleiner werdenden λ sowohl die Anzahl der richtig erkannten Bäume als auch die Anzahl der falschen Segmente zunimmt. Ab einem bestimmten Wert jedoch steigt die Anzahl der falschen Segmente stärker als die Anzahl der richtigen. Beim First/Last-Pulse Datensatz II ist dies für $\lambda = 3$ der Fall, bei den Full Waveform

| Verfahren | Steuerparameter | Datensätze | Wert |
|------------------------------|-----------------------|------------|-----------------|
| Watershed Segmentierung | c_p | alle | 0.5 m |
| | g_w | alle | 0.5 m |
| | λ | II | 3 |
| | | III-VI | 5 |
| Stammdetektion | H_{Schicht} | alle | 0.5 m |
| | S_{N_P} | alle | 0.15 |
| | D_{min} | alle | 1.2 m |
| | S_{Neigung} | alle | 7° |
| | H_{maxUnten} | alle | 10 m |
| | H_{minOben} | alle | 5 m |
| | L_{min} | alle | 3 m |
| Normalized Cut Segmentierung | L_V | alle | 0.5 m |
| | R_{XY} | alle | 4.5 m |
| | $NCut_{\text{max}}$ | II | 0.14 |
| | | III-VI | 0.16 |
| | N_{minV} | alle | 40 |
| | σ_{xy} | alle | 1.35 m |
| | σ_z | alle | 11 m |
| | σ_f | alle | 0.5 m |
| | σ_G | alle | 3.5 m |
| | U | alle | 2 m × 2 m × 6 m |
| | H_{V1V2} | alle | 12 m |
| | S_{minV1} | alle | 30 |
| | S_{minV2} | alle | 60 |
| | H_{minL} | alle | 10 m |
| | $H_{\text{Lücke}}$ | II | 3 m |
| | | III-VI | 2 m |

Tabelle 6.3: Gewählte Steuerparameter für die Verfahren zur Einzelbaumerkennung

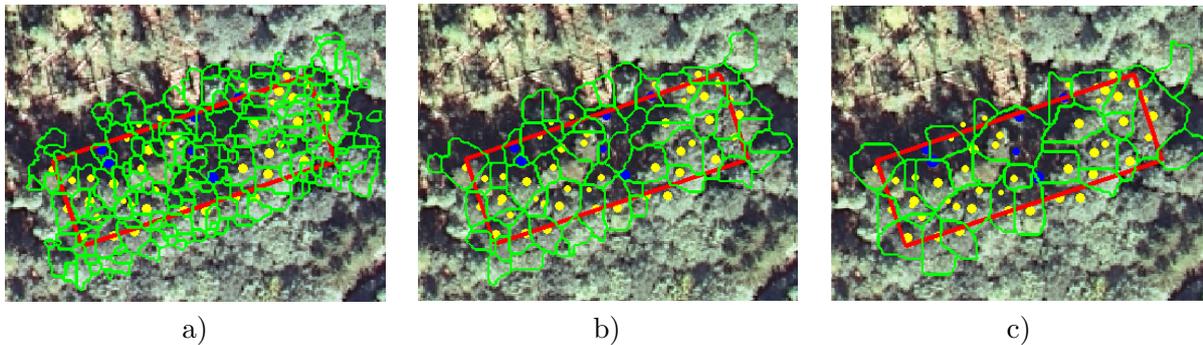


Abbildung 6.15: Watershed Segmente für verschiedene Glättungen des CHM. a) Geringe Glättung, b) mittlere Glättung, c) starke Glättung

Datensätzen III - VI für $\lambda = 5$. Diese Werte werden für die weiteren Auswertungen verwendet, weil hier die Differenz zwischen richtigen und falschen Segmenten maximal ist. In analoger Vorgehensweise erhält man $c_p = 0.5$ m und $g_w = 0.5$ m für alle Datensätze. Die CHM Interpolation wird mit dem Ansatz von D'Errico [2006] durchgeführt. Tests mit der Methode der finiten Elemente [Krzystek & Wild, 1992] ergeben nahezu identische Ergebnisse.

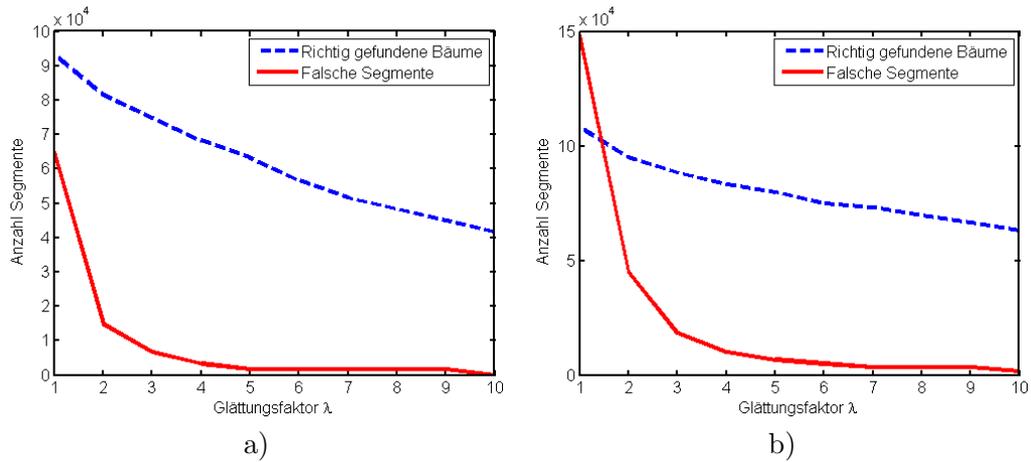


Abbildung 6.16: Abhängigkeit der Watershed Segmentierung vom Glättungsfaktor λ . a) für den Datensatz II, b) für den Datensatz IV

Stammdetektion

Auch bei der Stammdetektion gibt es eine Reihe von Parametern, deren Werte für eine erfolgreiche Anwendung dieser Methode maßgeblich sind. Für die Filterung der Stammpunkte ist die Höhe H_{Schicht} bei der Unterteilung der Baumpunkte in Höhengschichten und der Schwellwert S_{N_P} bei der Festlegung der Kronenansatzhöhe entscheidend (siehe Abschnitt 3.2.2). Beide Werte sind aneinander gekoppelt, da bei einem höheren Wert für H_{Schicht} die Anzahl der Reflexionen pro Schicht zunimmt und somit auch S_{N_P} erhöht werden muss. Bei der Analyse mit Hilfe der Referenzdaten zeigen sich die Werte $H_{\text{Schicht}} = 0.5 \text{ m}$ und $S_{N_P} = 0.15$ als optimal für alle Datensätze. Dasselbe gilt für den Mindestabstand $D_{\text{min}} = 1.2 \text{ m}$ beim hierarchischen Clustering. Zum Aussortieren falscher Stammcluster, die sich z.B. aus Reflexionen von Ästen oder vom Unterstand zusammensetzen können, erweist sich eine maximal zulässige Neigung $S_{\text{Neigung}} = 7^\circ$ für die angepassten Geraden als geeignet. Fehlerhafte Stämme, die zufällig die Neigungsvoraussetzung erfüllen, werden mit folgenden Kriterien effektiv entfernt: Die unterste Stammreflexion darf nicht höher als $H_{\text{maxUnten}} = 10 \text{ m}$ über dem Boden liegen. Außerdem muss die oberste Stammreflexion mindestens $H_{\text{minOben}} = 5 \text{ m}$ über dem Boden liegen und die Länge des Stamms mindestens $L_{\text{min}} = 3 \text{ m}$ betragen.

Normalized Cut Segmentierung

Auch die Normalized Cut Segmentierung wird von mehreren Steuerparametern beeinflusst, für die geeignete Werte ermittelt werden. Die Kantenlänge L_V bei der Voxelbildung wird dabei auf 0.5 m gesetzt. Der Radius R_{XY} , der den maximalen Bereich für Berechnung von Ähnlichkeitswerten festlegt, beträgt 4.5 m. Ein sehr wichtiger Parameter ist der Schwellwert $NCut_{\text{max}}$, der maßgeblich für den Abbruch des hierarchischen Ablaufschemas verantwortlich ist. In der Abbildung 6.17 ist die Anzahl der richtigen und falschen Segmente in Abhängigkeit von $NCut_{\text{max}}$ für den Datensatz IV dargestellt. Man sieht, dass die Anzahl der falschen Segmente ab einem Wert von 0.16 stärker ansteigt als die Anzahl der richtigen Segmente, weshalb dieser Wert für die Auswertungen verwendet wird. Auch bei den anderen Full Waveform Datensätzen ist dieser Wert optimal. Beim First/Last-Pulse Datensatz II wird $NCut_{\text{max}} = 0.14$ verwendet. Der Schwellwert N_{minV} , der die Anzahl von Voxel vorgibt, ab der die Segmente nicht mehr weiter geteilt werden, wird für alle Datensätze auf 40 gesetzt. Für die Parameter

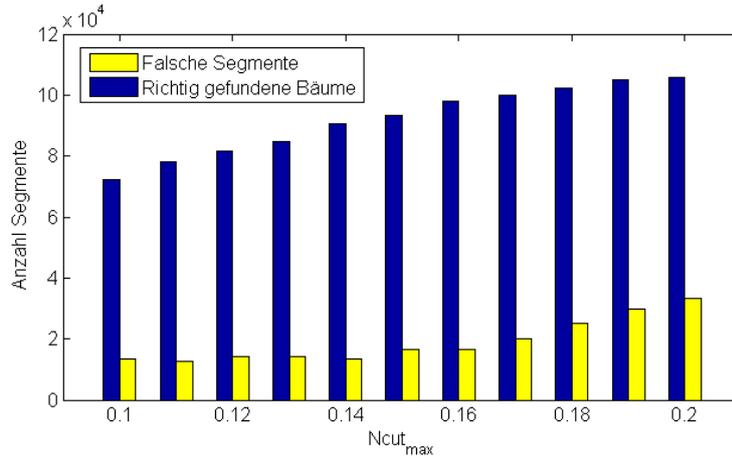


Abbildung 6.17: Abhängigkeit der Normalized Cut Segmentierung vom Schwellwert $Ncut_{max}$

zur Kontrolle der unterschiedlichen Einflussfaktoren in der Ähnlichkeitsfunktion (3.11) werden die Werte $\sigma_{xy} = 1.35$ m, $\sigma_z = 11$ m, $\sigma_f = 0.5$ m und $\sigma_G = 3.5$ m verwendet. Mit dem größeren Wert von σ_z im Vergleich zu σ_{xy} wird der Tatsache Rechnung getragen, dass die vertikale Ausdehnung von Bäumen größer ist als ihre horizontale Ausdehnung. Die Umgebung U für die Berechnung der Merkmale Intensität und Pulsbreite entspricht einem Quader mit 2 m \times 2 m Kantenlänge in der Lage und 6 m in der Höhe. Wie im Abschnitt 3.3.7 beschrieben, werden die 3D Segmente in einfacher Weise nachbearbeitet: Segmente mit weniger als $S_{minV1} = 30$ Voxel werden eliminiert, weil solche Segmente zu klein sind, um einen in den Referenzdaten erfassten Baum zu präsentieren. Befindet sich das höchste Voxel mehr als $H_{V1V2} = 12$ m über dem Boden, so wird diese Mindestzahl auf $S_{minV2} = 60$ Voxel erhöht, da korrekte Segmente so hoher Bäume in der Regel aus mehr Voxeln bestehen. Die Schwellwerte S_{minV1} und S_{minV2} beziehen sich hierbei auf die verwendete Kantenlänge L_V der Voxel von 0.5 m und müssen bei einer Veränderung von L_V entsprechend angepasst werden. Besitzt ein Segment ab einer Höhe von $H_{minL} = 10$ m vertikale Lücken von mehr als $H_{Lücke} = 2$ m, so werden die Reflexionen oberhalb der Lücke entfernt. Dadurch können bei Segmenten dominierter Bäume die manchmal enthaltenen Äste darüber stehender Bäume beseitigt werden. Bei den First/Last-Pulse Daten wird $H_{Lücke}$ auf 3 m erhöht, weil hier wegen der niedrigeren räumlichen Punktdichte auch in korrekten Segmenten Lücken von bis zu 2 m auftreten können.

6.2.3 Durchführung und Kombination der Verfahren

Zuerst wird die Watershed Segmentierung (Abschnitt 3.1) für die verschiedenen Datensätze auf den Referenzflächen angewendet. Das Ergebnis sind die Baumpositionen $(X_{Baum}^{CHM}, Y_{Baum}^{CHM})$ aus den lokalen Maxima, die Baumhöhen Z_{Baum}^{CHM} aus dem jeweils höchsten Punkt im Segment und die Segmentgrenzen.

Als zweites Verfahren wird die Stammdetektion (Abschnitt 3.2) für jedes Watershed Segment durchgeführt. In Abhängigkeit von der Anzahl der gefundenen Stämme werden drei Fälle unterschieden:

1. Wenn kein Stamm identifiziert werden kann, bleiben Baumposition und -höhe unverändert.
2. Bei einem Stamm wird die Baumposition durch den genaueren Wert $(X_{Baum}^{StDet}, Y_{Baum}^{StDet})$ ersetzt. Die Baumhöhe bleibt unverändert.

3. Bei mehreren Stämmen wird die Baumposition und -höhe durch $(X_{\text{Baum } i}^{\text{StDet}}, Y_{\text{Baum } i}^{\text{StDet}}, Z_{\text{Baum } i}^{\text{StDet}})(i = 1, \dots, N_{\text{StDet}})$ ersetzt. Es werden also zusätzliche Bäume gefunden, die im CHM kein eigenes lokales Maximum besitzen. Eine Zuordnung der Laserpunkte zum jeweiligen Baum findet jedoch nicht statt.

Als drittes Verfahren wird die Normalized Cut Segmentierung ausgeführt. Je nach Parametrisierung der Ähnlichkeitsfunktion (Abschnitt 3.3.4) gibt es hier verschiedene Möglichkeiten, die unterschiedliche Anforderungen an die Eingangsdaten stellen. In der Tabelle 6.4 sind die verwendeten Optionen aufgeführt. Bei NCut_K und NCut_{KM} besteht keine Abhängigkeit von der Watershed Segmentierung

| Abkürzung | Parametrisierung der Ähnlichkeitsfunktion |
|---------------------------|--|
| NCut_K | Koordinaten |
| NCut_{KM} | Koordinaten, Merkmale |
| NCut_{KP_W} | Koordinaten, Baumpositionen (Watershed) |
| $\text{NCut}_{KP_{W+S}}$ | Koordinaten, Baumpositionen (Watershed + Stämme) |
| $\text{NCut}_{KMP_{W+S}}$ | Koordinaten, Merkmale, Baumpositionen (Watershed + Stämme) |

Tabelle 6.4: Verschiedene Parametrisierungen der Ähnlichkeitsfunktion (3.11) bei der Normalized Cut Segmentierung

und der Stammdetektion und es werden lediglich die Laserpunkte X ohne oder mit Attribute verwendet. Bei den restlichen Optionen fließen die Resultate der vorangegangenen beiden Methoden in das Verfahren mit ein. Als Ergebnis der Normalized Segmentierung erhält man eine Zuordnung der Laserpunkte X zu den jeweiligen Segmenten, woraus die Charakteristiken des Baums abgeleitet werden können. So wird als Baumhöhe wiederum die Höhe des höchsten Punktes über dem Boden verwendet. Die Baumposition und der Umriss der Krone können aus den Lagekoordinaten der Punkte durch Berechnung des Schwerpunkts und der konvexen Hülle ermittelt werden.

6.2.4 Vergleich der Resultate für die verschiedenen Verfahren

Zuerst werden die Ergebnisse der verschiedenen Methoden anhand des Datensatz IV miteinander verglichen (Tabelle 6.5). Hierbei steht die Abkürzung „W“ für die Watershed Segmentierung und

| Methode | Gefundene Bäume [%] | | | | Falsche Segmente [%] |
|---------------------------|---------------------|-----------------|-------------|--------|----------------------|
| | Unterschicht | Zwischenschicht | Oberschicht | Gesamt | |
| W | 5 | 21 | 77 | 48 | 4 |
| W + S | 7 | 27 | 82 | 52 | 5 |
| NCut_K | 18 | 32 | 77 | 53 | 6 |
| NCut_{KM} | 19 | 35 | 77 | 54 | 6 |
| NCut_{KP_W} | 20 | 36 | 83 | 57 | 9 |
| $\text{NCut}_{KP_{W+S}}$ | 20 | 37 | 86 | 59 | 9 |
| $\text{NCut}_{KMP_{W+S}}$ | 21 | 38 | 87 | 60 | 9 |

Tabelle 6.5: Segmentierungsergebnisse unter Verwendung des **Datensatz IV** (Riegl, Full Waveform, 25 Punkte/m², unbelaubt) für **alle Teilgebiete**

„W+S“ für die Kombination von Watershed Segmentierung und Stammdetektion. Die Variationen der Normalized Cut Segmentierung werden so bezeichnet wie in der Tabelle 6.4. Bei der Watershed

Segmentierung beträgt die Erkennungsrate insgesamt 48 %, wobei in der Unterschicht nur sehr wenige Bäume gefunden werden. Eine Kombination der Watershed Segmentierung mit der Stammerkennung wirkt sich vor allem in der Zwischen- und Oberschicht positiv aus, so dass sich die Gesamterkennung um 4 % verbessert. Neben der Erkennungsrate wird auch die Genauigkeit der Baumpositionen durch die Stammerkennung verbessert. Die Tabelle 6.6 enthält die mittleren Positionsfehler für die Watershed Segmentierung und deren Kombination mit der Stammdetektion. Bei den Nadelbäumen

| | Watershed | Watershed + Stammdetektion |
|--|-----------|----------------------------|
| Mittlerer Positionsfehler (Nadelbäume) | 0.83 m | 0.68 m |
| Mittlerer Positionsfehler (Laubbäume) | 1.49 m | 1.12 m |
| Mittlerer Positionsfehler (Gesamt) | 1.17 m | 0.91 m |

Tabelle 6.6: Genauigkeit der Baumpositionen für den Datensatz IV (Full Waveform, 25 Punkte/m², unbelaubt)

verbessert sich die Position im Mittel um 15 cm ($\cong 18\%$), bei den Laubbäumen sogar um 37 cm ($\cong 25\%$). Insgesamt beträgt die Verbesserung der Baumpositionen 26 cm ($\cong 22\%$). Die Normalized Cut Segmentierung erhöht die Erkennungsrate in der Unter- und Zwischenschicht erheblich. Je nach Parametrisierung der Ähnlichkeitsfunktion liegt die Steigerung zwischen 11 % und 17 % im Vergleich zur Watershed Segmentierung. Wenn nur die Koordinaten der Voxel und die zusätzlichen Merkmale als Ähnlichkeitsmaße verwendet werden, kann die Erkennungsrate in der Oberschicht nicht gesteigert werden und ist sogar etwas geringer als bei der Kombination von Watershed und Stammerkennung. Erst wenn die Baumpositionen aus diesen beiden Verfahren als Vorwissen in die Normalized Cut Segmentierung integriert werden, können auch in der Oberschicht wesentlich mehr Bäume erkannt werden. Das Einbringen der Merkmale Intensität und Pulsbreite zeigt nur eine geringe Verbesserung, die jedoch in allen drei Schichten zu beobachten ist. Insgesamt kann die Erkennungsrate durch die Stammerkennung und das Normalized Cut Verfahren um 12 % gesteigert werden, wobei der Vorteil in der Unter- und Zwischenschicht mit ca. 16 % sehr deutlich ist. In der Abbildung 6.18 ist diese Verbesserung der Detektionsrate grafisch dargestellt, wobei die Bäume abhängig vom BHD in verschiedene Durchmesserstufen aufgeteilt sind. Man sieht eine beträchtliche Verbesserung durch die Normalized Cut

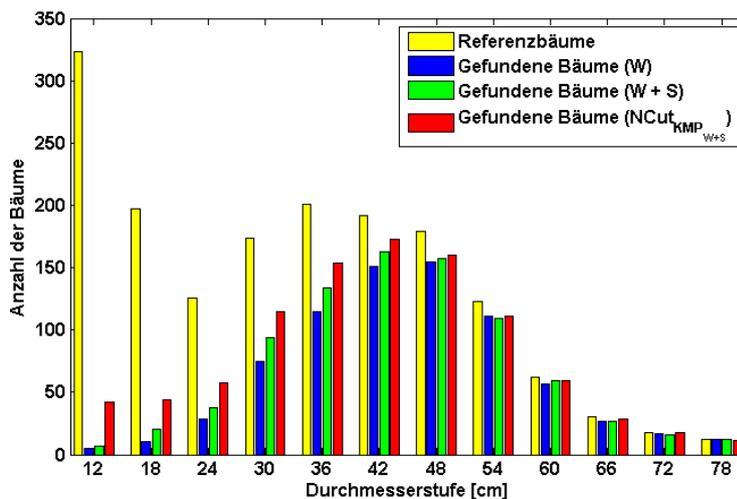


Abbildung 6.18: Gefundene Bäume in Abhängigkeit vom BHD für den Datensatz IV

Segmentierung bei den kleinen Bäumen, die jedoch mit steigendem Stammdurchmesser schrittweise abnimmt. Die Abbildungen 6.19 und 6.20 enthalten die Erkennungsraten der verschiedenen Verfahren getrennt für Laub- und Nadelbäume. Insbesondere bei den Laubbäumen ist die Steigerung bei ei-

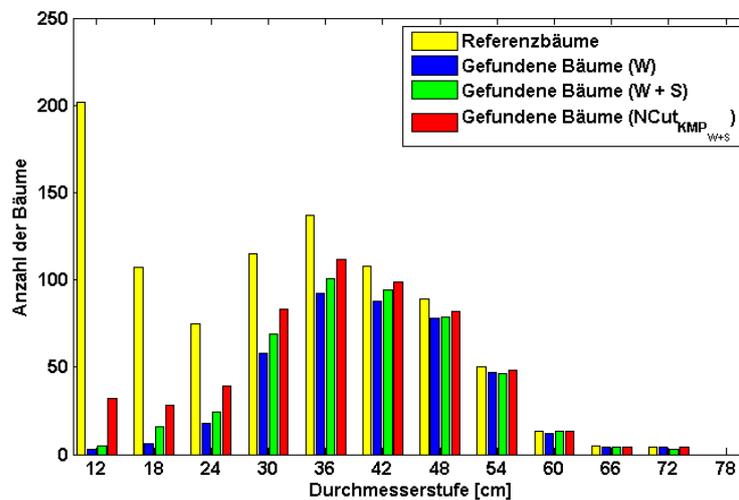


Abbildung 6.19: Gefundene Bäume in Abhängigkeit vom BHD für den Datensatz IV (nur Laubbäume)

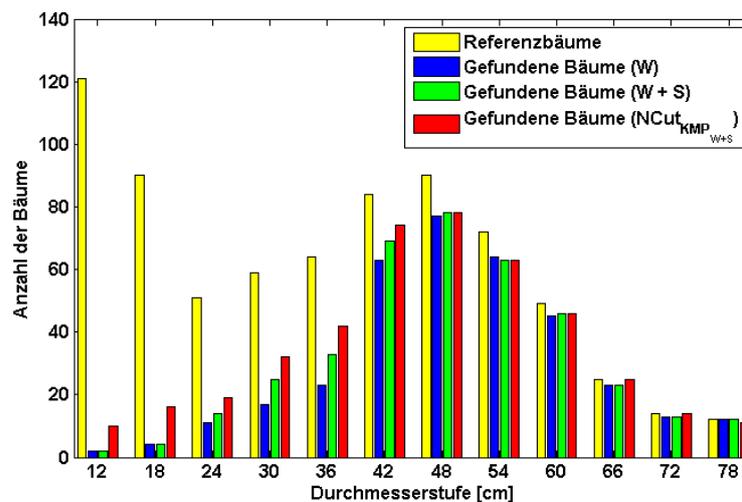


Abbildung 6.20: Gefundene Bäume in Abhängigkeit vom BHD für den Datensatz IV (nur Nadelbäume)

nem BHD bis 12 cm sehr ausgeprägt. Die Watershed Segmentierung und die automatische Detektion von Stämmen versagen hier fast komplett. In den Grafiken ist neben dem Fortschritt durch das neue Verfahren auch zu erkennen, dass immer noch viele kleine Bäume unerkannt bleiben. Wenn mehrere Bäume sehr eng beieinander stehen und eine fast homogene Punktwolke bilden, ist auch bei der Normalized Cut Segmentierung eine Trennung schwierig. In der Abbildung 6.21 sind Beispiele hierfür dargestellt. Vor allem bei kleineren Bäumen ist dies häufig der Fall, wie die Abbildung 6.22 zeigt. Diese Bäume gelten in der Statistik als nicht erkannt, weil die Position und Höhe aus den Segmenten nicht zu den Referenzbäumen passt. Hervorzuheben ist jedoch, dass der Unterstand und die dominanten

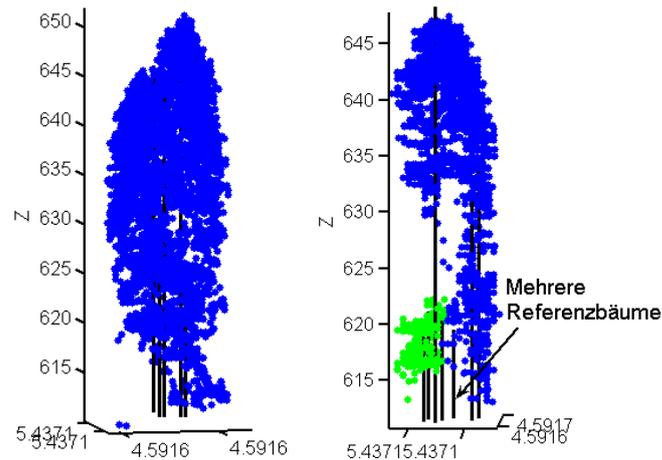


Abbildung 6.21: Beispiele für die Zusammenfassung mehrerer Bäume

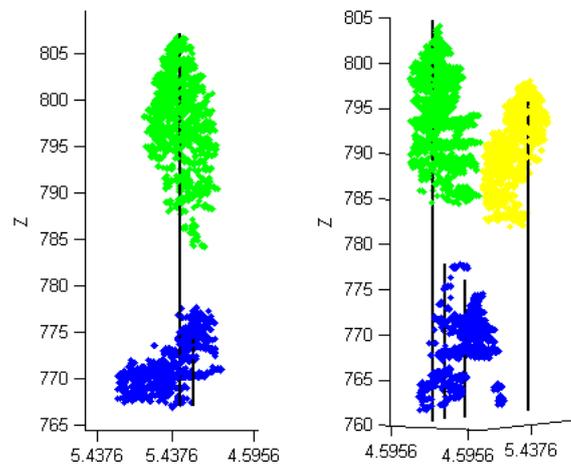


Abbildung 6.22: Beispiele für mehrere kleine Bäume in einem Segment (blau)

Bäume häufig voneinander getrennt werden können und somit die Segmente der großen Bäume nicht verfälscht werden. Ein weiterer wichtiger Aspekt ist, dass bei der 3D Segmentierung auch eine Steigerung der falschen Segmente stattfindet, die jedoch deutlich kleiner ist als die Zunahme der richtigen Segmente. Am stärksten wächst die Anzahl der falschen Segmente bei der Integration der Watershed Resultate in das Normalized Cut Verfahren, weil damit natürlich auch Fehler übernommen werden. Die Ursachen für fehlerhafte Segmente sind vielfältig. Die Abbildung 6.23 enthält zwei Beispiele. In einem Fall werden fälschlicherweise dem kleineren Baum Äste des großen Baums zugeordnet, wodurch das kleinere Segment komplett und das große Segment teilweise falsch wird. Im anderen Fall wird aus den Kronen von zwei breiten Bäumen ein zusätzliches drittes Segment gebildet, für das es keinen Referenzbaum gibt.

6.2.5 Belaubter und unbelaubter Vegetationszustand

Die Ergebnisse in der Tabelle 6.5 beziehen sich auf Daten, die im unbelaubten Vegetationszustand erfasst wurden (Datensatz IV). Außerdem wurde für alle Referenzflächen eine Befliegung im belaubten Zustand mit nahezu identischen Aufnahmeparametern durchgeführt (Datensatz V), so dass ein Ver-

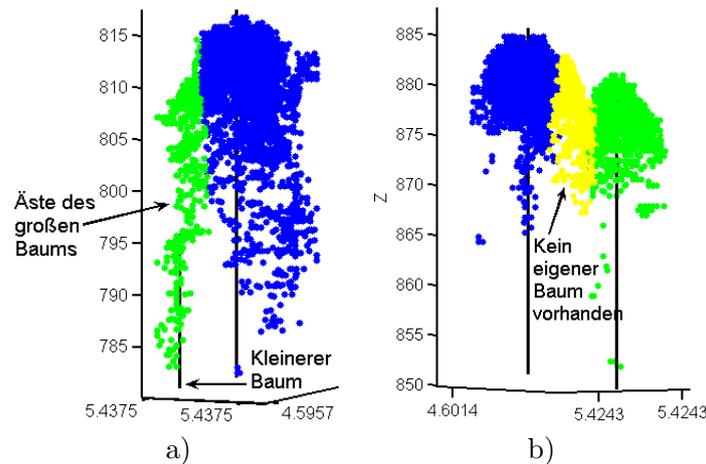


Abbildung 6.23: Beispiele für falsche Segmente

gleich der beiden Vegetationszustände möglich ist. Die Segmentierungsergebnisse für den Datensatz V sind in der Tabelle 6.7 aufgelistet. Der Vergleich mit der Tabelle 6.5 zeigt, dass die Ergebnisse der Watershed Segmentierung und der Stammerkennung fast identisch sind für alle Schichten. Bei der Normalized Cut Segmentierung verschlechtert sich die Erkennungsrate in der Unter- und Zwischenschicht um ungefähr 5 %, und für alle Schichten um 2 %. Die Anzahl der falschen Segmente ändert sich kaum.

| Methode | Gefundene Bäume [%] | | | | Falsche Segmente [%] |
|-----------------------------------|---------------------|-----------------|-------------|--------|----------------------|
| | Unterschicht | Zwischenschicht | Oberschicht | Gesamt | |
| W | 5 | 20 | 79 | 48 | 4 |
| W + S | 6 | 27 | 83 | 52 | 6 |
| NCut _K | 13 | 29 | 73 | 49 | 7 |
| NCut _{KM} | 16 | 29 | 73 | 50 | 7 |
| NCut _{KP_W} | 15 | 29 | 82 | 54 | 9 |
| NCut _{KP_{W+S}} | 15 | 31 | 86 | 57 | 10 |
| NCut _{KMP_{W+S}} | 17 | 32 | 86 | 58 | 10 |

Tabelle 6.7: Segmentierungsergebnisse unter Verwendung des **Datensatz V** (Riegl, Full Waveform, 25 Punkte/m², belaubt) für **alle Teilgebiete**

6.2.6 Einfluss der Punktdichte

Damit der Einfluss der Punktdichte auf die Segmentierungsergebnisse untersucht werden kann, wurde das Teilgebiet E zusätzlich mit einer niedrigeren Dichte von 10 Punkten/m² befliegen (Datensatz VI). Ein genauer Vergleich mit dem Datensatz V macht es notwendig, auch diese Daten nur für das Gebiet E auszuwerten. Die Tabellen 6.8 und 6.9 enthalten die Ergebnisse der beiden Datensätze. Der Vergleich zeigt, dass sich die Erkennungsraten bei der Normalized Cut Segmentierung kaum unterscheiden. Das Resultat der Watershed Segmentierung ist bei der niedrigen Dichte sogar leicht besser. Nur bei der Stammerkennung wirkt sich die höhere Punktdichte positiv aus, so dass beim Datensatz V das Ergebnis der Watershed Segmentierung um 5 % verbessert wird.

| Methode | Gefundene Bäume [%] | | | | Falsche Segmente [%] |
|-----------------------------------|---------------------|-----------------|-------------|--------|----------------------|
| | Unterschicht | Zwischenschicht | Oberschicht | Gesamt | |
| W | 5 | 20 | 82 | 55 | 5 |
| W + S | 6 | 29 | 87 | 60 | 7 |
| NCut _K | 18 | 27 | 75 | 55 | 7 |
| NCut _{KM} | 23 | 29 | 76 | 57 | 7 |
| NCut _{KP_W} | 21 | 31 | 84 | 62 | 10 |
| NCut _{KP_{W+S}} | 21 | 32 | 88 | 65 | 11 |
| NCut _{KMP_{W+S}} | 24 | 35 | 88 | 66 | 11 |

Tabelle 6.8: Segmentierungsergebnisse unter Verwendung des **Datensatz V** (Riegl, Full Waveform, 25 Punkte/m², belaubt) für das **Teilgebiet E**

| Methode | Gefundene Bäume [%] | | | | Falsche Segmente [%] |
|-----------------------------------|---------------------|-----------------|-------------|--------|----------------------|
| | Unterschicht | Zwischenschicht | Oberschicht | Gesamt | |
| W | 6 | 21 | 84 | 57 | 6 |
| W + S | 7 | 22 | 86 | 58 | 7 |
| NCut _K | 19 | 29 | 75 | 56 | 9 |
| NCut _{KM} | 23 | 31 | 76 | 57 | 8 |
| NCut _{KP_W} | 21 | 32 | 85 | 63 | 11 |
| NCut _{KP_{W+S}} | 21 | 32 | 87 | 64 | 11 |
| NCut _{KMP_{W+S}} | 26 | 33 | 87 | 65 | 11 |

Tabelle 6.9: Segmentierungsergebnisse unter Verwendung des **Datensatz VI** (Riegl, Full Waveform, 10 Punkte/m², belaubt) für das **Teilgebiet E**

6.2.7 Vergleich von First/Last-Pulse und Full Waveform

Mit Hilfe der Datensätze II und VI ist ein Vergleich der Segmentierungsmethoden für First/Last-Pulse und Full Waveform Daten mit derselben nominalen Punktdichte und für denselben Belaubungszustand möglich. Die Tabelle 6.10 enthält die Ergebnisse des Datensatz II nur für das Gebiet E, so dass direkt mit der Tabelle 6.9 verglichen werden kann. Man sieht, dass die Erkennungsraten für die Full Waveform

| Methode | Gefundene Bäume [%] | | | | Falsche Segmente [%] |
|-----------------------------------|--------------------------|-----------------|-------------|--------|----------------------|
| | Unterschicht | Zwischenschicht | Oberschicht | Gesamt | |
| W | 2 | 12 | 80 | 52 | 5 |
| W + S | 3 | 13 | 80 | 52 | 6 |
| NCut _K | 14 | 25 | 65 | 47 | 10 |
| NCut _{KM} | Keine Merkmale vorhanden | | | | |
| NCut _{KP_W} | 15 | 28 | 77 | 55 | 13 |
| NCut _{KP_{W+S}} | 15 | 27 | 77 | 55 | 13 |
| NCut _{KMP_{W+S}} | Keine Merkmale vorhanden | | | | |

Tabelle 6.10: Segmentierungsergebnisse unter Verwendung des **Datensatz II** (TopoSys, First/Last-Pulse, 10 Punkte/m², belaubt) für das **Teilgebiet E**

Daten wesentlich höher sind als für die First/Last-Pulse Daten. Sogar die CHM basierende Watershed Segmentierung, bei der man den geringsten Unterschied erwartet, ist beim Datensatz VI um 5 %

besser. Zur Verdeutlichung sind in der Abbildung 6.24 die Laserpunkte beider Datensätze für zwei benachbarte Fichten dargestellt. Man kann erkennen, dass die Baumkronen bei den Full Waveform

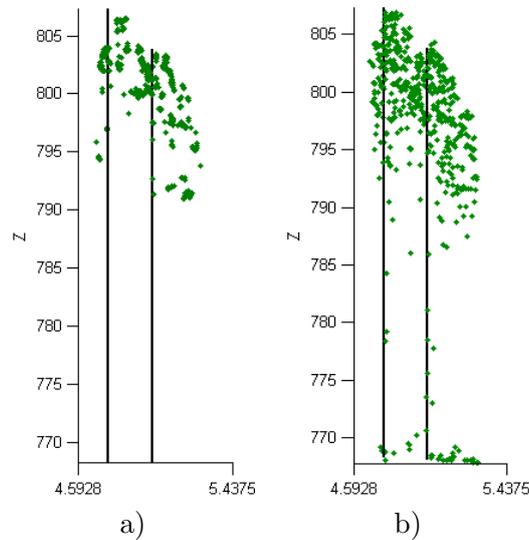


Abbildung 6.24: Vergleich von First/Last-Pulse und Full Waveform für zwei benachbarte Fichten. a) Punkte vom TopoSys Scanner, b) Punkte aus den Echoprofilen des Riegl Scanners

Daten viel detaillierter abgebildet werden. Das liegt vor allem an den zusätzlichen Punkten zwischen der ersten und der letzten Reflexion und an der guten Trennbarkeit benachbarter Reflexionen bei der Waveform Zerlegung. Als Beispiel hierfür ist in der Abbildung 6.25 eine Waveform dargestellt, von der die beiden schwarz markierten Kronenpunkte mit einem Abstand von nur ca. 1 m abgeleitet wurden. Bei der Normalized Cut Segmentierung zeichnet sich der Vorteil der Full Waveform Daten

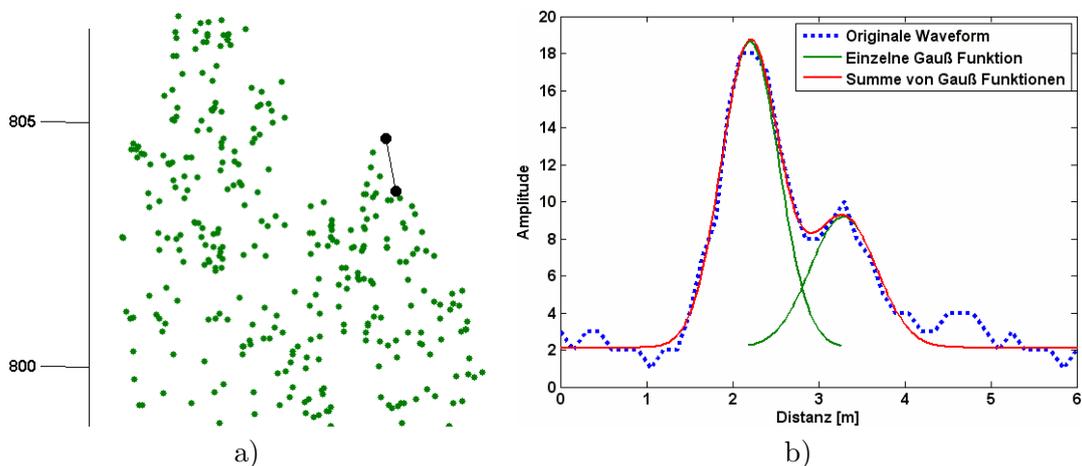


Abbildung 6.25: Beispiel für die gute Auflösung von Kronenstrukturen durch die Waveform Zerlegung. a) Detaillierte Darstellung der Kronenpunkte aus der Abbildung 6.24b, b) Waveform der beiden schwarz markierten Punkte

noch klarer in den Ergebnissen ab. Hier beträgt die Erkennungsrate 65 % und ist somit um 10 % besser als mit den First/Last-Pulse Daten. Bemerkenswert ist aber, dass bei der Normalized Cut Segmentierung die Detektionsrate in den unteren beiden Schichten selbst für die First/Last-Pulse

Daten steigt. Vergleicht man die Ergebnisse der Normalized Cut Segmentierung für die Full Waveform Daten mit den Ergebnissen der Watershed Segmentierung für die First/Last-Pulse Daten, so ist die Verbesserung sehr signifikant und beträgt in den unteren Schichten mehr als 20 %. In der Abbildung 6.26 wird dieser Fortschritt, der sowohl technologisch als auch methodisch bedingt ist, an einem Beispiel verdeutlicht. In 6.26A sind die Laserpunkte von vier Bäumen und in 6.26B die Segmentgrenzen im

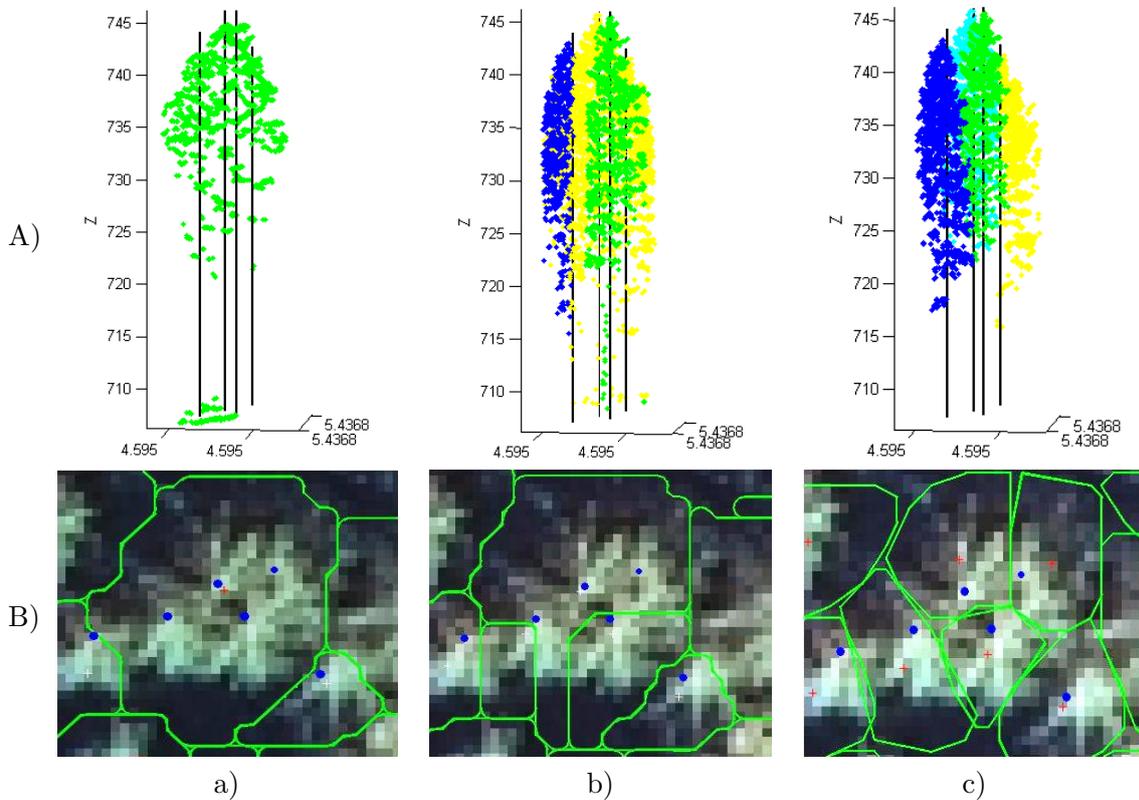


Abbildung 6.26: Beispiel für den sowohl technologisch als auch methodisch bedingten Fortschritt. a) Segmentierungsergebnisse für First/Last-Pulse und Watershed, b) für Full Waveform und Watershed, c) für Full Waveform und Normalized Cut

zugehörigen Orthofoto für drei verschiedene Konstellationen dargestellt. Die Abbildung 6.26a zeigt, dass die First/Last-Pulse Punkte der Bäume in der Watershed Segmentierung zu einem Segment zusammengefasst werden. Verwendet man die Full Waveform Daten von exakt demselben Gebiet, so werden die Bäume viel detaillierter abgebildet und selbst bei der Watershed Segmentierung entstehen drei Segmente (Abbildung 6.26b). Wendet man schließlich die Normalized Cut Segmentierung auf die Full Waveform Daten an, so erhält man vier Segmente und somit das optimale Ergebnis (Abbildung 6.26c).

6.2.8 Vergleich der beiden Full Waveform Systeme

Eine Anwendung der Segmentierungsverfahren auf die Datensätze III und V ermöglicht einen Vergleich zwischen den beiden Full Waveform Systemen von Riegl und TopEye (Tabellen 6.11 und 6.12). Da der TopEye Datensatz nur die beiden Referenzflächen 74 und 81 umfasst, bezieht sich die Auswertung der Riegl Daten auch nur auf diese Flächen. Der größte Unterschied in den Ergebnissen ist bei der Stammerkennung (W+S) zu beobachten, die beim Datensatz V die Erkennungsrate um 9 % verbessert,

beim Datensatz III jedoch nur um 3 %. Beim Einbringen der Stammpositionen in das Normalized Cut Verfahren setzt sich dieser Vorteil fort, so dass bei den Riegl Daten das Endergebnis um 5 % besser ist.

| Methode | Gefundene Bäume [%] | | | | Falsche Segmente [%] |
|-----------------------------------|---------------------|-----------------|-------------|--------|----------------------|
| | Unterschicht | Zwischenschicht | Oberschicht | Gesamt | |
| W | 0 | 3 | 69 | 47 | 1 |
| W + S | 0 | 4 | 71 | 50 | 2 |
| NCut _K | 0 | 2 | 58 | 40 | 3 |
| NCut _{KM} | 0 | 4 | 59 | 41 | 3 |
| NCut _{KP_W} | 0 | 2 | 70 | 48 | 3 |
| NCut _{KP_{W+S}} | 0 | 3 | 73 | 50 | 4 |
| NCut _{KMP_{W+S}} | 0 | 4 | 72 | 50 | 4 |

Tabelle 6.11: Segmentierungsergebnisse unter Verwendung des **Datensatz III** (TopEye, Full Waveform, 25 Punkte/m², belaubt) für die **Referenzflächen 74 und 81**

| Methode | Gefundene Bäume [%] | | | | Falsche Segmente [%] |
|-----------------------------------|---------------------|-----------------|-------------|--------|----------------------|
| | Unterschicht | Zwischenschicht | Oberschicht | Gesamt | |
| W | 0 | 0 | 70 | 47 | 1 |
| W + S | 0 | 12 | 80 | 56 | 5 |
| NCut _K | 2 | 2 | 55 | 38 | 4 |
| NCut _{KM} | 2 | 2 | 57 | 40 | 4 |
| NCut _{KP_W} | 0 | 5 | 71 | 49 | 3 |
| NCut _{KP_{W+S}} | 0 | 7 | 78 | 54 | 5 |
| NCut _{KMP_{W+S}} | 0 | 8 | 79 | 55 | 5 |

Tabelle 6.12: Segmentierungsergebnisse unter Verwendung des **Datensatz V** (Riegl, Full Waveform, 25 Punkte/m², belaubt) für die **Referenzflächen 74 und 81**

6.3 Baumartenklassifikation

Um die Wirksamkeit der im Abschnitt 4.1 beschriebenen Merkmale zu untersuchen, werden diese für die Segmente auf den Referenzflächen abgeleitet und in einer Baumartenklassifikation eingesetzt. Die Anzahl l der Höenschichten wird bei den Merkmalen S_g^2 , S_i^d , S_i^h und S_I^1 auf 10 gesetzt. Bei S_g^2 und S_I^1 werden nur die Werte der obersten Schicht verwendet, weil die unteren Schichten manchmal zu wenige Reflexionen beinhalten, um daraus repräsentative Werte abzuleiten. So kann es z.B. bei S_I^1 vorkommen, dass in einer Schicht nur ein paar Stammtreffer mit einer hohen Intensität vorhanden sind, wohingegen andere Bäume von der gleichen Art in dieser Schicht keine Stammtreffer haben.

Aus der Verknüpfung von Referenzbäumen und Segmenten (Abschnitt 6.2.1) ist für jedes Segment die entsprechende Referenzbaumart bekannt, so dass eine genaue Kontrolle der Klassifikationsergebnisse möglich ist. Es wird für alle Segmente der verschiedenen Datensätze eine unüberwachte K-Means Klassifikation, eine unüberwachte Expectation-Maximization (EM) Klassifikation und eine überwachte Maximum-Likelihood (ML) Klassifikation durchgeführt. Bei der überwachten Klassifikation wird für jede zu klassifizierende Baumart ein Fünftel der Bäume zufällig als Trainingsdaten ausgewählt. Die

Klassifikationen werden für jeden Datensatz 20 mal ausgeführt und die Ergebnisse gemittelt, um den Einfluss der zufälligen Auswahl der Trainingsdaten bei der überwachten Klassifikation und den Einfluss der zufälligen Initialisierung bei der unüberwachten Klassifikation zu minimieren.

6.3.1 Klassifikation von Laub- und Nadelbäumen

Im ersten Schritt wird zwischen den beiden Hauptbaumarten Laubbaum und Nadelbaum unterschieden, die in den Referenzflächen etwa gleiche Anteile haben. Die Tabellen 6.13 und 6.14 enthalten die Ergebnisse für die Watershed Segmente und die Normalized Cut Segmente der verschiedenen Datensätze.

| Merkmale | Gesamtgenauigkeit [%] (Watershed Segmente, Datensätze II - VI) | | | | | | | | | | | |
|--------------------------------|--|----|-------------|----|----|----|----|----|-------|----|--------|----|
| | II (E) | | III (74,81) | | IV | | V | | V (E) | | VI (E) | |
| | EM | ML | EM | ML | EM | ML | EM | ML | EM | ML | EM | ML |
| S_{g}^1 | 83 | 84 | 73 | 72 | 72 | 72 | 78 | 77 | 80 | 79 | 83 | 83 |
| S_{g}^2 | 84 | 85 | 83 | 83 | 79 | 83 | 85 | 85 | 82 | 85 | 82 | 83 |
| S_{i}^h | 65 | 70 | 59 | 76 | 61 | 72 | 68 | 67 | 69 | 66 | 64 | 71 |
| S_{i}^d | 69 | 67 | 72 | 75 | 54 | 71 | 67 | 75 | 71 | 72 | 68 | 71 |
| S_{I}^1 | | | 70 | 69 | 77 | 77 | 91 | 93 | 95 | 95 | 93 | 93 |
| S_{I}^2 | | | 77 | 75 | 82 | 81 | 92 | 93 | 96 | 95 | 95 | 96 |
| S_W | | | 83 | 85 | 81 | 82 | 52 | 53 | 54 | 55 | 56 | 61 |
| S_n^1 | | | 75 | 76 | 80 | 84 | 58 | 66 | 57 | 66 | 59 | 57 |
| S_n^2 | | | 68 | 65 | 86 | 94 | 65 | 65 | 64 | 65 | 54 | 64 |
| S_{g}^2, S_{I}^2 | | | 84 | 86 | 89 | 90 | 92 | 94 | 94 | 97 | 93 | 97 |
| $S_{g}^2, S_{I}^2, S_W, S_n^2$ | | | 85 | 88 | 92 | 96 | 83 | 95 | 82 | 97 | 83 | 97 |

Tabelle 6.13: Ergebnisse der unüberwachten EM Klassifikation und überwachten ML Klassifikation zwischen Laub- und Nadelbäumen für die **Watershed Segmente** der verschiedenen Datensätze. Die jeweils besten Ergebnisse sind gelb markiert.

| Merkmale | Gesamtgenauigkeit [%] (3D Segmente, Datensätze II - VI) | | | | | | | | | | | |
|--------------------------------|---|----|-------------|----|----|----|----|----|-------|----|--------|----|
| | II (E) | | III (74,81) | | IV | | V | | V (E) | | VI (E) | |
| | EM | ML | EM | ML | EM | ML | EM | ML | EM | ML | EM | ML |
| S_{g}^1 | 80 | 80 | 76 | 81 | 74 | 75 | 81 | 82 | 83 | 84 | 83 | 83 |
| S_{g}^2 | 80 | 78 | 78 | 84 | 75 | 78 | 80 | 82 | 83 | 82 | 81 | 81 |
| S_{i}^h | 62 | 66 | 57 | 73 | 73 | 72 | 64 | 67 | 66 | 66 | 65 | 70 |
| S_{i}^d | 66 | 67 | 63 | 77 | 68 | 76 | 68 | 74 | 69 | 73 | 65 | 70 |
| S_{I}^1 | | | 67 | 66 | 74 | 74 | 90 | 91 | 93 | 93 | 91 | 91 |
| S_{I}^2 | | | 74 | 73 | 81 | 81 | 93 | 94 | 97 | 96 | 95 | 97 |
| S_W | | | 81 | 85 | 75 | 79 | 52 | 51 | 54 | 56 | 60 | 64 |
| S_n^1 | | | 77 | 76 | 80 | 84 | 56 | 54 | 57 | 65 | 66 | 64 |
| S_n^2 | | | 75 | 65 | 89 | 93 | 62 | 63 | 61 | 65 | 57 | 57 |
| S_{g}^2, S_{I}^2 | | | 80 | 86 | 81 | 86 | 90 | 94 | 93 | 97 | 91 | 97 |
| $S_{g}^2, S_{I}^2, S_W, S_n^2$ | | | 85 | 89 | 91 | 94 | 81 | 95 | 84 | 97 | 82 | 97 |

Tabelle 6.14: Ergebnisse der unüberwachten EM Klassifikation und überwachten ML Klassifikation zwischen Laub- und Nadelbäumen für die **Normalized Cut Segmente** der verschiedenen Datensätze. Die jeweils besten Ergebnisse sind gelb markiert.

Als erstes stellt sich die Frage, wie sich die verschiedenen Klassifikationsmethoden auf die Ergebnisse auswirken. Bei den unüberwachten Methoden gibt es kaum Unterschiede zwischen der K-Means Klassifikation und der EM Klassifikation. In den Tabellen 6.13 und 6.14 sind deshalb nur die Werte für das EM Verfahren angegeben. Vergleicht man die jeweils besten Ergebnisse der unüberwachten EM Klassifikation und der überwachten ML Klassifikation, so ist die überwachte Klassifikation mit bis zu 4 % immer leicht im Vorteil.

Interessant ist außerdem, ob sich die Art der Segmentierung in den Ergebnissen der Klassifikation widerspiegelt. Betrachtet man die besten Ergebnisse pro Datensatz für die Watershed Segmente (Tabelle 6.13) und die Normalized Cut Segmente (Tabelle 6.14), so sind keine signifikanten Unterschiede erkennbar. Lediglich beim First/Last-Pulse Datensatz II ist die Klassifikationsrate für die Watershed Segmente um 5 % höher.

Wirksamkeit der verschiedenen Merkmale

Konzentriert man sich auf die Wirksamkeit der einzelnen Merkmale (Tabellen 6.13 und 6.14), so stellen sich die Intensitätsmerkmale S_I^1 und S_I^2 bei den Datensätzen V und VI, die im belaubten Zustand erfasst wurden, als die mit Abstand besten Einzelmerkmale heraus. Bei diesen Datensätzen sind die mittleren Intensitätswerte der Laubbäume höher als die der Nadelbäume. Im Gegensatz dazu sind diese beiden Merkmale beim Datensatz III, der zwar auch noch im belaubten Zustand, aber erst im September erfasst wurde, nicht sehr signifikant. Hier sind die mittleren Intensitätswerte der Laubbäume eher niedriger als die der Nadelbäume. Beim Datensatz IV, der Anfang Mai noch im unbelaubten Zustand erfasst wurde, wirken diese Merkmale besser als beim Datensatz III, jedoch nicht so gut wie bei den Datensätzen V und VI.

Das Merkmal S_W , das die mittlere Pulsbreite der Reflexionen repräsentiert, zeigt bei den Datensätzen III und IV wesentlich höhere Klassifikationsraten als bei den Datensätzen V und VI. Beim Datensatz III ist S_W zusammen mit S_g^2 dafür verantwortlich, dass trotz der schlechten Wirksamkeit der Intensitätsmerkmale eine Klassifikationsgenauigkeit von 89 % erreicht werden kann. Beim Datensatz IV liefert das Merkmal S_n^2 die besten Ergebnisse, so dass bei der überwachten ML Klassifikation eine Genauigkeit von ca. 95 % erzielt wird. Die Merkmale S_i^h und S_i^d zur Beschreibung der internen Baumstruktur sind bei allen Datensätzen nicht sehr signifikant. Die geometrischen Merkmale S_g führen bei allen Datensätzen zu einer Klassifikationsgenauigkeit von ca. 80 % und stellen beim Datensatz II die besten Merkmale dar.

Vergleich der verschiedenen Datensätze

Ein Vergleich der verschiedenen Daten zeigt, dass bei den Datensätzen IV, V und VI sehr hohe Klassifikationsgenauigkeiten erzielt werden können, wobei je nach Belaubungszustand unterschiedliche Merkmale wirken. Betrachtet man die Datensätze V und VI nur für das Gebiet E, so gibt es kaum Unterschiede zwischen den Ergebnissen. Die niedrigere Punktdichte beim Datensatz VI hat also keinen negativen Einfluss auf die Klassifikation zwischen Laub- und Nadelbäumen. Beim Datensatz III sind die Klassifikationsraten nicht ganz so hoch wie bei den übrigen Full Waveform Datensätzen. Vergleicht man die Datensätze II und VI, die beide im belaubten Zustand und mit derselben nominalen Punktdichte von 10 Punkten/m² erfasst wurden, so ist die Klassifikationsgenauigkeit beim First/Last-Pulse Datensatz II deutlich niedriger. Weil hier nur die Koordinaten der Reflexionen vorliegen, können weitaus weniger Merkmale berechnet werden.

Konfusionsmatrizen der besten Ergebnisse

Zur genaueren Analyse sind in der Tabelle 6.15 die Konfusionsmatrizen für die besten Ergebnisse der Datensätzen IV und V dargestellt. Man sieht, dass die Klassifikationsgenauigkeiten für Laub- und

| Datensatz IV (unbelaubt, 3D Segmente) | | | | |
|--|-----------|----------|----------------------|-------------------|
| Baumart | Nadelbaum | Laubbaum | Klassifizierte Bäume | Nutzergenauigkeit |
| Nadelbaum | 332 | 13 | 345 | 96 % |
| Laubbaum | 37 | 424 | 461 | 92 % |
| Referenzbäume | 369 | 437 | 806 | |
| Herstellergenauigkeit | 90 % | 97 % | | |
| Gesamtgenauigkeit: 94 % Kappa: 0.87 | | | | |
| Datensatz V (belaubt, 3D Segmente) | | | | |
| Baumart | Nadelbaum | Laubbaum | Klassifizierte Bäume | Nutzergenauigkeit |
| Nadelbaum | 322 | 16 | 338 | 95 % |
| Laubbaum | 21 | 374 | 395 | 95 % |
| Referenzbäume | 343 | 390 | 733 | |
| Herstellergenauigkeit | 94 % | 96 % | | |
| Gesamtgenauigkeit: 95 % Kappa: 0.90 | | | | |

Tabelle 6.15: Konfusionsmatrizen der überwachten Klassifikation von Laub- und Nadelbäumen

Nadelbäume im laublosen Zustand etwas ungleich verteilt sind. Es liegen zwar 97 % der Laubbäume in der einen Klasse, aber nur 90 % der Nadelbäume in der anderen Klasse. Das deutet auf eine etwas größere Streuung der Merkmale bei den Nadelbäumen hin. Im belaubten Zustand liegt fast eine Gleichverteilung vor. Aus diesem Grund ist hier der Wert für Kappa mit 0.90 etwas höher als im laublosen Zustand mit 0.87.

Abhängigkeit von der Höhengschicht

Da insbesondere bei der Normalized Cut Segmentierung auch Bäume in den unteren Höhengschichten des Waldes gefunden werden, stellt sich die Frage, wie sich die Klassifikationsgenauigkeit in Abhängigkeit von der Höhengschicht der Bäume verhält. Aus diesem Grund werden die Genauigkeiten für die Datensätze IV und V separat für jede Höhengschicht berechnet (Tabelle 6.16). Man sieht, dass die Er-

| Datensatz | Klassifikationsgenauigkeit pro Höhengschicht [%] | | | |
|-----------|--|-----------------|-------------|--------|
| | Unterschicht | Zwischenschicht | Oberschicht | Gesamt |
| IV | 95 | 93 | 94 | 94 |
| V | 86 | 90 | 97 | 95 |

Tabelle 6.16: Klassifikationsgenauigkeit für die überwachte Klassifikation der 3D Segmente in Abhängigkeit von der Höhengschicht

gebnisse beim Datensatz IV im unbelaubten Zustand für alle drei Höhengschichten fast gleich sind. Im Vergleich dazu nimmt die Klassifikationsgenauigkeit im belaubten Zustand des Datensatz V in den unteren Schichten leicht ab. Der Grund dafür ist offenbar die schlechtere Durchdringung der Waldstruktur im belaubten Zustand, so dass weniger Reflexionen an den kleineren Bäumen stattfinden.

6.3.2 Klassifikation einzelner Laub- und Nadelbaumarten

Wie die obigen Ergebnisse zeigen, können Laub- und Nadelbäume in beiden Vegetationszuständen mit hoher Genauigkeit voneinander unterschieden werden. Es stellt sich die Frage, ob noch eine weitere Auftrennung in einzelne Laub- und Nadelbaumarten möglich ist. Um dies zu testen, wird mit den 3D Segmenten des Datensatz V eine überwachte Klassifikation zwischen Fichte und Tanne durchgeführt. Weil lediglich in den Referenzflächen des Teilgebiets E einige Tannen vorhanden sind, beschränkt sich die Auswertung auf dieses Gebiet. Insgesamt gehen in die Klassifikation 52 Segmente mit Tannen und 302 Segmente mit Fichten ein, wovon jeweils ein Fünftel als Trainingsdaten verwendet wird. Wegen der ungleichen Verteilung der Baumarten ist das Ergebnis der Klassifikation in einer Konfusionsmatrix dargestellt (Tabelle 6.17). Dieses Resultat wird mit einer Kombination der Merkmale S_g^2 , S_I^2 , S_W und

| Baumart | Fichte | Tanne | Klassifizierte Bäume | Nutzergenauigkeit |
|--|--------|-------|----------------------|-------------------|
| Fichte | 230 | 8 | 238 | 97 % |
| Tanne | 12 | 34 | 46 | 74 % |
| Referenzbäume | 242 | 42 | 284 | |
| Herstellergenauigkeit | 95 % | 81 % | | |
| Gesamtgenauigkeit: 93 % Kappa: 0.72 | | | | |

Tabelle 6.17: Konfusionsmatrix der überwachten Klassifikation von Fichte und Tanne

S_n^2 erreicht und stellt das beste Ergebnis dar. Die hohe Gesamtgenauigkeit von 93 % ist hauptsächlich durch die Herstellergenauigkeit von 95 % bei den Fichten beeinflusst. Die proportional unterrepräsentierten Tannen können mit einer Herstellergenauigkeit von 81 % klassifiziert werden, wobei jedoch die Standardabweichung bei der 20-maligen Durchführung mit zufälliger Auswahl der Trainingsdaten 7.7 % beträgt.

Analog zu den beiden Nadelbaumarten wird auch eine Klassifikation der Laubbaumarten Buche und Ahorn durchgeführt. Jedoch gelingt es hier sowohl im belaubten als auch im unbelaubten Zustand nicht, diese Baumarten mehrheitlich in unterschiedliche Klassen aufzuteilen.

Kapitel 7

Diskussion

Im Folgenden werden die Ergebnisse der im Kapitel 6 durchgeführten Experimente diskutiert und bewertet. Insgesamt gliedert sich dieses Kapitel in fünf Abschnitte:

- Der Abschnitt 7.1 umfasst die Zerlegung der Waveforms durch eine Anpassung von Gauß-Funktionen. Dabei wird die Eignung dieses Modells und die Anwendung des Schätzverfahrens für die beiden eingesetzten Scanner diskutiert. Außerdem werden die Vorteile dieser Vorgehensweise gegenüber der Erfassung von Reflexionen bei diskret arbeitenden Systemen herausgearbeitet.
- Im Abschnitt 7.2 wird die Kalibrierung der Intensität bezüglich der unterschiedlichen Laufzeiten der einzelnen Lasermessungen behandelt. Insbesondere wird die Überprüfung und Anpassung der modellbasierten Korrektur aus der Radargleichung mit Hilfe von Daten aus unterschiedlicher Flughöhe erörtert.
- Im Abschnitt 7.3 werden die Werte der Intensität und Pulsbreite für Reflexionen an verschiedenen Objekten im Wald analysiert. Hierbei wird sowohl zwischen Boden-, Stamm- und Kronenpunkten als auch zwischen Laub- und Nadelbäumen unterschieden.
- Der Abschnitt 7.4 setzt sich mit den in der Arbeit vorgestellten Methoden zur Erkennung von Einzelbäumen und deren Anwendung auf die verschiedenen Datensätze auseinander. Dabei werden die Vorzüge und Schwachstellen der jeweiligen Methode herausgearbeitet. Die unterschiedlichen Eigenschaften der verwendeten Datensätze erlauben außerdem eine Analyse der Methoden bezüglich ihrer Anforderungen an die Daten.
- Der Abschnitt 7.5 beschäftigt sich mit den Ergebnissen der durchgeführten Baumartenklassifikationen. Insbesondere wird die Wirksamkeit der verschiedenen Merkmale für die überwachte und unüberwachte Klassifikation von Laub- und Nadelbäumen, bzw. einzelner Laub- und Nadelbaumarten diskutiert.

7.1 Zerlegung der Waveforms

7.1.1 Eignung des Gauß-Modells

Das im Abschnitt 2.2 beschriebene mathematische Modell zur Zerlegung der Waveforms darf nur bei Lasersystemen angewendet werden, deren ausgesendetes Signal gaußförmig ist. Eine Analyse der Sendesignale zeigt, dass diese Annahme bei den beiden eingesetzten Scannern für den größten Teil

des Signalverlaufs sehr gut zutrifft (Abschnitt 6.1). Lediglich in einem kleinen Bereich am Ende des Impulses treten Abweichungen auf, die über dem Rauschen liegen. Da diese Abweichungen im Vergleich zur Amplitude des Nutzsignals gering sind, können sie vernachlässigt werden. Auch Wagner et al. [2006] untersucht die Sendesignale des Riegl LMS-Q560 Scanner und kommt zu demselben Ergebnis.

7.1.2 Schätzung der unbekannt Parameter und deren Genauigkeiten

Das vorgestellte Verfahren zur Schätzung der unbekannt Parameter des Gauß-Modells ist dank des integrierten LM Algorithmus sehr robust. Die erfolgreiche Anwendung auf die Daten der beiden Scanner wurde nachgewiesen. Es ist zu erwarten, dass auch die Waveforms anderer Systeme damit verarbeitet werden können, sofern sie das Gauß-Kriterium erfüllen.

Die Schätzung der Genauigkeiten im Zuge der Ausgleichung ermöglicht eine interne Qualitätskontrolle der Ergebnisse. Dabei zeigen insbesondere die kleinen Standardabweichungen für die Positionen der Gauß-Funktionen von durchschnittlich 2 cm, dass die Approximation der Waveforms sehr präzise erfolgt. Im Vergleich zum Abstand der einzelnen Abtastwerte von ca. 15 cm ist das eine erhebliche Verbesserung. Indirekt bestätigt sich damit nochmals die Eignung des Modells. Wegen der eher kleinen Scanwinkel ist σ_{t_m} ein guter Schätzwert für die interne Höhengenaugigkeit σ_{z_m} der abgeleiteten Punkte.

7.1.3 Ringing Effekt

Die Auswirkungen des Ringing Effekts fallen bei Objekten, deren Geometrie bekannt ist, wie Häusern oder Straßen, sofort auf (Abbildung 6.3). Bei unregelmäßigen und durchdringbaren Objekten, wie Bäumen, ist dies nicht so offensichtlich. Doch wie die Waveform in der Abbildung 6.6a zeigt, treten diese Nachschwinger auch dort auf. Die entstehenden Pseudo-Punkte können sich negativ auf die Segmentierungs- und Klassifikationsgenauigkeit von Einzelbäumen auswirken, so dass die im Abschnitt 2.2.3 beschriebene Vorgehensweise auch hier erforderlich ist.

7.1.4 Vergleich der beiden Scanner

Bei der Zerlegung der Waveforms zeigen sich im Wesentlichen zwei Unterschiede zwischen den beiden Scannern. Zum einen variiert der Rauschpegel beim TopEye Scanner von Waveform zu Waveform, so dass der Schwellwert $S_{\hat{A}_m}$ individuell für jede Waveform ermittelt werden muss. Da dieser Wert so hoch anzusetzen ist, dass auf keinen Fall das Rauschen fehlerhaft als Reflexion interpretiert wird, kann es vorkommen, dass sehr schwache Reflexionen übergangen werden (Abbildung 6.9). Als Grund für das unterschiedliche Rauschen ist eine Sensitivität bezüglich der Hintergrundstrahlung denkbar, d.h. der Filter des Empfängers ist auch für Licht außerhalb der Wellenlänge des Lasers durchlässig. Beim Riegl Scanner scheint dieses Problem besser gelöst zu sein, weil der Rauschpegel für alle Waveforms konstant ist. Somit kann $S_{\hat{A}_m}$ auf einen festen, einmal ermittelten Wert gesetzt werden. Die Unterscheidung zwischen Reflexionen und Rauschen ist somit einfacher.

Zum zweiten tritt der Ringing Effekt beim Riegl Scanner nicht so stark auf wie beim TopEye Scanner. Das deutet darauf hin, dass Riegl auch dieses Problem besser im Griff hat.

Insgesamt weisen also die Riegl Waveforms weniger potentielle Fehlerquellen auf. Möglicherweise treten diese nachteiligen Effekte aber nur bei dieser ersten Version des TopEye MK II Scanners auf und sind bei der überarbeiteten Version, die 2006 auf den Markt kam, schon behoben. Die Tatsache, dass die Länge der Waveforms bei diesem überarbeiteten Scanner nicht mehr auf 19 m begrenzt ist, lässt grundlegende Verbesserungen vermuten.

7.1.5 Vorteile gegenüber der Erfassung bei diskret arbeitenden Systemen

Ein wesentlicher Nachteil von diskret arbeitenden Systemen besteht darin, dass diese Systeme nach dem Registrieren einer Reflexion wegen hardwaretechnischer Begrenzungen für eine gewisse Zeit blind sind. Diese sog. Totzeit liegt bei mindestens einer vollständigen Pulsdauer. Das vorherige Echo muss also vollständig abgeklungen sein, bevor ein neues detektiert werden kann. Insbesondere bei älteren Systemen kann die Totzeit sogar Werte bis zur dreifachen Pulsdauer annehmen. Das wirkt sich z.B. nachteilig auf die Qualität abgeleiteter Geländemodelle aus, weil eine Unterscheidung zwischen Boden und bodennaher Vegetation nicht möglich ist.

Im Gegensatz dazu können bei der Zerlegung der Waveforms sogar überlagerte Reflexionen noch getrennt werden. Die Abbildung 6.8 zeigt, dass Objekte mit einem Abstand von nur 0.4 m in der Ausbreitungsrichtung des Laserstrahls noch aufgelöst werden können. Das nach Wagner et al. [2006] definierte räumliche Trennungsvermögen Δr eines Laserscanners als die kleinste Entfernung zweier Objekte, bei der noch keine Überlappung der Echos auftritt, beträgt beim TopEye Scanner ca. 1.5 m und beim Riegl Scanner ca. 1.2 m. Mit dem hier verwendeten Verfahren kann dieser Wert wesentlich unterschritten werden. Das führt zu einer genaueren Abbildung der internen Baumstruktur und der nachwachsenden Verjüngung im Unterstand.

Weiterhin werden bei diskreten Systemen die schwachen Reflexionen häufig nicht berücksichtigt, wofür vermutlich ein zu hoch angesetzter interner Schwellwert verantwortlich ist. Ein anschauliches Beispiel dafür ist in der Abbildung 6.6a zu sehen. Hier wurde bei der diskreten Erfassung durch das TopEye System nur eine dominante Reflexion erfasst, wohingegen die Zerlegung der entsprechenden Waveform zu vier zusätzlichen Punkten führt.

Bei den First/Last-Pulse Systemen kommt noch hinzu, dass alle Reflexionen zwischen dem ersten und letzten Puls vernachlässigt werden. Im Vegetationsbereich sind deshalb kaum Aussagen über die Strukturen zwischen Boden und Oberfläche möglich. Heurich [2006], der die First/Last-Pulse Datensätze I und II (Tabellen 5.2 und 5.3) im Nationalpark Bayerischer Wald auswertete, stellte fest, dass nachwachsende Verjüngung in diesen Daten kaum zu identifizieren ist.

Aus obigen Gründen erhält man durch die Auswertung der Waveforms eine viel höhere räumliche Punktdichte als bei First/Last-Pulse Daten. Somit können die charakteristischen Eigenschaften der Bäume detaillierter aufgelöst und im 3D Raum abgebildet werden. Besonders gut sieht man das in den Bereichen a) und d) der Abbildung 6.4. Forstlich relevante Merkmale wie das Kronenvolumen und das davon abhängige Stammvolumen sollten sich somit genauer bestimmen lassen. In den Bereichen b) und c) sieht man den Unterschied nicht so deutlich, weil diese Bäume freistehend sind und somit auch seitliche Laserstrahlen zu Reflexionen führen.

7.2 Kalibrierung der Intensität

Eine Kalibrierung der Intensität ist insbesondere erforderlich, wenn sich die Laufzeiten der einzelnen Lasermessungen stark voneinander unterscheiden. Gerade im bewegten Gelände und bei unterschiedlichen Scanwinkeln sind Entfernungsvariationen nicht zu vermeiden. Im Waldbereich trägt auch die Höhe der Bäume dazu bei. Betrachtet man zur Verdeutlichung die Entfernungen aller Reflexionen des Datensatz V in den Referenzflächen, so liegen diese im Bereich von 250 m bis 542 m und weichen zum Teil erheblich von der mittleren Flughöhe von 400 m ab. Obwohl vielen Anwendern die Notwendigkeit einer Kalibrierung bekannt ist, fehlt ihnen häufig die dafür erforderliche Datengrundlage. So konnten z.B. Ørka et al. [2009] mangels Information keine Kalibrierung durchführen. Die Aufzeichnung

der Echoprofile und deren Auswertung bieten den Vorteil, dass dem Nutzer jetzt die zur Kalibrierung notwendigen Daten zur Verfügung stehen.

Bei der Kalibrierung der Datensätze IV bis VI (Abschnitt 6.1.2) zeigt sich, dass der Exponent n in der Gleichung 2.23 etwas kleiner ist als der Wert von 2, der für das Modell der Radargleichung gilt. Es müssen also Effekte auftreten, die im theoretischen Modell nicht berücksichtigt werden. Möglich wäre z.B. eine Nichtlinearität bei der Signalverarbeitung im Empfänger, so dass schwache Signale besser verstärkt werden als starke Signale. Vom Hersteller des Systems gibt es darüber aber keine Informationen.

Eine solche Überprüfung der modellbasierten Korrektur ist jedoch nur möglich, wenn Daten aus signifikant unterschiedlichen Flughöhen vorliegen. In diesem Fall sollten die Daten zur Anpassung des Exponenten n genutzt werden, weil dieser Wert einen erheblichen Einfluss auf die resultierenden Intensitäten hat. Folgendes Beispiel verdeutlicht dies: Hat man bei einer Entfernung $R = 400$ m eine Intensität $I^c = 100$, so reduziert sich diese bei $R_{\text{ref}} = 450$ m und $n = 2$ auf 79.01. Bei dem für die Datensätze V und VI ermittelten Wert von $n = 1.736$ findet lediglich eine Reduktion auf 81.51 statt. Ein Δn von 0.1 bewirkt also bei diesen Entfernungen einen Intensitätsunterschied von ca. 1 %.

Entscheidend ist die Frage, ob im Waldbereich dieselben Kalibrierparameter angewendet werden dürfen wie bei Einzelreflexionen im freien Gelände. Wie im Abschnitt 2.3.2 erläutert, müsste man zur genauen Kalibrierung von Mehrfachreflexionen die jeweilige Größe der beleuchteten Fläche am Zielobjekt kennen. Zwei Ergebnisse dieser Arbeit weisen darauf hin, dass die Anwendung derselben Kalibrierparameter auch im Waldbereich sinnvoll ist. Erstens haben die Experimente auf dem Flugplatz (Abschnitt 6.1.2) gezeigt, dass sich der Faktor n im Vegetationsbereich kaum von dem Wert unterscheidet, der mit Hilfe ebener Flächen ermittelt wurde. Zweitens eignet sich die so kalibrierte Intensität sehr gut als Merkmal in der Baumartenklassifikation.

Im Gegensatz zur hier durchgeführten Kalibrierung nutzen Höfle et al. [2008] für die Klassifikation von 11 Buchen, 10 Eichen und 4 Lärchen den Streuquerschnitt Γ , der nach der Gleichung 2.20 eine Multiplikation von I^c mit R^4 verlangt. Die Lärchen lassen sich damit eindeutig von den Buchen und Eichen unterscheiden. Eine Trennung der Laubbaumarten Buche und Eiche ist jedoch nicht möglich. Interessant wäre bei dieser Studie die Angabe der Entfernungen R für die einzelnen Bäume. Denn nur bei einem signifikant unterschiedlichen R wirkt sich die Art der Kalibrierung auf das Ergebnis aus und lässt Rückschlüsse auf die Güte des Verfahrens zu.

7.3 Analyse von Intensität und Pulsbreite

7.3.1 Vergleich von Boden-, Stamm- und Kronenpunkten

Wie man in den Abbildungen 6.12a und 6.12b sieht, besitzen die Bodenpunkte im Vergleich zu den Stamm- und Kronenpunkten im Mittel eine niedrigere Pulsbreite und eine höhere Intensität. Das deckt sich mit den Ergebnissen von Doneus & Briese [2006], die bei der Filterung von Bodenpunkten zur DGM-Erzeugung die Punkte mit großer Pulsbreite ausschließen.

Bei den Stammpunkten nimmt die Pulsbreite bei steigendem Scanwinkel ab, weil dann der Winkel zwischen dem Laserstrahl und der Normalen zur Stammoberfläche kleiner wird. Somit verringert sich das Entfernungsintervall innerhalb des beleuchteten Stammbereichs, was zu einer geringeren Pulsaufweitung führt. Zum Vergleich konnte diese Abhängigkeit der Pulsbreite für urbane Objekte bereits von Jutzi & Stilla [2003] nachgewiesen werden. Bei den Stämmen ist dieser Effekt für die Einzelpunkte und die letzten Punkte deutlicher als für die ersten Punkte und die Zwischenpunkte, weil hier der

Stamm nur mit einer Teilfläche des Footprints am Rand getroffen wird, was große Schwankungen der Pulsbreite bewirkt.

Die Intensität der Stammpunkte steigt bei größer werdendem Scanwinkel wiederum wegen der Abnahme des Einfallswinkels. Wie man in der Abbildung 6.12b sieht, können Stammpunkte und Kronenpunkte dadurch ab einem Scanwinkel von 10° gut unterschieden werden. Der Nachteil hierbei ist aber, dass dieser Unterschied in der Intensität nur bei Einzelpunkten so deutlich ist, die beim Datensatz IV nur ca. 20 % der Stammtreffer ausmachen.

Bei den Boden- und Kronenpunkten zeigt der Scanwinkel keinen Einfluss auf die mittlere Pulsbreite und die mittlere Intensität, weil hier die Zielobjekte geometrisch nicht so einheitlich sind wie die Baumstämme. Das bewegte Gelände im Wald und die unterschiedliche Ausrichtung der Baumkronen überschatten den Effekt des Scanwinkels.

7.3.2 Vergleich von Laub- und Nadelbäumen

Beim Vergleich der Punktattribute für Laub- und Nadelbäume zeigt sich überraschenderweise, dass die Intensität von Einzelpunkten an Stämmen gut für eine Unterscheidung dieser Baumarten geeignet ist (Abbildung 6.14b). Offensichtlich liegt das an dem unterschiedlichen Reflexionsverhalten der Rinde. Die Buchen besitzen eine glatte Rinde, so dass eine teilweise spiegelnde Oberfläche vorherrscht und deshalb weniger Energie in die Einfallrichtung des Laserstrahls zurückgeworfen wird. Die Rinde der Fichten hingegen ist erheblich rauer und verursacht deshalb höhere Intensitätswerte. Leider ist eine flächenhafte Baumartenklassifikation mit Hilfe dieses Merkmals nicht möglich, weil solche Einzelpunkte an Stämmen nicht bei allen Bäumen identifiziert werden können. Erwartungsgemäß zeigen sich bei der mittleren Pulsbreite der Stammpunkte (Abbildung 6.14a) kaum Unterschiede, weil hier nur die Form der Stämme maßgebend ist, die sich für Laub- und Nadelbäume im unteren Stammbereich kaum unterscheidet.

Für die Kronenpunkte zeigen sich sowohl bei der Pulsbreite als auch bei der Intensität unterschiedliche mittlere Werte (Abbildungen 6.13a und 6.13b). Der erfolgreiche Einsatz dieser Attribute in der Baumartenklassifikation bestätigt diese Beobachtung. Wegen der großen Standardabweichungen der Einzelwerte erweisen sich jedoch nur Mittelwerte über einen bestimmten Bereich, wie z.B. ein gesamtes Baumsegment, als aussagekräftig, was sich auch in der Berechnung der Merkmale S_I und S_W widerspiegelt.

7.4 Erkennung von Einzelbäumen

7.4.1 Watershed Segmentierung

Als erstes Verfahren zur Erkennung von Einzelbäumen wird die im Abschnitt 3.1 dargestellte Watershed Segmentierung getestet. Hierbei sind die Ergebnisse für den First/Last-Pulse Datensatz II ähnlich wie die Resultate von Heurich [2006]. Dieser hat ebenfalls eine CHM basierte Methode, die von Persson et al. [2002] beschrieben wird, unter Verwendung des Datensatz II auf nahezu denselben Referenzflächen eingesetzt. Der Vergleich zeigt, dass die beiden Segmentierungsansätze äquivalent wirken. Dies bekräftigt, dass die hier verwendete Watershed Segmentierung als repräsentatives Verfahren für die Segmentierung im CHM betrachtet werden darf und als Basis für einen Vergleich mit den Methoden der Stammerkennung und der 3D Segmentierung geeignet ist.

Erwartungsgemäß zeigt sich bei allen Datensätzen, dass mit dieser Art der Segmentierung nur wenige Bäume in der Unter- und Zwischenschicht gefunden werden können. Meistens werden diese kleineren Bäume von größeren verdeckt und sind somit im CHM gar nicht enthalten oder besitzen kein eigenes lokales Maximum. Zusätzlich führt die in einem gewissen Umfang notwendige Glättung des CHM zu einer Verschmelzung von Maxima.

7.4.2 Erkennung von Baumstämmen

Die vorgestellte Methode zur Erkennung von Baumstämmen geht einen Schritt weiter und nutzt Informationen unterhalb des CHM. Dadurch kann die Erkennungsrate in der Zwischen- und Oberschicht im Vergleich zur Watershed Segmentierung gesteigert werden. In der Unterschicht hingegen ist die Verbesserung gering, weil Stammreflexionen bei kleinen Bäumen selten auftreten und wegen der meist bis zum Boden gehenden Äste dieser Bäume schwer isolierbar sind. Mindestens genauso wichtig wie die gesteigerte Erkennungsrate ist die höhere Genauigkeit der Baumpositionen durch die Stammdetektion. Vor allem bei Laubbäumen werden die Positionen erheblich genauer, weil deren lokale Maxima im CHM oft stark von den wirklichen Stammpositionen abweichen. Weiterhin wirkt sich die Integration der Ergebnisse dieser Methode in das Normalized Cut Verfahren positiv auf die Genauigkeit der 3D Segmentierung aus.

Ein Nachteil der Stammerkennungsmethode ist, dass die Baumhöhe vom höchsten Punkt in der Umgebung der gefundenen Stammgeraden abhängt. Bei Bäumen im Unterstand kann es daher leicht zu Verfälschungen kommen, wenn keine ausreichend große vertikale Lücke zum dominanten Baum hin besteht. Zusätzlich besitzt diese Methode die Einschränkung, dass den jeweiligen Stämmen keine Kronenpunkte zugeordnet werden. Es handelt es sich also bei der Stammerkennung um keine echte Methode zur Segmentierung.

7.4.3 Normalized Cut Segmentierung

Die Normalized Cut Segmentierung repräsentiert einen substantiellen Fortschritt beim Einzelbauman-satz. Es handelt sich dabei um eine hierarchische Segmentierung, welche auf der Minimierung einer Energiefunktion basiert. Das globale Minimum wird hierbei approximiert. Die resultierenden 3D Seg-mente erlauben eine direkte Berechnung des Kronenvolumens, weshalb eine Verbesserung bei der Bestimmung des Holzvolumens erwartet wird.

Gegenüber anderen Ansätzen zur 3D Segmentierung von Bäumen hat das hier beschriebene Ver-fahren zwei entscheidende Vorteile:

- Zum einen benötigt das Normalized Cut Verfahren keine Saatpunkte zur Initialisierung. Im Ver-gleich dazu verwenden [Morsdorf et al. \[2003\]](#) die lokalen Maxima im CHM als Anfangswerte für ein 3D K-Means Clustering der Laserpunkte. Dabei erhalten sie zwar auch 3D Segmente, können aber deren Anzahl gegenüber der Anzahl der lokalen Maxima nicht steigern.
- Zum anderen arbeitet das Verfahren echt in 3D. Im Gegensatz dazu unterteilen [Wang et al. \[2008\]](#) den Waldbereich in horizontale Schichten, führen in jeder Schicht eine 2D Segmentierung mit Methoden der Morphologie durch und kombinieren die Ergebnisse der einzelnen Schichten zu einem 3D Modell. Dies hat den Nachteil, dass auch hier die Ergebnisse von einer korrekten Detektion der Baumspitzen in den jeweiligen Schichten abhängen.

Die mathematische Formulierung bei der Berechnung der Ähnlichkeiten zwischen den Voxeln macht die Normalized Cut Segmentierung sehr flexibel bezüglich der vorhandenen Informationen aus den Laserdaten. Die Eingangsinformationen werden in einen geometrischen Teil, einen merkmalsbasierten Teil und einen Teil zum Einbringen von Vorwissen untergliedert, wobei nur die geometrische Information zwingend notwendig ist. Aus diesem Grund ist das Verfahren nicht von Full Waveform Daten oder Baumpositionen aus anderen Verfahren abhängig und kann auch auf konventionelle First/Last-Pulse Daten angewendet werden. Auch die Liste der Merkmale ist beliebig erweiterbar.

Die Experimente mit den verschiedenen Datensätzen zeigen jedoch, dass erst eine Kombination von Watershed Segmentierung, Stammdetektion und Normalized Cut Segmentierung insgesamt zu einer deutlichen Verbesserung führt. Das Normalized Cut Verfahren alleine findet zwar in den unteren Schichten mehr Bäume, weist aber in der Oberschicht eine geringere Detektionsrate auf als die Watershed Segmentierung und die Stammerkennung.

Trotz der Verbesserungen bleiben immer noch viele kleine Bäume unerkannt (Abbildung 6.18). Bei engem Bestand werden diese häufig zusammengefasst werden (Abbildung 6.22). Ein großer Fortschritt im Vergleich zur Watershed Segmentierung ist jedoch, dass die dominanten Bäume meist von den kleineren Bäumen getrennt werden, so dass die Segmente der großen Bäume nicht durch Reflexionen vom Unterstand verfälscht werden. Auf die Ableitung von forstlich relevanten Größen aus den 3D Segmenten sollte sich das positiv auswirken, was jedoch näher untersucht werden muss. Es stellt sich außerdem die Frage, ob es wirklich notwendig ist, jeden kleinen Baum einzeln zu erkennen und dessen Position zu bestimmen. Für die meisten Anwendungen ist es interessant zu wissen, ob überhaupt Verjüngung vorhanden ist, wie dicht die Verjüngung ist und welcher Baumart sie angehört. Die Auswertung der niedrigen Segmente sollte sich also auf diese Fragestellungen fokussieren.

7.4.4 Festlegung von Schwellwerten

Aus dem Abschnitt 6.2.2 geht hervor, dass für eine erfolgreiche Anwendung der hier beschriebenen Verfahren zur Einzelbaumerkennung eine Vielzahl von Parametern festgelegt werden müssen. Wie auch schon andere Arbeiten (z.B. [Persson et al., 2002; Koch et al., 2006]) zeigen, sind die Ergebnisse der Watershed Segmentierung stark von der Glättung des CHM abhängig. Bei den Experimenten mit den verschiedenen Datensätzen stellt sich heraus, dass beim First/Last-Pulse Datensatz II keine so starke Glättung vorgenommen werden darf wie bei den Full Waveform Datensätzen III - VI. Der Grund hierfür ist der größere Footprint von 85 cm beim Datensatz II, wodurch schon bei der Datenerfassung eine gewisse Glättung vorweggenommen wird.

Der wichtigste Parameter bei der Normalized Cut Segmentierung ist der Schwellwert $NCut_{max}$, weil dieser über die weitere Aufteilung eines Segments entscheidet. Auch hier zeigt sich ein Unterschied zwischen den First/Last-Pulse und den Full Waveform Daten. Der erforderliche niedrigere Wert bei den First/Last-Pulse Daten bedeutet, dass die rekursive Zweiteilung schon früher abgebrochen werden muss, um eine Übersegmentierung zu verhindern. Der Grund hierfür liegt in der eher flächenhaften Verteilung der Laserpunkte an der Kronenoberfläche im Vergleich zur gleichmäßigeren räumlichen Verteilung bei den Full Waveform Daten. Dadurch sind die Voxel in den 3D Segmenten der First/Last-Pulse Daten nicht so homogen verteilt, was ein Aufsplitten schon bei einem niedrigeren Schwellwert bewirkt.

7.4.5 Belaubter und unbelaubter Vegetationszustand

Die beiden Full Waveform Datensätze IV und V erlauben einen Vergleich der Segmentierungsergebnisse für den belaubten und unbelaubten Vegetationszustand (Abschnitt 6.2.5). Bei der Watershed Segmentierung ergeben sich hierbei nahezu identische Resultate. Offensichtlich weist das CHM keine signifikanten Unterschiede auf. Bei der hohen Punktdichte von 25 Punkten/m² wird also die Kronenform von Laubbäumen auch im unbelaubten Zustand gut repräsentiert.

Erwartungsgemäß zeigt die Normalized Cut Segmentierung im belaubten Zustand eine Verschlechterung in den unteren beiden Schichten. Das liegt an der geringeren Durchdringbarkeit der Laubbäume in diesem Zustand, wodurch die Bäume dieser Schichten weniger Reflexionen aufweisen. Im Mischwald ist also der unbelaubte Zustand besser für eine 3D Segmentierung geeignet als der belaubte. Darüber hinaus ist der unbelaubte Zustand vorteilhaft für die DGM-Ableitung. Möchte man jedoch mehrere Laubbaumarten anhand ihrer Blätter klassifizieren, so ist man auf den belaubten Zustand angewiesen und muss die obigen Nachteile in Kauf nehmen.

7.4.6 Unterschiedliche Punktdichten

Der Vergleich der Erkennungsraten für die unterschiedlichen Punktdichten von 10 und 25 Punkten/m² (Abschnitt 6.2.6) zeigt insgesamt kaum einen Nachteil für die niedrige Punktdichte. Trotz einer deutlichen Verringerung der Lasermessungen werden also die relevanten Baumstrukturen immer noch erfasst. Nur die Stammerkennung arbeitet bei der niedrigen Dichte schlechter, weil nicht genügend Stammreflexionen vorliegen. Auf das Endergebnis der 3D Segmentierung hat das aber kaum Auswirkungen. Im Hinblick auf eine großflächige Anwendung des Verfahrens sollte man herausfinden, wie weit die Punktdichte noch reduziert werden kann, bis eine deutliche Verschlechterung der Erkennungsrate auftritt. Zusätzlich muss untersucht werden, wie sich die Qualität der Segmente dabei verändert, also ob z.B. ein Nachteil bei der Bestimmung des Holzvolumens auftritt.

7.4.7 Vorteil der Full Waveform Technologie

Beim Vergleich der First/Last-Pulse Daten aus dem Jahr 2002 (Datensatz II) mit den Full Waveform Daten aus dem Jahr 2007 (Datensatz VI) im Abschnitt 6.2.7 ist der technologische Fortschritt klar zu erkennen. Trotz der gleichen nominalen Punktdichte werden die Bäume durch die Full Waveform Daten viel detaillierter abgebildet, was sich positiv auf die Segmentierung auswirkt. Die deutliche Erhöhung der Erkennungsrate in der Unter- und Zwischenschicht ist nur möglich, weil durch die Auswertung der Waveforms eine sehr hohe räumliche Punktdichte entsteht und dadurch auch der untere Teil des Waldes noch gut in den Laserdaten abgebildet wird. Es können selbst schwache und sich überlappende Reflexionen erkannt werden, was zu einer effektiven Punktdichte führt, die zwei bis drei Mal höher ist als bei den First/Last-Pulse Daten. Insgesamt trägt also sowohl die neue Technologie als auch die neue Segmentierungsmethode zur Erhöhung der Erkennungsrate bei.

Die Verwendung der Merkmale Intensität und Pulsbreite in der Normalized Cut Segmentierung bringt nur eine geringe, aber dennoch konstante Verbesserung. Das kann man damit erklären, dass diese Merkmale für Bäume gleicher Baumart ähnlich sind, was deren positiver Effekt bei der Baumartenklassifikation zeigt. Deshalb ist nur für benachbarte Bäume unterschiedlicher Baumart ein positiver Einfluss bei der Segmentierung möglich.

7.4.8 Vergleich der beiden Full Waveform Scanner

Im Abschnitt 6.2.8 werden die Erkennungsraten für die beiden Full Waveform Scanner von TopEye und Riegl auf zwei Referenzflächen miteinander verglichen. Der einzige Unterschied liegt dabei in der Erkennung von Baumstämmen, bei der die Riegl Daten wesentlich bessere Ergebnisse liefern. Der Grund hierfür liegt vermutlich in den verschiedenen Wellenlängen, die beim Riegl Scanner 1550 nm und beim TopEye Scanner 1064 nm beträgt. Die Untersuchungen von Danson et al. [2008] bekräftigen das. Beim Vergleich terrestrischer Scanner mit unterschiedlichen Wellenlängen stellen sie fest, dass bei 1550 nm starke Reflexionen an den Stämmen stattfinden, bei 900 nm jedoch nur schwache.

7.5 Baumartenklassifikation

7.5.1 Unterscheidung von Laub- und Nadelbäumen

Überwachte und unüberwachte Klassifikation

Vergleicht man die Ergebnisse der überwachten und der unüberwachten Klassifikation von Laub- und Nadelbäumen (Tabellen 6.13 und 6.14), dann zeigen sich bei der überwachten Klassifikation leichte Vorteile von bis zu 4 %. Aus diesem Grund ist die überwachte Klassifikation der unüberwachten vorzuziehen, wenn dafür eine ausreichende Anzahl repräsentativer Trainingsdaten vorliegt. Für die hier erzielten Ergebnisse wurde beispielsweise ein Fünftel der Daten als Trainingsdaten verwendet.

Bei der unüberwachten Klassifikation sind deutlich weniger Referenzdaten erforderlich, weil diese nur für die Zuordnung der Cluster zur jeweiligen Baumart eingesetzt werden. Insbesondere bei der guten Unterscheidbarkeit von Laub- und Nadelbäumen reicht hierzu ein kleiner Datensatz aus. Beim Einsatz der Baumartenklassifikation in der Praxis muss also abgewägt werden, ob die leicht besseren Ergebnisse der überwachten Klassifikation den höheren Aufwand für die Erfassung von Referenzdaten rechtfertigen.

Watershed und Normalized Cut Segmente

Die prozentualen Klassifikationsergebnisse sind für die Watershed Segmente (Tabelle 6.13) und die 3D Normalized Cut Segmente (Tabelle 6.14) nahezu identisch. Beim Vergleich muss jedoch beachtet werden, dass die Anzahl der detektierten Bäume bei der Normalized Cut Segmentierung höher ist als bei der Watershed Segmentierung. Somit werden bei Verwendung der 3D Segmente insgesamt mehr Bäume richtig klassifiziert.

Die Betrachtung der Klassifikationsgenauigkeit in Abhängigkeit von der Höhengschicht (Tabelle 6.16) zeigt, dass auch die bei der Normalized Cut Segmentierung gefundenen Bäume der Unter- und Zwischenschicht mit hoher Genauigkeit klassifiziert werden. Offensichtlich sind die eingesetzten Merkmale sowohl für die dominanten Bäume der Oberschicht als auch für die dominierten Bäume der Unter- und Zwischenschicht charakteristisch.

Merkmale aus den Attributen der Reflexionen

Vergleicht man die Wirksamkeit der verschiedenen Merkmale (Tabellen 6.13 und 6.14), dann fallen sofort die hohen Klassifikationsgenauigkeiten auf, die mit Hilfe der Intensitätsmerkmale S_1^1 und S_1^2 bei den Datensätzen V und VI erreicht werden. Bei diesen Daten, die im belaubten Zustand erfasst wurden, weisen die Reflexionen von Laubbäumen im Mittel eine deutlich höhere Intensität auf als

die Reflexionen von Nadelbäumen. Die unterschiedlichen Materialeigenschaften von Laub- und Nadelbäumen spiegeln sich also in den Intensitätswerten wider. Das zeigt indirekt, dass die Kalibrierung der Intensität erfolgreich durchgeführt wurde.

Es stellt sich jedoch die Frage, warum die Intensitätsmerkmale beim Datensatz III, der auch im belaubten Zustand erfasst wurde, bei weitem nicht so erfolgreich sind. Hierfür sind zwei Gründe denkbar. Zum einen waren die Blätter bei der Erfassung dieses Datensatzes schon verfärbt und teilweise sogar schon abgefallen, weil die Befliegung erst im September stattfand. Zum anderen unterscheiden sich die Wellenlängen der beiden Scanner von TopEye und Riegl, was sich auf das Reflexionsverhalten der Laserstrahlen auswirkt.

Beim Datensatz IV, der im unbelaubten Zustand erfasst wurde, wirken die Intensitätsmerkmale zwar besser als beim Datensatz III, jedoch lange nicht so gut wie bei den Datensätzen V und VI. Das deutet darauf hin, dass die Blätter der Laubbäume bei der Wellenlänge des Riegl Scanners wesentlich zum Intensitätsunterschied zwischen Laub- und Nadelbäumen beitragen.

Ein Vergleich von S_I^1 und S_I^2 zeigt, dass S_I^2 bei allen Datensätzen etwas bessere Ergebnisse liefert als S_I^1 . Das weist darauf hin, dass die mittlere Intensität aller Reflexionen eines Segments, welche durch S_I^2 repräsentiert wird, charakteristischer ist als nur der Mittelwert der obersten Höhenschicht, der in S_I^1 enthalten ist.

Das Merkmal S_W , das für die mittlere Pulsbreite der Reflexionen eines Segments steht, trägt nur bei den Datensätzen III und IV wesentlich zur Unterscheidung von Laub- und Nadelbäumen bei. Bei den Datensätzen V und VI zeigt dieses Merkmal fast keine Wirkung. Daraus kann man schließen, dass Reflexionen an Nadelbäumen und Laubbäumen mit einem geschlossenen Kronendach eine ähnliche Pulsbreite besitzen. Erst bei nicht mehr so dichtem, bzw. komplett abgefallenem Laub zeigen sich Unterschiede. Vermutlich finden dann bei den Laubbäumen mehr Reflexionen an den Ästen statt, so dass eine höhere Pulsbreite entsteht.

Die Merkmale S_n^1 und S_n^2 , welche die Durchdringbarkeit der Bäume charakterisieren, sind bei den Datensätzen V und VI fast wirkungslos. Beim Datensatz IV hingegen stellen sie die besten Merkmale dar. Offensichtlich ist also die Durchdringbarkeit von Nadel- und Laubbäumen im belaubten Zustand ähnlich, wohingegen im unbelaubten Zustand signifikante Unterschiede vorhanden sind. Beim Datensatz III sind die Klassifikationsgenauigkeiten höher als bei den Datensätzen V und VI, jedoch niedriger als beim Datensatz IV. Das ist ein deutlicher Hinweis dafür, dass bei diesen im Herbst erfassten Daten die Blätter der Laubbäume schon teilweise abgefallen waren. Die obigen Aussagen zur Wirksamkeit dieser Merkmale in Abhängigkeit von der Belaubung gelten natürlich nicht allgemein für alle Laub- und Nadelbäume, sondern nur für die in den Referenzflächen vorhandenen Baumarten. So berichten zum Beispiel [Moffiet et al. \[2005\]](#) von guten Ergebnissen mit dem Merkmal S_n^2 bei der Unterscheidung von Weißen Zypressen (*Callitris glaucophylla*) und Eukalyptusbäumen (*Eucalyptus populnea*) im belaubten Zustand.

Merkmale aus den Koordinaten der Reflexionen

Die Merkmale S_g , welche die äußere Baumgeometrie beschreiben, zeigen mit ca. 80 % eine annähernd konstante Klassifikationsgenauigkeit für alle Datensätze. Somit liefern diese Merkmale für die First/Last-Pulse Daten des Datensatz II die besten Ergebnisse. Bei den Full Waveform Daten findet trotz der höheren räumlichen Punktdichte keine Steigerung statt, so dass diese Merkmale hier weniger bedeutend sind. Die für diese Merkmale relevanten Baumstrukturen sind also bereits in den First/Last-Pulse Daten abgebildet. Zum Vergleich wenden [Holmgren & Persson \[2004\]](#) ein ähnliches Merkmal wie S_g^1

auf First/Last-Pulse Daten an, um Fichten und Kiefern zu unterscheiden. Sie erreichen damit eine etwas niedrigere Klassifikationsgenauigkeit von ca. 70 %. Durch eine Kombination dieses Merkmals mit Merkmalen der Punktverteilung und der Intensität können sie diese beiden Baumarten jedoch mit einer Genauigkeit von 95 % klassifizieren.

Die Merkmale S_i^h und S_i^d gehören sowohl bei den First/Last-Pulse Daten als auch bei den Full Waveform Daten zu den Merkmalen mit den schlechtesten Ergebnissen. Das steht im Gegensatz zu Heurich [2006], der mit dem Merkmal S_i^h für First/Last-Pulse Daten, die im laublosen Zustand erfasst wurden, eine Klassifikationsgenauigkeit von 94 % erreicht. Vermutlich liegt das an der speziellen Situation, dass bei diesen Daten nur die letzten Punkte aufgezeichnet wurden. Offensichtlich können gerade damit Nadel- und Laubbäume im Winter gut voneinander unterschieden werden, weil die letzten Punkte bei den Laubbäumen größtenteils am Boden liegen, bei den Nadelbäumen hingegen nicht. Im Gegensatz dazu werden in der vorliegenden Arbeit bei der Berechnung von S_i^h und S_i^d alle Punktklassen verwendet. Gerade durch die Auswertung der Waveforms entstehen auch bei Laubbäumen ohne Blätter viele Punkte in der Krone, so dass eine Unterscheidung nicht eindeutig ist. In künftigen Untersuchungen sollte daher getestet werden, ob nur die Verwendung von letzten Punkten bei diesen Merkmalen zu besseren Ergebnissen führt.

Vorteil der Full Waveform Technologie

Bei der Klassifikation von Laub- und Nadelbäumen zeigen sich die Vorteile der Full Waveform Technologie insbesondere im belaubten Zustand. Hier kann vor allem mit Hilfe der Intensitätsmerkmale S_1^1 und S_1^2 eine Klassifikationsgenauigkeit von ca. 95 % erreicht werden. Während im unbelaubten Zustand ähnlich gute Ergebnisse auch schon mit First/Last-Pulse Daten erzielt wurden, konnte dies im belaubten Zustand bislang nicht erbracht werden. Auch Heurich [2006] erlangt unter Verwendung von First/Last-Pulse Sommerdaten lediglich eine Klassifikationsgenauigkeit von ca. 80 %, was mit den Ergebnissen des Datensatz II (Tabellen 6.13 und 6.14) der vorliegenden Arbeit in Einklang steht.

7.5.2 Unterscheidung einzelner Laub- und Nadelbaumarten

Fichte und Tanne

Bei der Klassifikation zwischen den beiden Nadelbaumarten Tanne und Fichte (Abschnitt 6.3.2) zeigt sich eine überraschend gute Klassifikationsrate von 93 % (Tabelle 6.17). Für die Beurteilung dieses Ergebnisses muss jedoch Folgendes beachtet werden:

- Wegen der wenigen Tannen in den Referenzflächen ist diese Baumart bei der Klassifikation stark unterrepräsentiert. Die Gesamtgenauigkeit ist stark von der hohen Herstellergenauigkeit der Fichten beeinflusst.
- Die vorhandenen Tannen sind überwiegend sehr alt, so dass sie die typische „Storchennestkrone“ besitzen. Diese entsteht, weil der Gipfeltrieb weniger stark in die Höhe wächst als die unmittelbar darunter stehenden und schräg nach oben wachsenden Seitentriebe [LWF, 2004]. Fichten hingegen haben immer eine spitze Krone, so dass vor allem das Geometriemerkmal S_g^2 die beiden Baumarten unterscheidet. Bei jüngeren Tannen ist die Unterscheidung vermutlich schwieriger.

Man kann also folgern, dass mit den hier verwendeten Merkmalen zumindest bei älteren Tannen eine erfolgreiche Klassifikation möglich ist. Für die Ermittlung repräsentativer Ergebnisse sind jedoch

weitergehende Untersuchungen mit einer höheren Anzahl von Tannen und einer gleichmäßig verteilten Altersstruktur unbedingt notwendig.

Buche und Ahorn

Bei der Klassifikation zwischen den beiden Laubbaumarten Buche und Ahorn können mit den vorhandenen Daten und den hier verwendeten Merkmalen keine brauchbaren Ergebnisse erzielt werden. Vermutlich ist dafür die Ähnlichkeit zwischen diesen Bäumen sowohl im belaubten als auch im unbelaubten Zustand zu groß. Aus diesem Resultat darf man jedoch nicht folgern, dass eine Unterscheidung einzelner Laubbaumarten mit Hilfe von Laserdaten generell nicht möglich ist. Zum Beispiel gelingt [Brandtberg \[2007\]](#) die Unterscheidung der drei Arten Eiche (*Quercus spp.*), Rot-Ahorn (*Acer rubrum*) und Tulpenbaum (*Liriodendron tuliperifera*) im unbelaubten Zustand mit einer Genauigkeit von 64 %. Er berechnet dazu Merkmale der Höhenverteilung der Laserpunkte und der Intensität aus First/Last-Pulse Daten, wobei die Reflexionen abhängig von ihrer Art (d.h. erste, letzte oder einzelne) und deren Höhe (d.h. Baum oder Boden) in fünf Gruppen eingeteilt werden. Ein direkter Vergleich zu dieser Arbeit ist wegen der anderen Baumarten kaum möglich. Jedoch zeigt die nicht sehr hohe Klassifikationsgenauigkeit von 64 %, dass die Unterscheidung einzelner Laubbaumarten mit Laserscanning schwierig ist. Eine Kombination mit optischen Multi- oder Hyperspektraldaten ist hier sicherlich hilfreich.

Kapitel 8

Zusammenfassung und Ausblick

8.1 Zusammenfassung

In der vorliegenden Arbeit konnten Verbesserungen bei der Segmentierung von Einzelbäumen und der Bestimmung der zugehörigen Baumart aus Daten luftgestützter Laserscanner erzielt werden. Für diesen Fortschritt sind zwei Faktoren verantwortlich:

- Zum einen ermöglicht die technologische Weiterentwicklung der Scanner eine Aufzeichnung des gesamten Signalverlaufs. Dadurch ist die Grundlage für eine detaillierte Analyse des reflektierten Signals geschaffen, die insbesondere im Vegetationsbereich zusätzliche Informationen liefert.
- Zum anderen wurden neue Methoden erarbeitet, die den hohen Informationsgehalt dieser Daten nutzen können und so zu besseren Ergebnissen führen.

Zerlegung der Waveforms

Im Einzelnen wurde gezeigt, dass die vorgestellte Methode zur Zerlegung der Waveforms durch eine Anpassung von Gauß-Funktionen bei den zwei eingesetzten Lasersystemen sehr gut anwendbar ist. Die in das Verfahren integrierte Erkennung von Nachschwingern erweist sich als notwendig und effektiv. Zusätzlich ermöglicht die Schätzung von Genauigkeiten im Zuge der Ausgleichung eine interne Qualitätskontrolle der Ergebnisse. Die Vorteile dieser Auswertung der Lasermessungen gegenüber der diskreten Erfassung von Punkten im Lasersystem wurden an Hand von Beispielen veranschaulicht:

- Überlagerte Reflexionen können getrennt werden, so dass Objekte mit einem Abstand von weniger als einen halben Meter in der Ausbreitungsrichtung des Laserstrahls noch aufgelöst werden können. Bei diskreten Systemen beträgt dieser Abstand mindestens eine volle Pulslänge.
- Auch schwache Reflexionen werden berücksichtigt, die bei der diskreten Erfassung häufig vernachlässigt werden.
- Insbesondere im Vergleich zu First/Last-Pulse Systemen erhält man viele zusätzliche Reflexionen, die zwischen dem ersten und dem letzten Puls liegen.
- Insgesamt führt die Auswertung der Waveforms zu einer höheren räumlichen Punktdichte, so dass die Waldstrukturen detaillierter abgebildet werden.
- Aus der Form der erfassten Reflexionen können die Merkmale Intensität und Pulsbreite abgeleitet werden, die insbesondere für die Baumartenklassifikation wichtig sind.

Kalibrierung der Intensität

Bei der hier durchgeführten Kalibrierung der Intensität aus Daten unterschiedlicher Flughöhen zeigt sich, dass eine im Vergleich zur Radargleichung etwas abgeschwächte Korrektur anzubringen ist. Es müssen also beim eingesetzten Riegl LMS-Q560 Scanner Effekte auftreten, die in diesem Modell nicht berücksichtigt werden. Die Korrektheit der Kalibrierung wird indirekt durch die guten Ergebnissen der Baumartenklassifikation mit Hilfe der Intensität bestätigt.

Analyse der Merkmale Intensität und Pulsbreite

Eine Analyse der Merkmale Intensität und Pulsbreite für Boden-, Stamm- und Kronenpunkte von Laub- und Nadelbäumen führt zu folgenden Resultaten:

- Bodenpunkte besitzen eine vergleichsweise niedrige Pulsbreite und eine hohe Intensität. Dies kann bei der Filterung dieser Punkte genutzt werden.
- Bei den Stammpunkten nimmt die Pulsbreite mit steigendem Scanwinkel ab, die Intensität hingegen nimmt zu. Der Vergleich von Reflexionen an Stämmen von Laub- und Nadelbäumen zeigt, dass die Intensität von Einzelreflexionen gut für die Unterscheidung der beiden Baumarten geeignet ist. Offensichtlich liegt das am unterschiedlichen Reflexionsverhalten der Rinde. Eine flächenhafte Baumartenklassifikation mit Hilfe dieses Merkmals ist jedoch nicht möglich, weil solche Punkte nicht bei allen Bäumen vorhanden sind.
- Die Kronenpunkte von Laub- und Nadelbäumen weisen sowohl in der Intensität als auch in der Pulsbreite Unterschiede auf. Jedoch streuen die Einzelwerte stark, so dass nur Mittelwerte über einen bestimmten Bereich, wie z.B. ein gesamtes Baumsegment, aussagekräftig sind.

Erkennung von Einzelbäumen

Für die Erkennung von Einzelbäumen wurden drei verschiedene Verfahren vorgestellt und getestet:

- Die Segmentierung von Bäumen mit Hilfe des Watershed Algorithmus repräsentiert die Gruppe der Verfahren, die lediglich auf dem CHM basieren und die bis jetzt überwiegend für diesen Zweck eingesetzt werden. Diese Methode eignet sich gut zur Erkennung dominanter Bäume in der Oberschicht. In der Unter- und Zwischenschicht jedoch werden nur wenige Bäume gefunden, weil diese entweder im CHM gar nicht enthalten sind oder kein eigenes lokales Maximum besitzen. Auch in der Oberschicht führt die in einem gewissen Umfang notwendige Glättung des CHM zu einer Verschmelzung eng beieinander stehender Bäume. Diese Art der Segmentierung hat zwei grundsätzliche Defizite: Zum einen wird die hohe räumliche Punktdichte aus der Waviform Zerlegung kaum genutzt. Zum anderen erhält man 2D Segmente, die keine Überlappung benachbarter Bäume erlauben. Insbesondere auf mehrschichtige, naturnahe Wälder trifft dieses Modell nicht zu.
- Die Methode zur Erkennung von Baumstämmen geht einen Schritt weiter und nutzt Informationen unterhalb des CHM. Im Vergleich zur Watershed Segmentierung kann dadurch die Erkennungsrate gesteigert und die Genauigkeit der Baumpositionen erhöht werden. Allerdings hat auch dieses Verfahren zwei entscheidende Schwächen: Zum einen muss eine ausreichende Anzahl gut isolierbarer Stammreflexionen vorliegen. Dies setzt eine hohe Punktdichte und eine

klare Trennbarkeit der Bäume in einen Stamm- und einen Kronenbereich voraus. Zum anderen werden den gefundenen Stämmen keine Kronenpunkte zugeordnet, so dass die Bäume zwar erkannt, aber nicht segmentiert werden können.

- Die 3D Segmentierung von Bäumen mit Hilfe der Normalized Cut Methode überwindet die Defizite der beiden anderen Verfahren. Hier werden alle Reflexionen genutzt, so dass kein Informationsverlust durch die Reduktion auf das CHM entsteht. Durch die Zuordnung der Reflexionen zum jeweiligen Baum besteht keine Einschränkung bezüglich der Form des Segments im 3D Raum, so dass ein Baumsegment im Idealfall genau die Laserpunkte enthält, die von diesem Baum stammen. Ein großer Vorteil im Vergleich zu anderen 3D Verfahren liegt darin, dass keine Saatpunkte zur Initialisierung benötigt werden. Durch die große Flexibilität bezüglich der Eingangsinformationen kann das Verfahren sowohl auf konventionelle First/Last-Pulse Daten als auch auf Full Waveform Daten samt deren Merkmalen angewendet werden. Die Experimente zeigen, dass mit diesem Verfahren die Erkennungsrate in der unteren Waldschicht erheblich gesteigert werden kann. Beim Einbringen von Vorwissen aus der Watershed Segmentierung und der Stammerkennung findet auch in den oberen Waldschichten eine Steigerung im Vergleich zur alleinigen Anwendung dieser Verfahren statt. Neben der höheren Erkennungsrate ist die detaillierte Abbildung der Bäume in den 3D Segmenten für die Ableitung von Baumparametern sicherlich vorteilhaft. Dies muss jedoch in künftigen Arbeiten näher untersucht werden.

Baumartenklassifikation

Die durchgeführten Klassifikationen zwischen Laub- und Nadelbäumen führen zu folgenden Erkenntnissen:

- Sowohl bei der überwachten ML Klassifikation als auch bei der unüberwachten EM Klassifikation ergeben sich hohe Klassifikationsraten, wobei die überwachte Methode geringfügig bessere Ergebnisse liefert.
- Die prozentualen Klassifikationsergebnisse sind für die Watershed Segmente und die Normalized Cut Segmente nahezu identisch. Wegen der höheren Erkennungsrate bei der Normalized Cut Segmentierung liegen hier auch mehr richtig klassifizierte Bäume vor. Eine Analyse bezüglich der Höhenschichten zeigt, dass die Klassifikationsraten auch für die Bäume der unteren Schichten hoch sind.
- Die zusätzlichen Informationen aus den Full Waveform Daten wirken sich positiv auf die Klassifikationsergebnisse aus. Insbesondere durch die Nutzung der Intensität wurde eine erhebliche Verbesserung gegenüber First/Last-Pulse Daten erreicht. Während im unbelaubten Zustand auch schon mit First/Last-Pulse Daten eine sehr gute Unterscheidung zwischen Laub- und Nadelbäumen möglich war, konnte im belaubten Zustand nur eine Klassifikationsrate von ca. 80 % erzielt werden. Mit Hilfe der Intensität jedoch wird jetzt auch im belaubten Zustand eine Klassifikationsrate von ca. 95 % erreicht. Das zeigt indirekt, dass die Kalibrierung der Intensität erfolgreich durchgeführt wurde.

Bei der Klassifikation einzelner Laub- und Nadelbaumarten zeigt sich für Fichten und Tannen ein gutes Ergebnis, das jedoch wegen der geringen Anzahl von Tannen und deren einseitiger Altersstruktur nicht sehr repräsentativ ist. Hier sind weitere Untersuchungen erforderlich. Die Klassifikation zwischen

Buche und Ahorn führt zu keinem brauchbaren Ergebnis. Vermutlich ist die Ähnlichkeit zwischen diesen Baumarten zu groß, um alleine mit Laserdaten eine Unterscheidung zu erreichen.

8.2 Ausblick

Auf Grund der Experimente im Kapitel 6 und der Diskussion der Ergebnisse im Kapitel 7 werden die folgenden weiterführenden Untersuchungen vorgeschlagen:

Zerlegung der Waveforms

Beim vorgestellten Verfahren zur Zerlegung der Waveforms werden überlagerte Reflexionen nur dann getrennt, wenn diese in den Echoprofilen entweder durch lokale Maxima oder Terrassenpunkte gekennzeichnet sind. Das Verfahren sollte deshalb erweitert werden, so dass auch Reflexionen erkannt werden, die wegen ihres geringen Abstands die obigen Kennzeichen nicht aufweisen. Dazu eignet sich die zweite Ableitung von $w(t)$, deren Maxima und Minima an den auf- und absteigenden Flanken stärkerer Reflexionen auf weitere schwächere Reflexionen hindeuten. Zusätzlich sollte eine Analyse der Verbesserungen v nach der Ausgleichung durchgeführt werden. Wenn dabei Werte auftreten, die deutlich über dem Rauschen liegen, so ist das ein Hinweis auf nicht erkannte Reflexionen. Bei diesen Schritten muss jedoch darauf geachtet werden, dass keine Überparametrisierung entsteht und nicht mehr Gauß Funktionen an die Waveforms angepasst werden, wie Reflexionen vorliegen.

Weiterhin sollte untersucht werden, inwiefern im Vegetationsbereich eine gemeinsame Auswertung benachbarter Signale für die Erkennung schwacher Reflexionen genutzt werden kann. [Stilla et al. \[2007\]](#) zeigen, dass dadurch im urbanen Bereich Objekte besser identifiziert werden können, die teilweise verdeckte sind oder eine schwache Oberflächenantwort besitzen. Da dieser Ansatz auf Hypothesen für Ebenen verschiedener Neigung beruht, ist eine direkte Übertragung auf den Waldbereich nicht sinnvoll. Jedoch könnte eine Erweiterung auf Zylinder oder Kegel zu einer besseren Erkennung von Reflexionen an Baumstämmen führen.

Kalibrierung und Nutzung der Intensität

Für eine weitergehende Kalibrierung und Nutzung der Intensität im Waldbereich sind noch detaillierte Untersuchungen notwendig. Es gibt zwar schon Kenntnisse darüber, wie die Beschaffenheit künstlicher Objekte mit bekannter Geometrie die Signalform von Laserpulsen beeinflusst [[Jutzi, 2007](#)], jedoch fehlt bis jetzt das Verständnis dafür, wie sich der Laserstrahl bei der Interaktion mit Bäumen verhält. Ein eindrucksvolles Beispiel für das Potenzial des Merkmals Intensität ist die hier gezeigte Unterscheidung von Baumarten an Hand von nur wenigen Einzelreflexionen an den Baumstämmen. Die Reflexionen in den Baumkronen ermöglichen zwar auch eine Unterscheidung von Baumarten, jedoch sind hier nur Mittelwerte über einen größeren Bereich aussagekräftig. Die Einzelwerte streuen stark und werden bislang nicht genutzt, obwohl darin die für den beleuchteten Bereich spezifischen Objekteigenschaften enthalten sind. Mit dem Ansatz von [Morsdorf et al. \[2007\]](#), die über ein Baummodell und ein Raytracing-Verfahren theoretische Waveforms ableiten, wird versucht, hierfür ein Verständnis zu entwickeln. Die Verifizierung mit realen Daten fehlt jedoch. Es sollte daher die Struktur von Referenzbäumen mit Hilfe eines terrestrischen Laserscanners sehr detailliert bestimmt werden. Die aus der Luft erfassten Full Waveform Daten können dann bezüglich der bekannten Baumstruktur analysiert werden.

Erkennung von Einzelbäumen

Bei der Normalized Cut Segmentierung sollte die Nachbearbeitung der Segmente unter Einbeziehung baumspezifischen Wissens verfeinert werden, weil mit den bisherigen Schritten lediglich grobe Fehler beseitigt werden. Insbesondere ist das Verwerfen von Segmenten, die für einen eigenen Baum zu klein sind, keine optimale Lösung. Besser wäre es, diese Fragmente den Segmenten zuzuordnen, denen sie wirklich angehören.

Außerdem sollte der Schwellwert $NCut_{max}$ in Abhängigkeit von bestimmten Kriterien variabel gestaltet werden. Zum Beispiel können für die zu segmentierende Waldfläche vorab Informationen über die Baumarten und Altersklassen ermittelt werden. Hierzu eignen sich die Intensität der Reflexionen und deren Höhe über Grund. Diese Informationen können dann für die gebietsweise Festlegung von $NCut_{max}$ genutzt werden.

Der Hauptgrund dafür, dass selbst bei der Normalized Cut Segmentierung noch viele kleine Bäume nicht als Einzelbäume erkannt werden, liegt in deren Zusammenfassung zu einem Segment. Weil gerade bei den kleinen Bäumen die Ermittlung der Anzahl viel wichtiger ist als die Bestimmung der genauen Positionen, sollten diese Segmente statistisch weiter untersucht werden. Dazu kann mit Hilfe der Referenzdaten analysiert werden, wie viele Bäume sich durchschnittlich in einem Segment mit einer bestimmten Ausdehnung und einer bestimmten Höhe befinden. Ähnlich einer überwachten Klassifikation wird diese Kenntnis dann auf alle Daten übertragen. Somit kann die Zahl der gefundenen kleinen Bäume erheblich gesteigert werden [Flewelling, 2008].

Weiterhin sollte man die 3D Segmente detaillierter mit den Referenzbäumen vergleichen, um die Qualität der Segmente besser beurteilen zu können. Daraus gewonnene Erkenntnisse können für eine weitere Verbesserung des Segmentierungsverfahrens eingesetzt werden. Für die genaue Erfassung der Referenzdaten eignen sich terrestrische Laserscanner.

Baumartenklassifikation

Eine Einschränkung bei der Nutzung der Intensität aus den Laserdaten ist die Verfügbarkeit nur eines spektralen Kanals bei der Wellenlänge des Laserstrahls. Deshalb können Baumarten mit ähnlichen Reflexionseigenschaften bei dieser Wellenlänge nur dann erfolgreich klassifiziert werden, wenn andere Merkmale, wie die Baumgeometrie, signifikante Unterschiede aufweisen. Aus diesem Grund sollten zusätzliche spektrale Merkmale passiver optischer Sensoren bei der Baumartenklassifikation eingesetzt werden. Insbesondere Hyperspektraldaten sind für diese Aufgabe besonders gut geeignet, wie z.B. die Studie von Clark et al. [2005] zeigt.

Obwohl die Bestimmung der Baumart mit optischen Daten einfacher zu sein scheint als mit Laserdaten, sollten dennoch die Möglichkeiten des Laserscanning auf diesem Gebiet voll ausgeschöpft werden. Im Gegensatz zu den passiven optischen Verfahren kann beim aktiven Laserscanning gut zwischen Reflexionen an dominanten Bäumen der Waldoberfläche und dominierten Bäumen in den unteren Waldschichten unterschieden werden. Somit können mit Hilfe der Laserdaten auch die Bäume unterhalb der Waldoberfläche klassifiziert werden. Es sollte daher bei der Baumartenklassifikation nicht auf das Laserscanning verzichtet werden. Momentan laufen sogar Untersuchungen im Hinblick auf multispektrale Laserscanner. Morsdorf et al. [2008] stellen zum Beispiel das Konzept für ein Instrument vor, das mit vier Kanälen arbeitet. Für die Baumartenbestimmung ergeben sich daraus sicherlich Vorteile.

Ableitung weiterer Baumparameter

Neben der Baumart müssen weitere Eigenschaften der Bäume aus den Segmenten abgeleitet werden. Das Stammvolumen stellt hierbei die wichtigste Zielgröße für die Waldinventur dar. Da die Baumstämme in den luftgestützten Laserdaten nicht so detailliert erfasst sind, dass man daraus direkt das Volumen berechnen kann, ist eine indirekte Bestimmung mit Hilfe anderer Größen notwendig. Bei Segmenten, die auf dem CHM basieren, werden dafür meist die Baumhöhe und die projizierte Kronenfläche verwendet [Persson et al., 2002; Hyypä et al., 2001]. Dabei wird die Beziehung zwischen diesen Größen und dem Stammvolumen auf Referenzflächen mit Hilfe von Regressionen geeicht. Bei den 3D Segmenten aus der Normalized Cut Segmentierung sollte neben der Fläche auch das Volumen der Krone berechnet und für die Ableitung des Stammvolumens genutzt werden, weil das Kronenvolumen ein Maß für die fotosynthetische Aktivität des Baums ist und somit ein enger Zusammenhang zum Stammvolumen besteht [Kato et al., 2009].

Ähnlich wie das Stammvolumen ist auch das Baumalter ein Parameter der Waldinventur, der nur indirekt bestimmt werden kann. Kalliovirta & Tokola [2005] nutzen dafür die Baumhöhe und den maximalen Durchmesser von Kronenpolygonen, die sie aus Luftbildern ableiten. Auch hier ist zu erwarten, dass sich die Verwendung des Kronenvolumens aus den 3D Segmenten positiv auswirkt.

Literaturverzeichnis

- Albertz J (2007) *Einführung in die Fernerkundung. Grundlagen der Interpretation von Luft- und Satellitenbildern*. 3., aktualisierte und erweiterte Auflage. Wissenschaftliche Buchgesellschaft, Darmstadt.
- Andersen H-E, McGaughey RJ, Carson WW, Reutebuch SE, Mercer B, Allan J (2003) A Comparison of Forest Canopy Models Derived from LiDAR and InSAR Data in a Pacific NorthWest Conifer Forest. In: Maas H-G, Vosselman G, Streilein A (eds) *ISPRS Workshop '3-D reconstruction from airborne laserscanner and InSAR data'*. IAPRS 34 (Part 3/W13): 211–217.
- Baglama J, Calvetti D, Reichel L (2003) IRBL: An Implicitly Restarted Block Lanczos Method for Large-Scale Hermitian Eigenproblems. *SIAM Journal on Scientific Computing*, 24 (5): 1650–1677.
- Baltsavias E, Gruen A, Eisenbeiss H, Zhang L, Waser LT (2008) High-quality image matching and automated generation of 3D tree models. *International Journal of Remote Sensing*, 29 (5): 1243–1259.
- Balzter H, Rowland CS, Saich P (2007) Forest canopy height and carbon estimation at Monks Wood National Nature Reserve, UK, using dual-wavelength SAR interferometry. *Remote Sensing of Environment*, 108 (3): 224–239.
- Barber CB, Dobkin DP, Huhdanpaa H (2006) The Quickhull Algorithm for Convex Hulls. *ACM Transactions on Mathematical Software (TOMS)*, 22 (4): 469–483.
- Bauerhansl C, Rottensteiner F, Briese C (2004) Determination of terrain models by digital image matching methods. In: Altan O (ed) *XX ISPRS Congress*. IAPRS 35 (Part B4): 414–419.
- Berk A, Bernstein LS, Anderson GP, Acharya PK, Robertson DC, Chetwynd JH, Adler-Golden SM (1998) MODTRAN Cloud and Multiple Scattering Upgrades with Application to AVIRIS. *Remote Sensing of Environment*, 65 (3): 367–375.
- Blackburn GA (2007) Hyperspectral remote sensing of plant pigments. *Journal of Experimental Botany*, 58 (4): 855–867.
- Blair JB, Coyle DB, Bufton JL, Harding DJ (1994) Optimization of an Airborne Laser Altimeter for Remote Sensing of Vegetation and Tree Canopies. In: *International Geoscience and Remote Sensing Symposium - IGARSS 1994*: 939–941.
- Blair JB, Rabine DL, Hofton MA (1999) The Laser Vegetation Imaging Sensor: a medium-altitude, digitisation-only, airborne laser altimeter for mapping vegetation and topography. *ISPRS Journal of Photogrammetry and Remote Sensing*, 54: 115–122.
- Brandtberg T (2007) Classifying individual tree species under leaf-off and leaf-on conditions using airborne lidar. *ISPRS Journal of Photogrammetry and Remote Sensing*, 61 (5): 325–340.
- Brandtberg T, Walter F (1998) Automated delineation of individual tree crowns in high spatial resolution aerial images by multiple-scale analysis. *Machine Vision and Applications*, 11: 64–73.

- Briese C, Höfle B, Lehner H, Wagner W, Pfennigbauer M, Ullrich A (2008) Calibration of full-waveform airborne laser scanning data for object classification. *SPIE Laser Radar Technology and Applications XIII*, 6950.
- Chen Q, Gong P, Baldocchi D, Tian YQ (2007) Estimating Basal Area and Stem Volume for Individual Trees from Lidar Data. *Photogrammetric Engineering & Remote Sensing*, 73 (12): 1355–1365.
- Clark ML, Roberts DA, Clark DB (2005) Hyperspectral discrimination of tropical rain forest tree species at leaf to crown scales. *Remote Sensing of Environment*, 96: 375–398.
- Danson FM, Armitage RP, Bandugula V, Ramirez FA, Tate NJ, Tansey KJ, Tegzes T (2008) Terrestrial laser scanners to measure forest canopy gap fraction. In: Hill R, Suárez J, Rosette J (eds) *SilviLaser 2008, 8th international conference on LiDAR applications in forest assessment and inventory*: 335–341.
- Dempster AP, Laird NM, Rubin DB (1977) Maximum-Likelihood from incomplete data via the EM algorithm. *Journal of the Royal Statistical Society*, 39: 1–38.
- D'Errico J (2006) Surface fitting using gridfit. *MATLAB Central File Exchange Select*. <http://www.mathworks.com/matlabcentral/fileexchange> (Accessed 1. August 2007).
- Desclée B, Gingras A, Bemelmans V, Patigny E (2008) Forest mensuration parameters derived from individual tree crown forest inventory method using airborne imagery and LiDAR. In: Hill R, Suárez J, Rosette J (eds) *SilviLaser 2008, 8th international conference on LiDAR applications in forest assessment and inventory*: 67–75.
- Doneus M, Briese C (2006) Digital terrain modelling for archaeological interpretation within forested areas using full-waveform laserscanning. In: Ioannides M, Arnold D, Niccolucci F, Mania K (eds) *The 7th International Symposium on Virtual Reality, Archaeology and Cultural Heritage VAST (2006)*: 155–162.
- Fischer F, Knörzer O (2003) *Statistische Analyse von digitalen Geländemodellen und Waldstrukturen im Nationalpark Bayerischer Wald mit Hilfe von hochaufgelösten Laserscanningdaten und GPS-Messungen*. München: Hochschule für angewandte Wissenschaften - FH München, Fakultät für Geoinformation, Diplomarbeit.
- Flewelling JW (2008) Probability models for individually segmented tree crown images in a sampling context. In: Hill R, Suárez J, Rosette J (eds) *SilviLaser 2008, 8th international conference on LiDAR applications in forest assessment and inventory*: 284–293.
- Gougeon FA (1995) A crown-following approach to the automatic delineation of individual tree crowns in high spatial resolution aerial images. *Canadian Journal of Remote Sensing*, 21: 274–284.
- Guenther GC, Mesick HC (1988) Analysis of airborne laser hydrography waveforms. *SPIE Ocean Optics IX*, 925: 232–241.
- Gutierrez R, Neuenschwander A, Crawford MM (2005) Development of laser waveform digitization for airborne LIDAR topographic mapping instrumentation. In: *International Geoscience and Remote Sensing Symposium - IGARSS 2005*: 1154–1157.
- Heurich M (2006) *Evaluierung und Entwicklung von Methoden zur automatisierten Erfassung von Waldstrukturen aus Daten flugzeuggetragener Fernerkundungssensoren*. Forstliche Forschungsberichte München. Wissenschaftszentrum Weihenstephan für Ernährung, Landnutzung und Umwelt der Technischen Universität München und der Bayerischen Landesanstalt für Wald und Forstwirtschaft.
- Höfle B, Hollaus M, Lehner H, Pfeifer N, Wagner W (2008) Area-based parameterization of forest structure using full-waveform airborne laser scanning data. In: Hill R, Suárez J, Rosette J (eds) *SilviLaser 2008, 8th international conference on LiDAR applications in forest assessment and inventory*: 227–235.

- Höfle B, Pfeifer N (2007) Correction of laser scanning intensity data: Data and model-driven approaches. *ISPRS Journal of Photogrammetry and Remote Sensing*, 62 (6): 415–433.
- Hofton MA, Minster JB, Blair JB (2000) Decomposition of laser altimeter waveforms. *IEEE Transactions on Geoscience and Remote Sensing*, 38 (4): 1989–1996.
- Holmgren J, Persson Å (2004) Identifying species of individual trees using airborne laser scanner. *Remote Sensing of Environment*, 90: 415–423.
- Hug C, Ullrich A, Grimm A (2004) LiteMapper-5600 - A Waveform-Digitizing LIDAR Terrain and Vegetation Mapping System. In: Thies M, Koch B, Spiecker H, Weinacker H (eds) *Laser Scanners for Forest and Landscape Assessment*. IAPRS 36 (Part 8/W2): 24–29.
- Hyypä J, Hyypä H, Inkinen M, Engdahl M, Linko S, Zhu Y (2000) Accuracy comparison of various remote sensing data sources in the retrieval of forest stand attributes. *Forest Ecology and Management*, 128 (1): 109–120.
- Hyypä J, Kelle O, Lehtikainen M, Inkinen M (2001) A Segmentation-Based Method to Retrieve Stem Volume Estimates from 3-D Tree Height Models Produced by Laser Scanners. *IEEE Transactions on Geoscience and Remote Sensing*, 39 (5): 969–975.
- Irish JL, Lillycrop WJ (1999) Scanning laser mapping of the coastal zone: the SHOALS system. *ISPRS Journal of Photogrammetry and Remote Sensing*, 54: 123–129.
- Jelalian AV (1992) *Laser radar systems*. Boston, MA: Artech House.
- Jutzi B (2007) *Analyse der zeitlichen Signalform von rückgestreuten Laserpulsen*. München: Technische Universität München (TUM), Fakultät für Bauingenieur- und Vermessungswesen, Fachgebiet Photogrammetrie und Fernerkundung, Dissertation.
- Jutzi B, Stilla U (2003) Laser pulse analysis for reconstruction and classification of urban objects. In: Ebner H, Heipke C, Mayer H, Pakzad K (eds) *Symposium of ISPRS Photogrammetric Image Analysis PIA03*. IAPRS 34 (Part 3/W8): 151–156.
- Jutzi B, Stilla U (2005) Measuring and processing the waveform of laser pulses. *Optical 3-D Measurement Techniques VII*, 1: 194–203.
- Jutzi B, Stilla U (2006a) Characteristics of the Measurement Unit of a Full-Waveform Laser System. In: *Symposium of ISPRS Commission I: From Sensors to Imagery*. IAPRS 36 (Part 1/A): (on CD-ROM).
- Jutzi B, Stilla U (2006b) Range determination with waveform recording laser systems using a Wiener Filter. *ISPRS Journal of Photogrammetry and Remote Sensing*, 61 (2): 95–107.
- Kaasalainen S, Hyypä J, Litkey P, Hyypä H, Ahokas E, Kukko A, Kaartinen H (2007) Radiometric calibration of ALS intensity. In: Rönholm P, Hyypä H, Hyypä J (eds) *ISPRS Workshop Laser Scanning 2007 and SilviLaser 2007*. IAPRS 36 (Part 3/W52): 201–205.
- Kalliovirta J, Tokola T (2005) Functions for estimating stem diameter and tree age using tree height, crown width and existing stand database information. *Silva Fennica*, 39 (2): 227–248.
- Kato A, Moskal LM, Schiess P, Swanson ME, Calhoun D, Stuetzle W (2009) Capturing tree crown formation through implicit surface reconstruction using airborne lidar data. *Remote Sensing of Environment*, 113: 1148–1162.
- Koch B, Heyder U, Weinacker H (2006) Detection of Individual Tree Crowns in Airborne Lidar Data. *Photogrammetric Engineering & Remote Sensing*, 72 (4): 357–363.

- Koetz B, Morsdorf F, Sun G, Ranson KJ, Itten K, Allgöwer B (2006) Inversion of a LIDAR Waveform Model for Forest biophysical Parameter Estimation. *IEEE Geosciences and Remote Sensing Letters*, 3 (1): 49–53.
- Kononov AA, Ka M–H (2008) Model-Associated Forest Parameter Retrieval Using VHF SAR Data at the Individual Tree Level. *IEEE Transactions on Geoscience and Remote Sensing*, 46 (1): 69–84.
- Krzystek P, Wild D (1992) Experimental accuracy analysis of automatically measured digital terrain models. In: Förstner W, Ruhwiedel S (eds) *Robust Computer Vision: Quality of vision algorithms*. Karlsruhe: Wichmann Verlag: 372–390.
- Lefsky MA, Harding D, Cohen WB, Parker G, Shugart HH (1999) Surface Lidar Remote Sensing of Basal Area and Biomass in Deciduous Forests of Eastern Maryland, USA. *Remote Sensing of Environment*, 67 (1): 83–98.
- Levenberg K (1944) A method for the solution of certain non-linear problems in least-squares. *Quarterly Journal of Applied Mathematics*, 2: 164–168.
- Lorenz M, Fischer R, Becher G, Granke O, Roskams P, Nagel HD, Kraft P (2007) *Forest Condition in Europe*. Technical Report of ICP Forests. Hamburg: Federal Research Centre for Forestry and Forest Products.
- LWF (2004) *LWF Wissen 45 - Beiträge zur Tanne*. Berichte der Bayerischen Landesanstalt für Wald und Forstwirtschaft. Freising.
- Mallet C, Bretar F (2009) Full-waveform topographic lidar: State-of-the-art. *ISPRS Journal of Photogrammetry and Remote Sensing*, 64 (1): 1–16.
- Maltamo M, Eerikäinen K, Pitkänen J, Hyyppä J, Vehmas M (2004) Estimation of timber volume and stem density based on scanning laser altimetry and expected tree size distribution functions. *Remote Sensing of Environment*, 90 (3): 319–330.
- Maltamo M, Packalén P, Peuhkurinen J, Suvanto A, Pesonen A, Hyyppä J (2007) Experiences and possibilities of ALS based forest inventories in Finland. In: Rönnholm P, Hyyppä H, Hyyppä J (eds) *ISPRS Workshop Laser Scanning 2007 and SilviLaser 2007*. IAPRS 36 (Part 3/W52): 270–279.
- Marquardt DW (1963) An algorithm for least-squares estimation of nonlinear parameters. *Journal of the Society of Industrial and Applied Mathematics*, 11: 431–441.
- Means JE, Acker SA, Harding DJ, Blair JB, Lefsky MA, Cohen WB, Harmon ME, McKee WA (1999) Use of Large-Footprint Scanning Airborne Lidar To Estimate Forest Stand Characteristics in the Western Cascades of Oregon. *Remote Sensing of Environment*, 67 (3): 298–308.
- Mehtätalo L (2006) Eliminating the effect of overlapping crowns from aerial inventory estimates. *Canadian Journal of Forest Research*, 36 (7): 1649–1660.
- Messner M (2007) *Normalized Cut Segmentierung mit Airborne Lidar Daten zur Erkennung von Einzelbäumen im Nationalpark Bayerischer Wald*. München: Hochschule für angewandte Wissenschaften - FH München, Fakultät 07 Informatik / Mathematik, Masterarbeit.
- Moffiet T, Mengersen K, Witte C, King R, Denham R (2005) Airborne laser scanning: Exploratory data analysis indicates potential variables for classification of individual trees or forest stands according to species. *ISPRS Journal of Photogrammetry and Remote Sensing*, 59 (5): 289–309.
- Morsdorf F, Frey O, Koetz B, Meier E (2007) Ray Tracing for Modeling of Small Footprint Airborne Laser Scanning Returns. In: Rönnholm P, Hyyppä H, Hyyppä J (eds) *ISPRS Workshop Laser Scanning 2007 and SilviLaser 2007*. IAPRS 36 (Part 3/W52): 294–299.

- Morsdorf F, Meier E, Allgöwer B, Nüesch D (2003) Clustering in airborne laser scanning raw data for segmentation of single trees. In: *ISPRS working group III/3 workshop 3-D reconstruction from airborne laserscanner and InSAR data*. IAPRS 34 (Part 3/W13): 27–33.
- Morsdorf F, Nichol C, Maltis TJ, Patenaude G, Woodhouse IH (2008) Modelling multi-spectral LIDAR vegetation backscatter - assessing structural and physiological information content. In: Hill R, Suárez J, Rosette J (eds) *SilviLaser 2008, 8th international conference on LiDAR applications in forest assessment and inventory*: 257–265.
- Naesset E (2004) Practical large-scale forest stand inventory using a small-footprint airborne scanning laser. *Scandinavian Journal of Forest Research*, 19 (2): 164–179.
- Niemann H (2003) *Klassifikation von Mustern*. 2. überarbeitete und erweiterte Auflage im Internet. <http://www5.informatik.uni-erlangen.de/fileadmin/Persons/NiemannHeinrich/klassifikation-von-mustern/m00-www.pdf> (Accessed 09. November 2009).
- Niemeier W (2002) *Ausgleichsrechnung. Eine Einführung für Studierende und Praktiker des Vermessungs- und Geoinformationswesens*. Berlin: Walter de Gruyter.
- Olofsson K (2002) Detection of single trees in aerial images using template matching. In: *ForestSat 2002, Operational Tools in Forestry using Remote Sensing Techniques*: (on CD-ROM).
- Ørka HO, Naesset E, Bollandsås M (2009) Classifying species of individual trees by intensity and structure features derived from airborne laser scanner data. *Remote Sensing of Environment*, 113: 1163–1174.
- Packalén P, Pitkänen J, Maltamo M (2008) Comparison of individual tree detection and canopy height distribution approaches: a case study in Finland. In: Hill R, Suárez J, Rosette J (eds) *SilviLaser 2008, 8th international conference on LiDAR applications in forest assessment and inventory*: 22–28.
- Persson Å, Holmgren J, Söderman U (2002) Detecting and Measuring Individual Trees Using an Airborne Laser Scanner. *Photogrammetric Engineering & Remote Sensing*, 68 (9): 925–932.
- Persson Å, Söderman U, Töpel J, Ahlberg S (2005) Visualization and analysis of full-waveform airborne laser scanner data. In: Vosselman G, Brenner C (eds) *ISPRS Workshop Laser Scanning 2005*. IAPRS 36 (Part 3/W19): 103–108.
- Polley H (2001) *Aufnahmeanweisung für die Bundeswaldinventur II (2001-2002)*. Bonn: Bundesministerium für Verbraucherschutz, Ernährung und Landwirtschaft.
- Pyysalo U, Hyyppä H (2002) Reconstructing Tree Crowns from Laser Scanner Data for Feature Extraction. In: *Symposium of ISPRS Commission III: Photogrammetric Computer Vision PCV02*. IAPRS 34 (Part 3B): 218–221.
- Rall H, Martin K (2002) *Luftbilddauswertung zur Waldentwicklung im Nationalpark Bayerischer Wald 2001*. Berichte aus dem Nationalpark. Nationalparkverwaltung Bayerischer Wald.
- Reitberger J, Heurich M, Krzystek P, Stilla U (2007a) Single tree detection in forest areas with high-density Lidar data. In: Stilla U, Mayer H, Rottensteiner F, Heipke C, Hinz S (eds) *Symposium of ISPRS Photogrammetric Image Analysis PIA07*. IAPRS 36 (Part 3/W49B): 139–144.
- Reitberger J, Krzystek P, Heurich M (2006a) Full-Waveform Analysis of Small Footprint Airborne Laser Scanning Data in the Bavarian Forest National Park for Tree Species Classification. In: Koukal T, Schneider W (eds) *3D Remote Sensing in Forestry*: 229–238.

- Reitberger J, Krzystek P, Stilla U (2006b) Analysis of Full Waveform Lidar Data for Tree Species Classification. In: Förstner W, Steffen R (eds) *Symposium of ISPRS Commission III: Photogrammetric Computer Vision PCV06*. IAPRS 36 (Part 3): 228–233.
- Reitberger J, Krzystek P, Stilla U (2007b) Combined tree segmentation and stem detection using full waveform Lidar data. In: Rönnholm P, Hyyppä H, Hyyppä J (eds) *ISPRS Workshop Laser Scanning 2007 and SilviLaser 2007*. IAPRS 36 (Part 3/W52): 332–337.
- Reitberger J, Krzystek P, Stilla U (2008a) 3D segmentation and classification of single trees with full waveform Lidar data. In: Hill R, Suárez J, Rosette J (eds) *SilviLaser 2008, 8th international conference on LiDAR applications in forest assessment and inventory*: 216–226.
- Reitberger J, Krzystek P, Stilla U (2008b) Analysis of full waveform Lidar data for the classification of deciduous and coniferous trees. *International Journal of Remote Sensing*, 29 (5): 1407–1431.
- Reitberger J, Krzystek P, Stilla U (2009a) Benefit of airborne full waveform LIDAR for 3D segmentation and classification of single trees. In: *ASPRS 2009 Annual Conference*: (on CD-ROM).
- Reitberger J, Krzystek P, Stilla U (2009b) First/Last Pulse und Full Waveform Laserscanning zur 3D Kartierung von Wäldern. In: *29. Wissenschaftlich-Technische Jahrestagung der DGPF*. Tagungsband 18.
- Reitberger J, Schnörr C, Heurich M, Krzystek P, Stilla U (2008c) Towards 3D mapping of forests: A comparative study with first/last pulse and full waveform Lidar data. In: *XXI ISPRS Congress*. IAPRS 37 (Part B8): 1397–1403.
- Reitberger J, Schnörr C, Krzystek P, Stilla U (2008d) 3D segmentation of full waveform Lidar data for single tree detection using normalized cut. In: *XXI ISPRS Congress*. IAPRS 37 (Part B3a): 77–83.
- Reitberger J, Schnörr C, Krzystek P, Stilla U (2009c) 3D segmentation of single trees exploiting full waveform LIDAR data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 64 (6): 561–574.
- Roth RB, Thompson J (2008) Practical application of multiple-pulse in the air (MPiA) lidar in large area surveys. In: *XXI ISPRS Congress*. IAPRS 37 (Part B1): 183–188.
- Rousseeuw PJ, Leroy AM (1987) *Robust Regression and Outlier Detection*. New York: Wiley-Interscience.
- Schumann K (2005) *Die Wald-Ereignisanalyse. Eine hilfreiche Methode für das effiziente Management im Forstbetrieb*. Georg-August-Universität Göttingen, Forstwissenschaftlicher Fachbereich, Dissertation.
- Söderman U, Persson Å, Töpel J, Ahlberg S (2005) On Analysis and Visualization of Full-Waveform Airborne Laser Scanner Data. *SPIE Laser Radar Technology and Applications X*, 5791: 184–192.
- Shi J, Malik J (2000) Normalized cuts and image segmentation. *IEEE Transactions of Pattern Analysis and Machine Intelligence*, 22 (8): 888–905.
- Solberg S, Naesset E, Bollandas OM (2006) Single Tree Segmentation Using Airborne Laser Scanner Data in a Structurally Heterogeneous Spruce Forest. *Photogrammetric Engineering & Remote Sensing*, 72 (12): 1369–1378.
- Stilla U, Jutzi B (2008) Waveform analysis for small-footprint pulsed laser systems. In: Shan J, Toth CK (eds) *Topographic Laser Ranging and Scanning: Principles and Processing*. Boca Raton, FL: Taylor & Francis: 215–234.
- Stilla U, Yao W, Jutzi B (2007) Detection of weak laser pulses by full waveform stacking. In: Stilla U, Mayer H, Rottensteiner F, Heipke C, Hinz S (eds) *Symposium of ISPRS Photogrammetric Image Analysis PIA07*. IAPRS 36 (Part 3/W49A): 25–30.

- Sun GQ, Ranson KJ (2000) Modeling Lidar Returns from Forest Canopies. *IEEE Transactions on Geoscience and Remote Sensing*, 38 (6): 2617–2626.
- United Nations (2005) *European Forest Sector Outlook Study 1960-2000-2020: Main Report*. Geneva Timber and Forest Study Paper 20. Geneva: United Nations, Economic Commission for Europe.
- van der Heijden F, Duin RPW, de Ridder D, Tax DMJ (2004) *Classification, parameter estimation and state estimation: An engineering approach using MATLAB*. The Atrium, Southern Gate, Chichester, West Sussex PO19 8SQ, England: John Wiley and Sons.
- Vincent L, Soille P (1991) Watersheds in Digital Spaces: An Efficient Algorithm Based on Immersion Simulations. *IEEE Transactions of Pattern Analysis and Machine Intelligence*, 13 (6): 583–598.
- Wagner W, Hyypä J, Ullrich A, Lehner H, Briese C, Kaasalainen S (2008) Radiometric calibration of full-waveform small-footprint airborne laser scanners. In: *XXI ISPRS Congress*. IAPRS 37 (Part B1): 163–168.
- Wagner W, Ullrich A, Ducic V, Melzer T, Studnicka N (2006) Gaussian decomposition and calibration of a novel small-footprint full-waveform digitising airborne laser scanner. *ISPRS Journal of Photogrammetry and Remote Sensing*, 60 (2): 100–112.
- Wagner W, Ullrich A, Melzer T, Briese C, Kraus K (2004) From Single-pulse to Full-waveform Airborne Laser Scanners: Potential and Practical Challenges. In: Altan O (ed) *XX ISPRS Congress*. IAPRS 35 (Part B3): 201–206.
- Wang Y, Weinacker H, Koch B, Stereńczak K (2008) LIDAR Point Cloud Based Fully Automatic 3D Single Tree Modelling In Forest and Evaluations of the Procedure. In: *XXI ISPRS Congress*. IAPRS 37 (Part B6b): 45–51.
- Wu Z, Leahy R (1993) An Optimal Graph Theoretic Approach to Data Clustering: Theory and Its Application to Image Segmentation. *IEEE Transactions of Pattern Analysis and Machine Intelligence*, 15 (11): 1101–1113.
- Wulder M, Niemann KO, Goodenough DG (2000) Local Maximum Filtering for the Extraction of Tree Locations and Basal Area from High Spatial Resolution Imagery. *Remote Sensing of Environment*, 73 (1): 103–114.
- Zhao K, Popescu S (2007) Hierarchical Watershed Segmentation of Canopy Height Model for Multi-Scale Forest Inventory. In: Rönnholm P, Hyypä H, Hyypä J (eds) *ISPRS Workshop Laser Scanning 2007 and SilviLaser 2007*. IAPRS 36 (Part 3/W52): 436–441.

Lebenslauf

Name Josef Reitberger
Geburtstag und -ort 07.12.1977 in Regen
Familienstand verheiratet
Wohnort Klessinger Str. 1
94269 Rinchnach



Ausbildung/Tätigkeit

1984 – 1988 Grundschule in Rinchnach
1988 – 1997 Gymnasium in Zwiesel
Abschluss: Allgemeine Hochschulreife
1997 – 1998 Wehrdienst an der Graf-Aswin-Kaserne in Bogen
1998 – 2003 Studium des Vermessungswesens an der Technischen Universität München
Abschluss: Diplom
2000 – 2002 Wissenschaftliche Hilfskraft an der Technischen Universität München (Forschungseinrichtung Satellitengeodäsie, Lehrstuhl für Photogrammetrie und Fernerkundung, Geodätisches Institut)
2003 – 2005 Mitarbeiter bei der Bezirksfinanzdirektion München - Vermessungsabteilung (Ref. 46, Sachgebiet Geodatenserver)
seit 2005 Wissenschaftlicher Mitarbeiter an der Hochschule München
seit 2008 Lehrbeauftragter im Fach „Objektorientierte Programmierung mit Java - Vertiefung“ an der Hochschule München

