

Gemeinsamer Schlussbericht

zur Fördermaßnahme

Digital GreenTech – Umwelttechnik trifft Digitalisierung

Thema: Einzelbaumbasiertes, satellitengestütztes Waldökosystemmonitoring mittels autoadaptiver Hyperdimensions-Geodatenanalyse


Akronym: FOREST^{CARE}

Teilprojekt: 02WDG014A-E

durchgeführt von Projektkoordinator und -partner:

AWI – Abteilung für Arbeitswissenschaft und Verfahrenstechnologie, Georg-August-Universität Göttingen

Projektlaufzeit: 01.04.2021 – 30.09.2023



Autoren: Tarek Neubert, Dr. Sebastian Paczkowski, Prof. Dirk Jaeger, Büsgenweg 4, 37077 Göttingen,
tarek.neubert@uni-goettingen.de, dirk.jaeger@uni-goettingen.de
mit Beiträgen von: Pawanjeet Datta, Patrick Bieniek, Xiang Liu, Swati Negi (Felis, Freiburg);
Dorothea Sommer, Hauke Kirchner, Julian Kunkel (Gesellschaft für wissenschaftliche Datenverarbeitung Göttingen,
(GWDG) Göttingen); Anja Kipfer (GisCon, Dortmund); Irina Fabry (ConTerra, Münster)

Projektpartner

Prof. Dr. Barbara Koch, Albert-Ludwigs-Universität Freiburg, Professur für Fernerkundung und Landschaftsinformationssysteme (**FeLIS**), Universität

GISCON Systems GmbH, Spezialist für Forst- und Geoinformationssysteme (**GISCON**), Unternehmen (KMU)

Con terra GmbH, Spezialist für Geoinformationssysteme, insb. KI, (**CONTERRA**) Unternehmen (KMU)

Gesellschaft für wissenschaftliche Datenverarbeitung mbH Göttingen, Rechen- und IT-Kompetenzzentrum (**GWDG**), Gemeinnützige Forschungseinrichtung

Dieses Forschungs- und Entwicklungsprojekt wurde durch das Bundesministerium für Bildung und Forschung (BMBF) gefördert und vom Projektträger Karlsruhe (PTKA) betreut. Die Verantwortung für den Inhalt dieser Veröffentlichung liegt bei den Autorinnen und Autoren.

GEFÖRDERT VOM



Bundesministerium
für Bildung
und Forschung

Inhaltsverzeichnis

I.	Teil I Kurzfassung	1
I.1	Aufgabenstellung	1
I.2	Wissenschaftlicher und technischer Stand zu Beginn des Vorhabens.....	2
I.3	Wesentliche Ergebnisse im Überblick	2
II.	Teil 2 Eingehende Darstellung.....	3
	Motivation und Aufgabenstellung.....	3
II.1	Wissenschaftlicher und technischer Stand zu Beginn des Vorhabens	3
II.2	Planung und Ablauf des Vorhabens.....	4
II.3	Erzielte Ergebnisse.....	5
II.3.1	Ergebnisse Partner AWI.....	5
II.3.1.1	Projektmanagement (AI1)	5
II.3.1.2	Internes Projektmanagement (AI2).....	6
II.3.1.3	Bestandesaufnahmen zur Labelgenerierung (AI3)	8
II.3.1.4	Electronic Nose (AI4).....	16
II.3.1.5	Validierung Einzelbaumzustandsprognosen (AI5)	20
II.3.1.6	Fazit	20
II.3.2	Ergebnisse Partner Felis.....	21
II.3.2.1	Planung und Ablauf des Vorhabens (FE1)	21
II.3.2.2	Bestandsaufnahmen (FE2).....	24
II.3.2.3	Segmentierung (FE3).....	33
II.3.2.4	Fernerkundungsbasierte Analyse (FE4)	36
II.3.3	Ergebnisse Partner GWDG	43
II.3.3.1	Internes Projektmanagement (GW1)	43
II.3.3.2	Algorithmus Electronic Nose Auswertung (GW2).....	44
II.3.3.3	HPC Serversupport (GW3).....	44
II.3.3.4	Entwicklung Artificial/deep convolutional NN (GW4).....	45
II.3.4	Ergebnisse Partner GISCON.....	47
II.3.4.1	Parametrische Analyse (GC2)	47
II.3.4.2	Entwicklung Artificial NN Baumvitalität (GC3).....	52
II.3.5	Ergebnisse Partner con-terra	55
III.	Zusammenarbeit mit anderen Stellen außerhalb des Verbundprojektes.....	59
IV.	Veröffentlichungen, Vorträge Referate, etc.	61

Abbildungen

Abbildung 1: Ausschnitte der in FORESTCARE aufgenommenen Flächen mit den entsprechenden handerstellten Baumpolygonen.	11
Abbildung 2: Frequenzüberlagerung des im Projekt FORESTCARE verwendeten Micasense Kamerasystems mit den Satellitensystemen Sentinel 2A und Landsat 8	12
Abbildung 3: links ein Beispiel für die Befallsintensitätsklassifizierung eines Borkenkäferbefalls im Revier Clausthal-Zellerfeld im Harz und rechts die Statistik der baumspezifischen Pixel in Bezug zu den Schadklassen.	14
Abbildung 4: zeigt den Workflow zur KI basierten Klassifizierung eines subsets der Bestandes- und Drohnendaten in Bezug auf Baumartendifferenzierung und allgemeine Baumvitalität.....	15
Abbildung 5: Reaktion des Triplesensors (drei Wirkschichten) auf Isopren und Hexanal bei der optimalen Oberflächentemperatur 420 °C.....	17
Abbildung 6: zeigt die Glättung des Sensorsignals für die nachfolgende Peakdetektion.....	18
Abbildung 7: zeigt die Identifikation von lokalen Minima und Maxima zur Peakdetektion	18
Abbildung 8: zeigt die abstrahierten Sensorpeaks (obere blaue Striche) und macht damit die Georeferenzierung der Sensorergebnisse und den Vergleich zu den Bodendaten (Baumvitalität) möglich	19
Abbildung 9: zeigt ein Ergebniss der Electronic Nose im Harz. Die Fläche war stark mit Borkenkäfer befallen (Infested Trees)	19
Abbildung 10: Übersicht über die Versuchsflächen.....	24
Abbildung 11: Verteilung der gemessenen Bäume: nach Baumart (oben) und nach Kronen- und Stammvitalität (unten).....	25
Abbildung 12: Flugplanung in UgCS: Die Flugroute wird in Grün dargestellt, die Flugfläche auf dem Boden in Gelb. Eine Satellitenkarte ist in 2.5D vorhanden und es können Links die Parameter eingestellt werden	26
Abbildung 13: Seitenansicht Beispielbaum P1 3D Punktwolke mit rot hervorgehobenen Ausreizern	34
Abbildung 14: DOM mit drei Baumpositionen.....	34
Abbildung 15: Umrissbestimmung mittels Watershed.....	34
Abbildung 16: L1 Datensatz: Daten in RGB Farben. Punkte: Erkannte Baumspitzen eingefärbt nach relativer Höhe; Kreise: Nicht erkannter Baum.....	35
Abbildung 17: Rechts: Baum mit Umriss in Pink, verkleinerter Umriss in Blau; Links: Hervorgehoben eine Detailansicht.....	35
Abbildung 18: Konfusionsmatrizen für das RF-Modell (UAVdaten) in vier Klassifizierungsszenarien mit unterschiedlichen Klassen	39
Abbildung 19: Konfusionsmatrizen für das RF-Modell (Satellitendaten) in vier Klassifizierungsszenarien mit unterschiedlichen Klassen	41

Tabellen

Tabelle 1: Farbatlas Waldschäden (Butin H, Hartmann G, Farbatlas Waldschäden: Diagnose von Baumkrankheiten, 4. Auflage 2017, Ulmer Eugen Verlag)	9
Tabelle 2: Größe der Versuchsflächen	24
Tabelle 3: Anzahl der segmentierten Bäume für jedes Teilgebiet, aufgeteilt in Laub- und Nadelbäume	37

I. Teil I Kurzfassung

Das Projekt FOREST^{CARE} wurde initiiert, um die wachsenden Waldschäden in Deutschland, die wahrscheinlich durch den Klimawandel verursacht werden, zu erfassen und weiterer Schadensausweitung zu reduzieren. Ziel des Projekts war es, Möglichkeiten eines intensiveren Monitorings von Waldbeständen zu erforschen, insbesondere durch die Erfassung einzelbaumbasierter Informationen mittels hochauflösender Fernerkundungsdaten wie LiDAR und optischen Kameras. Diese Daten wurden mithilfe künstlicher Intelligenz (KI) analysiert, um Waldbesitzern Instrumente zur Bewältigung der Klimawandelfolgen, wie trockenheitsbedingten Schäden, zur Verfügung zu stellen.

Das Projekt umfasste die Entwicklung neuer Analysealgorithmen, die Bereitstellung von HPC-Server-Support und die Implementierung neuronaler Netzwerke. Durch die Zusammenarbeit mit verschiedenen Forschungseinrichtungen und die Integration des Projekts in die Lehre wurden wertvolle Erfahrungen und Erkenntnisse gewonnen. Besonders erfolgreich war die Forschung und Implementierung von Methoden zur Einzelbaumsegmentierung und Identifizierung von Schadensmerkmalen, was Potenzial für praktische Anwendungen im Forstsektor erwarten lässt.

I.1 Aufgabenstellung

Die Projektzusammenarbeit hatte das Ziel, die Projektpartner bei der Datenerhebung, Datenübertragung und anwendungsorientierten Algorithmusentwicklung zu koordinieren sowie die Kommunikation mit dem Projektträger und die Verbreitung wissenschaftlicher Ergebnisse sicherzustellen. Die Projektleitung überwachte den Fortschritt und kommunizierte diesen durch Zwischen- und Abschlussberichte. Der Schwerpunkt lag auf der Integration von Waldbestandesdaten, Geruchssensordaten, Multispektral- und LiDAR-Drohnendaten sowie optischen und Radar-Satellitendaten.

Die umfangreichen Bestandesaufnahmen waren zentral für die Generierung von Labels, auf die die KI-Algorithmen trainiert wurden. Diese Aufnahmen dienten als Grundlage für parametrische Analysen und erfassten eine Vielzahl von Baumarten und Eigenschaften dieser zur Bewertung der Bestandesvitalität und zur Erstellung von Vorhersagen. Ein weiteres Ziel war die Koordination von Luftbildaufnahmen mit Drohnen, um Daten zu sammeln, die zur Analyse der Baumvitalität und des Waldwachstums verwendet werden konnten. Die hochpräzisen Drohnendaten ermöglichten Vorhersagen auf Einzelbaumebene, die durch Bestandesbegehungen validiert wurden. Satellitendaten der Sentinel-2 und Plejades Systeme wurden ebenfalls auf Eignung untersucht.

I.2 Wissenschaftlicher und technischer Stand zu Beginn des Vorhabens

Satellitendaten bieten eine hohe zeitliche Auflösung und können großflächige Sturmschäden sowie Baumartenzusammensetzungen identifizieren. Moderne SAR- Satelliten ermöglichen sogar die Auflösung der Kronengeometrie, was die einzelbaumdiskrete Artbestimmung potenziell ermöglicht.

Drohnenbasierte Sensoren können dank ihrer Nähe zum Kronendach äußerst genaue Messwerte liefern, sind jedoch aufgrund des hohen Aufwands bei der Befliegung nur lokal begrenzt einsetzbar. Diese Sensoren liefern Daten zu verschiedenen Parametern wie Blattzustand, Kronengeometrie, Baumart und typischen quantitativen Parametern wie Baumdurchmessern und Vorräten auf der Fläche.

I.3 Wesentliche Ergebnisse im Überblick

Zu Beginn des Projekts wurden in Zusammenarbeit mit dem Partner FeLIS Bäume in Waldbeständen um Freiburg georeferenziert und über 30 Eigenschaften wie Baumdimensionen und Baumvitalität erfasst. In der zweiten Phase des Projekts wurden Flächen in der Umgebung von Göttingen erfasst. Insgesamt wurden 2.215 Einzelbäume aufgenommen. Die Baumaufnahmen wurden mit einer speziell entwickelten App des Projektpartners con terra unterstützt.

Über 13 Flächen mit einer Gesamtfläche von etwa 10 Hektar wurden mit fünf verschiedenen Sensoren befliegen, was zu hochauflösenden Bilddaten und E-Nose-Daten in einer Menge von etwa 10 Terabyte führte. Die Bilddaten wurden zu Orthophotos verarbeitet, per Hand segmentiert und statistisch analysiert. Die Berechnung der Orthophotos wurde in Zusammenarbeit mit der GWDG optimiert. Eine eigens programmierte Softwareroutine in R wurde verwendet, um E-Nose-Daten auszuwerten und mit den Daten aus der Bestandesbegehung zu vergleichen.

In der Entwicklung von neuronalen Netzwerken wurden verschiedene Architekturen evaluiert und eine Pipeline für das Training erstellt. Baumarten und -zustände wurden klassifiziert, wobei die Klassifizierung von Laub- und Nadelbäumen eine Genauigkeit von 64 Prozent und die Klassifizierung von Gesundheitszuständen eine Genauigkeit von 60 Prozent erreichte, was der hohen Komplexität der Bilddaten geschuldet war. Spätere Analysen mit deepCNN Algorithmen in Zusammenarbeit mit der Hochschule Würzburg konnten deutlich höhere Aufklärungsraten erzielen. Eine Pipeline für die Integration von LiDAR-Daten wurde aufgebaut und ein synthetischer Datenfluss für multimodale Anwendungen vorbereitet.

II. Teil 2 Eingehende Darstellung

Motivation und Aufgabenstellung

FORESTCARE hatte die Motivation, hochauflösende Satellitendaten zeitlich mit Drohnen Daten zu vernetzen, um ein detailliertes automatisiertes Monitoring der Bestandesvitalität auf einzelbaumbezogener Ebene zu ermöglichen. Dies könnte zum neuen weltweiten Standard für das Monitoring des Waldwachstums auf regionaler Ebene werden. Es sollten hochmoderne Sensoren maximaler Auflösung verwendet werden und die Bilddaten mittels High Performance Computing (HPC) hyperdimensional korreliert werden.

Diese Daten sollten dann als Trainingsdaten für tiefe neuronale Netzwerke dienen, um ein selbstlernendes System zu schaffen, das die Vitalität von Einzelbäumen anhand von Drohnen oder sogar Satellitendaten berechnen kann.

Das Projekt hat auch ein großes Potenzial für die Nachhaltigkeit, indem es an den Klimawandel angepasstes Wassermanagement durch vitale Wälder unterstützt. Die Wiederbewaldung von geschädigten Flächen kann langfristig die Bodenwasserbilanz verbessern und die CO₂-Bilanz positiv beeinflussen. Dies hat nicht nur lokale, sondern auch globale Auswirkungen auf die Reduzierung von Treibhausgasemissionen und das Erreichen der Klimaziele.

Darüber hinaus zielt das Projekt darauf ab, eine Plattform zur hochauflösenden Waldanalyse zu schaffen, die weltweit angewendet werden kann. Dies könnte zu einer Umsatzsteigerung der beteiligten Unternehmen führen und zur Förderung von Umwelttechnologien beitragen. Das Projekt unterstützt auch die Nachhaltigkeitsziele der Vereinten Nationen, insbesondere in Bezug auf sauberes Wasser, wirtschaftliches Wachstum, Innovation und Infrastruktur sowie nachhaltige Städte und Gemeinden.

II.1 Wissenschaftlicher und technischer Stand zu Beginn des Vorhabens

Satellitendaten haben den Vorteil der hohen zeitlichen Auflösung aufgrund des annähernd täglichen Überfliegens desselben Waldgebietes. Eine Ermittlung der Waldzustandsänderung über Waldverlust oder Neubewuchs ist bisher nur für Flächen mit über 0,5 Hektar Größe möglich. Satellitenbasierte SAR-Analyse von Waldbeständen kann bei bekanntem Höhenmodell und unter Verwendung aller verfügbaren Bänder Sturmschäden identifizieren. In Einzelfällen konnten auch Baumartenzusammensetzungen bestimmt werden. Moderne SAR-Satelliten lösen die Kronengeometrie auf, was potenziell die einzelbaumdiskrete Artbestimmung ermöglicht.

Drohnenbasierte Sensoren sind durch ihre Nähe zum Kronendach technisch in der Lage, eine sehr genaue Auflösung der Messwerte zu erzeugen. Sie können aber aufgrund des hohen Aufwandes bei der Befliegung nur lokal eingesetzt werden. Die modernsten zum Einsatz kommenden drohnenbasierten Sensoren sind LiDAR und Spektralkameras im UV-VIS-NIR-SWIR-TIR-Bereich. Potentiell können so Daten zu Blattzustand, Kronengeometrie, Baumart und quantitativen sowie qualitativen Inventurparametern (Durchmesser, Vorrat, Stammform) geliefert werden. Auch die chemischen Zustände des Blattes sind messbar.

In der Datenanalyse im Fernerkundungsbereich werden konventionelle parametrische Korrelationsanalysen sowie nicht-parametrische Verfahren aus dem Bereich des maschinellen Lernens verwendet. Nicht-parametrische Verfahren wie Random Forest Algorithmen oder tiefe neuronale Netzwerke bieten den Vorteil, sehr effizient nichtlineare Zusammenhänge abzubilden, erfordern jedoch große Trainingsdatensätze und eine entsprechende Rechenleistung. Dies gilt insbesondere für Convolutional Neural Networks (CNNs), die in den vergangenen Jahren enorme Erfolge im Bereich der Bilddatenverarbeitung verzeichneten.

Aus diesem Grund sowie einer oft mangelnden Verfügbarkeit an ground-truth Daten ist die Anwendung tiefer neuronaler Netzwerke in der Fernerkundung derzeit noch selten, zeigt jedoch ein großes Potenzial für die Waldzustandserfassung.

II.2 Planung und Ablauf des Vorhabens

In der ersten Projektphase wurde eine erste Version der Erfassungssapp für die notwendige in situ Datenerfassung vor Ort implementiert. Dank der bestehenden Software-Komponenten der con terra konnte die App mit sehr geringem Entwicklungsaufwand bereitgestellt werden. In Zusammenarbeit mit den Projektpartnern wurden die zu erfassenden Parameter definiert und das Datenmodell erstellt. Die erfassten Einzelbäume wurden als Punktgeometrien angelegt, die Parameter für den BHD, Stamm- und Kronenparameter enthalten. Die Anbindung einer elektronischen Kluppe per Bluetooth-Verbindung zur Erfassung des BHD wurde eingerichtet, ebenso die Anbindung einer GNSS-Antenne zur präzisen Verortung. Zur Datenhaltung wurde eine virtuelle Maschine aufgesetzt, ein ArcGIS Server eingerichtet und gegen unbefugten Zugriff abgesichert. Eine erste Version der offline verfügbaren, KI-basierten Spracherkennung wurde früh erstellt. Die KI basierte Sprachsteuerung wurde sukzessive verbessert und hinsichtlich des forstlichen Fachvokabulars optimiert.

Ein Upload der erfassten Baumdaten in die verwendete Cloud ermöglicht den Zugriff auf die erhobenen in situ Daten. Eine Zustandserhebung der Einzelbäume inklusive genauer Verortung war frühzeitig möglich. Die verwendete App zur Erfassung der Baumdaten wurde optimiert und die Genauigkeit der GNSS-Antenne im Wald verbessert. Die App erhielt eine Genauigkeitsanzeige und die Möglichkeit, den Standort nachträglich zu editieren. Die KI basierte Sprachsteuerung wurde verbessert und hinsichtlich des Fachvokabulars optimiert. Eine offline-fähige KI-Spracherkennung wurde somit erstmals implementiert. Eine Marktanalyse bestehender ASR-Systeme wurde durchgeführt. Die Aufnahme einer größeren Anzahl von Kontrollpunkten war möglich. Der gewählte Ansatz ist für weitere App-Umsetzungen nachnutzbar. Die Projektergebnisse wurden auf Fachkonferenzen vorgestellt.

II.3 Erzielte Ergebnisse

II.3.1 Ergebnisse Partner AWI

II.3.1.1 Projektmanagement (AI1)

Im Rahmen des Verbundmanagements wurden die Projektpartner koordiniert. Dabei wurde zu Beginn des Projektes insbesondere die Zusammenarbeit der akademischen Partner AWI und FeLIS in Bezug auf die Datenaufnahme im Bestand und die Erstellung der Orthophotos koordiniert. Ziel war

- 1) die gemeinsame Auswahl geeigneter Waldbestände in der Freiburger Umgebung zur repräsentativen Abbildung der Hauptbaumarten mit Schwerpunkt auf Fichte und Buche
- 2) die Erstellung und Verfeinerung von Workflows zur replizierbaren und möglichst objektiven Aufnahme der Einzelbäume im Bestand und
- 3) die Umsetzung der Drohnenbefliegungen in Bezug auf Missionsparameter wie Fluggeschwindigkeit und Abstand zum Kronendach.

Zusammen mit dem akademischen Partner GWDG wurden dann die Bestandesdaten analysiert, um einen ersten Eindruck von Korrelationen zwischen den aufgenommenen Baumparametern zu bekommen.

Insbesondere 2) wurde maßgeblich von dem Firmenpartner con terra unterstützt, der eine App konfigurierte, die über eine dynamische und sprachgesteuerte Aufnahmemaske die insgesamt 42 Kategorien organisiert abfragte, die Hardwareintegration von GPS, Outdoortablet und elektronischer Kluppe leistete und online Support insbesondere in der Anfangsphase des Projektes bereitstellte.

In Kooperation der Partner AWI, FeLIS und GWDG wurden umfangreiche Vorversuche zur Parameteroptimierung der Orthophotoberechnung gemacht, um Artefaktbildung und Verzerrungen zu minimieren. Diese Berechnungen wurden auf die HPC Rechner ausgelagert. Dies hatte mäßigen Erfolg, da zwar ausreichend CPU für die Berechnungen vorhanden waren, die Orthophotoberechnung in vielen Abschnitten der Erstellung aber auch GPU benötigte. Somit konnten parallel und ohne Leistungsverlust die bei FeLIS und AWI vorhandenen Workstations und Server verwendet werden. Die Berechnung der Orthophotos stellte sich im Projekt als der wichtigste Bottleneck heraus, was aber das Projektziel nicht gefährdete.

Im weiteren Verlauf des Projektes wurde der Partner GIS CON und der assoziierte Partner ESRI für die KI basierte Datenanalyse einbezogen. AWI koordinierte die KI Anwendung, insbesondere im Rahmen der co-Betreuung von zwei Masterarbeiten am Lehrstuhl für Geoinformatik und Fernerkundung der Technischen Hochschule Würzburg-Schweinfurt zum Thema KI basierte Erkennung von Baumart und Baumvitalität und zum Thema KI basierte 2D Segmentierung.

Diese Bemühungen führten zum Zeitpunkt der Berichtserstellung zu einer peer-reviewed Publikation und einem Manuskript.

Die Zwischenergebnisse des Projektes FOREST^{CARE} wurden auf insgesamt 27 Projekttreffen und Workshops mit den Partnern, Veranstaltungen wie z.B. der Nacht des Wissens in Göttingen und Statusseminaren kommuniziert.

II.3.1.2 Internes Projektmanagement (AI2)

Das interne Projektmanagement überspannte das gesamte Projekt, insbesondere die personelle Ressourcenplanung und -verwendung zur Durchführung der Bestandesaufnahmen (Bäume und Drohnendaten) und der Entwicklung und Anwendung der Electronic Nose. Darüber hinaus wurden innerhalb der Abteilung Synergien genutzt (depth to water Analyse) und eine Abschlussarbeit vergeben (Vergleich Drohnen und Satellitenbilder).

II.3.1.2.1 Bestandesaufnahmen

Es wurden die personellen Ressourcen zum Test unterschiedlicher GPS Geräte bereitgestellt, die Geräteanbieter befragt und Feldtests zur Gerätebedienung koordiniert. Es wurden weiterhin abteilungsinterne Schulungen zu dem beschafften Gerätesystem durchgeführt, um das erlernte Know-How weiterzugeben.

Es wurde geeignetes Personal zur Durchführung von Feldtests eingestellt, in die Flächenauswahl einbezogen und auf den ausgewählten Flächen eingewiesen. Durch regelmäßige Feedbackgespräche wurden Risiken und Probleme bei den Flächenaufnahmen identifiziert. So mussten z.B. die Flächen im Harz in einem engen Zeitrahmen aufgenommen werden, da die Borkenkäferdynamik und die parallel ablaufenden Harvestereinsätze die Ergebnisse durch schnelle Ausbreitung oder Teilnutzung des Bestandes verfälscht hätten.

Die angesprochenen Kontakte in den Forstrevieren zeigten sich sehr aufgeschlossen gegenüber der Projektidee und unterstützten den Projektverbund durch Bereitstellung von Untersuchungsflächen und vor Ort Einweisungen vorbehaltlos. Auch Waldspaziergänger zeigten sich mit wenigen Ausnahmen interessiert an der Projektthematik und standen technischen Ansätzen zum Waldschutz positiv gegenüber.

II.3.1.2.2 Drohnenbefliegungen

Das für die Drohneneinsätze geschulte Personal wurde an dem für das Projekt FOREST^{CARE} beschafftem Gerät (Matrice 300 RTK, L1, P1, Altum, RedEdge/Blue) intensiv und über einen ausreichend langen Zeitraum von ca. 2 Monaten eingearbeitet, so dass Knowhow in der Benutzung der Drohne sowie der Sensoren aufgebaut werden konnte. So wurden z.B. Tests zur optimalen Fluggeschwindigkeit, zur maximalen Windgeschwindigkeit und zu Flugzeiten und Flächenleistung gemacht. Diese Vorarbeiten resultierten in einem Manuskript zum Wirtschaftlichkeitsvergleich zwischen drohnenbasierter und konventioneller Borkenkäfersuche.


II.3.1.2.3 Orthophotoerstellung

Die Tests zur Erstellung der Orthophotos wurden innerhalb der Abteilung kommuniziert, um Synergien mit anderen Arbeitsbereichen zu identifizieren. Die später im Projekt erlangte Erfahrung mit der Erstellung von Orthophotos konnte zur Lösung ähnlicher Probleme, wie zum Beispiel der Fahrspurmodellierung oder der Erstellung von 3D Modellen aus Einzelphotos, beitragen. Ein wichtiger Teil der Koordination zur Orthophotoerstellung war die Bereitstellung von Rechner- und Speicherkapazitäten. Hier konnte durch Umwidmung in Kommunikation mit dem Projektträger und durch Beschaffung aus Eigenmitteln eine Workstationumgebung aufgebaut werden, die den hohen Ansprüchen an Datenverarbeitung (GPU/CPU) und Datenspeicherung (10TB Rohdaten und verarbeitete Daten) genügte.

II.3.1.2.4 Datenverarbeitung

Es wurde durch AWI eine nicht in dem Ausmaß geplante Datenverarbeitung, die über die im Projektplan vorgesehenen Arbeiten weit hinaus ging und der Entwicklung der Programmierkenntnissen der eingesetzten Mitarbeiter geschuldet war, durchgeführt. Hierzu wurden die im Projekt beschafften Hardwarekomponenten flexibel und parallel zur Orthophotoentwicklung genutzt. Weiterhin kam es durch die Entwicklung von Know-How im Bereich der Geoinformatik zu umfangreichen Synergien innerhalb der Gruppe und mit externen Kollegen und Kolleginnen. Durch gezielte und durch das Projekt FOREST^{CARE} mögliche Weiterbildung im IT Bereich konnten weit über das Projekt hinaus z.B. Netzwerke im Bereich Robotik und Geoinformatik aufgebaut werden.

Verbundstruktur nach Aufgaben im Projekt FOREST^{CARE}:



II.3.1.3 Bestandesaufnahmen zur Labelgenerierung (AI3)

II.3.1.3.1 Auswahl eines geeigneten GPS Systems

In der Anfangsphase des Projektes wurden mehrere RTK-GPS Systeme unter Einsatzbedingungen getestet. Dabei wurden Vertreter von Leica, Trimble und GeoMax eingeladen, um Ihre Systeme vorzuführen und unter Waldbedingungen zu testen. Weitere Geräte wurden geliehen und auf einem Vergleichsparkour auf Genauigkeit getestet. Es zeigte sich, dass mobile Systeme, die teilweise für den Outdooreinsatz beworben wurden, unter dem Kronendach eine nur sehr ungenügende Performance mit geringen Wiederholbarkeiten der physikalisch gleichen Position zeigten. Die Abweichungen lagen bei bis zu 10 m, insbesondere bei Rückkehr zum gleichen Punkt nach einem längeren Rundweg. Hochwertigere Geräte, die für Vermessungsaufgaben entwickelt wurden, zeigten eine deutlich bessere Performance mit Abweichungen von unter einem Meter. Bei allen Geräten war die Genauigkeit an den Aufbau einer Netzverbindung zur Kommunikation des Korrektursignals gebunden.

Die beste Performance für die vorgesehene Georeferenzierung von Bäumen in der Umtriebszeit im geschlossenen Bestand mit geringer Altersstrukturierung und wenig bis keinem Unterwuchs zeigten professionelle Base-Rover RTK Systeme. Für die Durchführung der Projektarbeiten wurde daher so ein System beschafft.

II.3.1.3.2 Definition von Struktur und Vitalitätskriterien für die Baumaufnahme

Bei der Auswahl der Kriterien für die Baumaufnahme wurde sich an gängigen Strukturparametern sowie an häufig auftretenden Vitalitätskriterien orientiert. Für die Strukturparameter wurden dabei Eigenschaften ausgewählt (Tabelle 1), die aus Sicht der Holzverwendung relevant sind und bei den Vitalitätsparametern wurde sich an einem Standardwerk zu Waldschäden orientiert¹.

¹ Butin H, Hartmann G, Farbatlas Waldschäden: Diagnose von Baumkrankheiten, 4. Auflage 2017, Ulmer Eugen Verlag

Tabelle 1 zeigt die ausgewählten Kriterien (links: einfache Auswahl „vorhanden“ oder „nicht vorhanden“, rechts: Kategorien). Zusätzlich wurde mit einer elektronischen Kluppe für jeden Baum der BHD durch Doppelkluppung bestimmt.

Column Name	Not Present	Present	Column Name	Distinct Values
nadelbaumart			nadelbaumart	Fichte, Libanonzeder, Lärche, Weißtanne
stamm_vital_kat			stamm_vital_kat	abgestorben, gesund, leichter Schaden, mittlerer Schaden, schwerer Schaden
stamm_kaeferbefall			stamm_kaeferbefall	leicht, mittel, nicht vorhanden, stark
stamm_form			stamm_form	Schiefwuchs (leicht), Schiefwuchs (mittel), Schiefwuchs (stark), gradschäftig, nicht vorhanden
krone_vital_kat			krone_vital_kat	abgestorben, gesund, leichter Schaden, mittlerer Schaden, schwerer Schaden
krone_verfichtung			krone_verfichtung	abgestorben, keine, leicht, mittel, stark
krone_trockenaeste			krone_trockenaeste	einer, keine, mehrere
stamm_lausbefall			stamm_lausbefall	leicht, mittel, nicht vorhanden
stamm_nekrose			stamm_nekrose	leicht, mittel, nicht vorhanden, stark
stamm_risse			stamm_risse	Mittel, leicht, mittel, nicht vorhanden, stark
stamm_rueckeschaeden			stamm_rueckeschaeden	leicht, mittel, nicht vorhanden, stark
stamm_sonnenbrand			stamm_sonnenbrand	leicht, mittel, nicht vorhanden
stamm_nadel_harzfluss			stamm_nadel_harzfluss	leicht, mittel, nicht vorhanden, stark
krone_astbruch			krone_astbruch	leicht, mittel, nicht vorhanden, stark
krone_hexenbesen			krone_hexenbesen	leicht, nicht vorhanden
krone_kaefer_gelb			krone_kaefer_gelb	leicht, nicht vorhanden, stark
krone_mistel			krone_mistel	leicht, nicht vorhanden
krone_nadel_verfaerbung			krone_nadel_verfaerbung	leicht, mittel, nicht vorhanden, stark
krone_nadel_frass			krone_nadel_frass	nicht vorhanden
laubbaumart			laubbaumart	Bergahorn, Birke, Buche, Eberesche, Eiche, Esche, Kirsche, Linde, Robinie
stamm_laub_schleimfluss			stamm_laub_schleimfluss	leicht, nicht vorhanden
krone_laub_verfaerbung			krone_laub_verfaerbung	leicht, nicht vorhanden
krone_laub_frass			krone_laub_frass	leicht, mittel, nicht vorhanden
krone_laub_welke			krone_laub_welke	leicht, nicht vorhanden
krone_laub_lausbefall			krone_laub_lausbefall	mittel, nicht vorhanden
krone_laub_mehltau			krone_laub_mehltau	leicht, nicht vorhanden

Tabelle 1: Farbatlas Waldschäden (Butin H, Hartmann G, Farbatlas Waldschäden: Diagnose von Baumkrankheiten, 4. Auflage 2017, Ulmer Eugen Verlag)

II.3.1.3.3 Auswahl geeigneter Bestände

Es wurden insgesamt 3 Flächen von AWI in Kooperation mit FeLLIS (Freiburger Flächen) und 10 in Eigenarbeit (Göttinger Flächen) aufgenommen. Die Auswahl der Flächen erfolgte im Wesentlichen nach dem Vorhandensein der Hauptbaumarten Fichte und Buche sowie den Mischbaumarten Tanne und Eiche. Weiterhin spielten die Begehrbarkeit der Fläche (z.B. teils starke Hangneigungen in der Freiburger Umgebung), die Intensität des Unterbewuchses und das Bestandesalter (ideal waren Flächen mit gleichaltrigen Bäumen in der Umtriebszeit) eine wichtige Rolle bei der Auswahl. Teilweise wurden die Versuchsflächen direkt vom Forstpersonal zugewiesen. Es wurden ebenfalls Flächen des DFG Graduiertenkollegs ConFoBi sowie Versuchsflächen der FVA Freiburg mit in die Auswahl einbezogen.

Die Bestände in Freiburg waren dominiert durch Fichte und Tanne und zeigten insgesamt eine gute Vitalität. Es wurden vereinzelt Borkenkäfernester gefunden, was in dieser geringen Häufigkeit ein Zeichen für die Latenzphase des Käfers ist. Trockenstress konnte kaum festgestellt werden und nur vereinzelte Fichten oder Fichtengruppen waren schwer beschädigt und damit im „red stage“ oder „grey stage“.

Die Bestände in der nahen Göttinger Umgebung waren Mischlaubwälder mit hauptsächlich Buche und Eiche sowie vereinzelt Gruppen von Lärchen.

Es wurden in Absprache mit dem Forstpersonal Bestände ausgewählt, die in den Vorjahren bereits unter Trockenstress gelitten hatten. Insgesamt machten die untersuchten Laubbestände allerdings einen vitalen Eindruck, abgesehen von vereinzelter Entlaubung in lokalen Kronenbereichen.

Die Bestände im Harz waren schwer von Trockenheit und Borkenkäferbefall betroffen. Es wurden in Absprache mit dem Forstpersonal frisch befallene Flächen ausgesucht, die oft kurz vor einem Sanitärhieb standen. Durch die eigenen Aufnahmen wurde das Forstpersonal bei der Auswahl der Käferbäume unterstützt, allerdings mussten die Feldversuche je Fläche in wenigen Tagen abgeschlossen werden, da sich zum einen der Borkenkäferbefall schnell ausbreitete und zum anderen durch die Sanitärhiebe der Bestand stark beeinflusst wurde. Bestände, die im Spätsommer/Herbst aufgenommen wurden zeigten sehr starke Entnadelung durch Trockniss.

II.3.1.3.4 Baumaufnahme

Als Vorbereitung für die Baumaufnahmen wurden die ausgewählten Bestände mit einer kleineren Kameradrohne (Mavic Zoom 2 Professional) befliegen. Das daraus erstellte Orthophoto wurde in die Baumaufnahmeapp von con terra eingelesen, transformiert und als Hintergrundkarte für die Begehung verwendet. Kurz vor dem Einsatz wurde die RTK Base an einem Ort mit gutem Satelliten- und Netzempfang installiert und der RTK Rover mit der Base verbunden. Das Roversignal wurde über ein Bluetooth Interface mit dem Tablet verbunden. Durch die so mögliche Live-Darstellung des eigenen Standortes konnte sich das Bodenpersonal auf dem Orthophoto orientieren. Dies war besonders nützlich in Bestandesbereichen mit schlechtem Satellitenempfang. Sobald ein Baum auf dem Orthophoto in der App identifiziert wurde, konnte der eigene Standort dupliziert und eingefroren werden und dem Standort die Eigenschaften des Baumes über eine benutzerfreundliche und sprachsteuerbare Nutzeroberfläche zugewiesen werden. Wenn das RTK-GPS Signal auf Grund von schlechtem Satellitenempfang eine unüblich hohe Ungenauigkeit von über einem halben Meter zeigte, konnte der eingefrorene Punkt manuell verschoben werden, damit er deckungsgleich mit der auf dem Orthophoto ausgewählten Baumkrone war. Diese frühe Korrektur der Datenqualität im Feld war deswegen wichtig, weil im weiteren Verlauf des Analyseworkflows die Fusion zwischen Rasterdaten der Krone, Baumpolygon und Aufnahmepunkt über die Koordinaten dieser drei Features erfolgte. Hätte der Aufnahmepunkt nicht im Kronenbereich gelegen, wäre der Datenfusionsprozess nicht automatisierbar gewesen.

Die aufgenommenen Bestandesdaten wurden regelmäßig auf dem Server von con terra synchronisiert und von dort über eine geschützte ArcGIS Server Connection dem FOREST^{CARE} Team bereitgestellt.

Insgesamt wurden während der Projektlaufzeit 2.215 Einzelbäume aufgenommen. Abbildung 1 zeigt eine Auswahl an aufgenommenen Flächen, die in einer Publikation in Zusammenarbeit mit dem assoziierten Partner ESRI veröffentlicht wurde.




Abbildung 1: Ausschnitte der in FORESTCARE aufgenommenen Flächen mit den entsprechenden hergestellten Baumpolygonen.

II.3.1.3.5 Bestandesbefliegungen zur drohnenbasierten Datengenerierung

Zu Beginn des Projektes wurde eine Drohne des Typs DJI Matrice 300 RTK beschafft. Grund für die Auswahl dieser Drohne war der hohe Stand der technischen Entwicklung, die Integrierbarkeit eines RTK Systems mit der Möglichkeit bei der Aufnahme der Sensordaten auf Referenzpunkte am Boden zu verzichten und die Verfügbarkeit unterschiedlicher im Projekt benötigten Sensoren. Weiterhin lag die Flugzeit mit 40 Minuten bei geringer Payload in einem für ein rein batteriebetriebenes System hohen Bereich.

Die Spiegelreflexkamera P1 ist nahtlos in die Drohnenplattform integrierbar und bietet viele Optionen für die Flugplanung, so z.B. die direkte Berechnung der GSD und die Darstellung der Flugtrajektorien bei gleichzeitiger Berechnung der Flugzeit bei festgelegter Fluggeschwindigkeit. Dies galt auch für den LiDAR Sensor L1, auch wenn sich die Datenaufnahme hier schwieriger gestaltete da manuelle Bedienung notwendig war. Die Multispektralkameras Micasense Altum und Micasense RedEdge/Blue erlaubten die Darstellung von im Vergleich zu Spiegelreflexkameras engen Frequenzbändern, was die Berechnung von Vegetationsindices möglich machte. Abbildung 2 zeigt die Frequenzen mit den entsprechenden Frequenzbreiten.

Die Frequenzen des RedEdge/Blue Systems überlagern sich mit den vom Sentinel-2 und Landsat System aufgenommenen Bändern, was im Rahmen des Projektes sinnvoll erschien, da auch die Performance von Satelliten für die Waldvitalitätserkennung untersucht werden sollte. Die Altum Kamera verfügt neben den gleichen Bändern der RedEdge in höherer Auflösung zusätzlich über einen Thermalkanal.




Abbildung 2: Frequenzüberlagerung des im Projekt FORESTCARE verwendeten Micasense Kamerasystems mit den Satellitensystemen Sentinel 2A und Landsat 8

Zunächst wurde das Gesamtsystem auf einer Fläche nahe Freiburg getestet. Es wurden Untersuchungen zur Fluggeschwindigkeit und zur Aufnahme Frequenz gemacht. Auf der Basis dieser Untersuchungen wurde für die P1 und die Multispektralkameras eine Fluggeschwindigkeit von 1 m/s als Optimum festgelegt. Die frontale Überlappung wurde mit 90 % maximiert und die seitliche Überlappung auf 80 % gestellt. Bei den zwischen 0,5 und 1 ha großen Flächen hätte eine höhere seitliche Überlappung zu einer starken Erhöhung der Flugzeit geführt, da die parallelen Flugtrajektorien dadurch enger zusammengerückt wären, was zu einem exponentiellen Anstieg der Flugzeit führt. Zudem ergaben Vorversuche zur Orthophotoberechnung, dass eine höhere seitliche Überlappung die Datenmengen und die Rechenzeit erhöht aber nicht die Qualität verbessert. Nach Optimierung der Flugmissionsparameter wurden über insgesamt 13 Flächen mit einer Gesamtfläche von ca. 10 ha mit ca. 400 Flügen Daten in einer Menge von ca. 10 TB generiert. Wichtig war hier die Absprache mit dem Personal für die Bestandesbegehungen, um eine optimale Überschneidung der aufgenommenen Bäume und der Luftbilder zu erreichen.

II.3.1.3.6 Orthophotoerstellung

Die Bilddaten wurden mit Hilfe der Software Agisoft Metashape zu Orthophotos verarbeitet. Eine in Zusammenarbeit mit dem Projektpartner GWDG durchgeführte Parameteroptimierung führte zu Parametern für alle Prozessierungsschritte (Alignment, Dense Cloud, Surface Model, Orthophoto), die über das ganze Projekt hinweg konstant angewandt wurden. Es zeigte sich vor allem bei den Rohdaten der P1, dass die Erstellung eines Orthophotos für 1 ha selbst mit den zur Verfügung stehenden Hochleistungsrechnern eine tagelange Rechenoperation darstellt. In manchen Fällen kam es auf Grund der hohen Auslastung des Arbeitsspeichers oder der Speichermedien zum Abbruch der Rechenoperation. Dies konnte zwar durch Aufteilen der Fläche und späterem Zusammenfügen der Einzelflächen kompensiert werden, die Berechnung der Orthophotos war aber der rechenintensivste Schritt im Projekt und damit ein Bottleneck.

II.3.1.3.7 Segmentierung

Nach Erstellung der Orthophotos mussten die Bäume segmentiert werden. AWI stellte dazu umfangreiche Recherchen an. Eine für die vorgesehenen Aufgaben funktionale Segmentierung von Baumkronen gab es zum Zeitpunkt der Projektdurchführung nicht. Annähernd gute Ergebnisse lieferte die Segmentierung auf der Basis von Dense Clouds, allerdings kam es hier zu Fehlidentifikationen oder nicht erkennen von Bäumen, insbesondere in Laubbaumbeständen oder dichten Nadelbaumbeständen. Durch Parametervariation des Segmentierungsalgorithmus konnte dies nicht verbessert werden. Somit mussten die aufgenommenen Bäume per Hand mit der Software ArcGIS Pro über die Erstellung von Polygonen segmentiert werden. Nach Erstellung der Polygone wurde der Workflow an die FeLIS übergeben, die die Extraktion der Rasterdaten über den ModelBuilder in ArcGIS Pro automatisierte und diese Routine der AWI zur Verfügung stellte.

Aus den Erfahrungen mit Segmentierung wurde eine Masterarbeit ausgekoppelt, die sich mit der zweidimensionalen Segmentierung über deepCNN Algorithmen beschäftigte². Im Ergebnis konnte im Rahmen einer Automatisierung mit Faster R-CNN eine fast 85 % korrekte Segmentierung im Vergleich zur Segmentierung per Hand erzielt werden. Damit kann der erzeugte Algorithmus, der im Rahmen der Masterarbeit als open source Add-On in die Software ArcGIS Pro integriert wurde, die Handsegmentierung maßgeblich unterstützen. Die zweidimensionale Segmentierung kann perspektivisch die Datenextraktion aus den Rohdaten ermöglichen und damit die aufwendige Orthophotoerstellung vollständig ersetzen, was den BottleNeck der hochaufgelösten einzelbaumbasierten Bilddatenanalyse vollständig auflösen würde.

² Speckenwirth S; Instance segmentation at single tree level using multispectral UAV images, Masterthesis supervised by Prof. Dr. Melanie Brandmeier, Dr. Sebastian Paczkowski, at the technical university Würzburg-Schweinfurt, Attendorn, February 19, 2024

II.3.1.3.8 Konventionelle Statistik

In Folge untersuchte die AWI die extrahierten Pixel der aufgenommenen Bäume mit Hilfe von konventioneller Statistik in Hinblick auf Korrelationen mit den im Bestand aufgenommenen Daten. Dabei wurde sich auf Borkenkäferbefall und Entnadelung konzentriert, da diese Schadbilder in den Bestandesaufnahmen am häufigsten vorkamen.

Man erkennt deutliche Tendenzen des für Chlorophyllaktivität sensitiven Vegetationsindexes Mcari/Osavi (Abbildung 3). Allerdings gibt es auch sehr starke Überlappungsbereiche zwischen den Schadklassen, was eine praktikable Detektionsrate unmöglich macht.




Abbildung 3: links ein Beispiel für die Befallsintensitätsklassifizierung eines Borkenkäferbefalls im Revier Clausthal-Zellerfeld im Harz und rechts die Statistik der baumspezifischen Pixel in Bezug zu den Schadklassen.

II.3.1.3.9 KI-basierte Datenauswertung

In Zusammenarbeit mit der Technischen Hochschule Würzburg-Schweinfurt, Lehrstuhl für Geoinformatik und Fernerkundung, wurden deepCNN Analysen zu Baumart und Vitalität durchgeführt³. Abbildung 4 zeigt den verwendeten Workflow für die KI basierte Analyse. Es wurden konventionelle und CNN Algorithmen verglichen.




Abbildung 4: zeigt den Workflow zur KI basierten Klassifizierung eines subsets der Bestandes- und Drohnen Daten in Bezug auf Baumartendifferenzierung und allgemeine Baumvitalität

Es wurden insgesamt drei Ansätze verfolgt: 1) binäre Klassifikation von gesunden und kranken Bäumen ohne Betrachtung der Schadensintensität; 2) Klassifizierung von Baumart und von gesunden oder kranken Bäumen ohne Betrachtung der Schadensintensität; 3) Klassifizierung der Schadensintensität (gesund, leicht, mittel/schwer). Es wurden für alle drei Ansätze ebenfalls die Datensätze optimiert, indem sowohl die Rohdaten (RGBI) als auch Vegetationsindices (NDVI, NDVIre) verwendet wurden.

Für den Ansatz in 1) wurden mit allen Algorithmen gute Ergebnisse erzielt. ResNet50 zeigte mit einer Detektionsrate von 99 % auf dem RGBI Datensatz das beste Ergebnis. Für 2) zeigten sowohl ResNet50 als auch ResNet101 sehr gute Detektionsraten mit jeweils 99 %. Im Falle von ResNet50 wurden die Ergebnisse mit dem NDVI Datensatz erzielt und die anderen Datensätze erzielten deutlich geringer Detektionsraten. Bei ResNet101 wurde das Beste Ergebnis zwar mit dem NDVIre Datensatz erzeugt, RGBI und NDVI Datensätze führten aber ebenfalls zu hohen Detektionsraten von jeweils 93 % und 97 %. Für 3) erzielten ResNet50 und ResNet101 eine über alle Datensätze gute Detektionsrate von mindestens 93 %. Die höchste Detektionsrate mit 97 % hatten sowohl ResNet50 auf dem RGBI Datensatz als auch ResNet101 auf dem NDVIre Datensatz.

³Anwander J, Brandmeier M, Paczkowski S, Neubert T, Paczkowska M; Evaluating different deep learning approaches for tree health classification using high-resolution multispectral UAV data in the black forest, Harz region, and Göttingen forest, Remote Sensing, 16, 1-21 (2024)

Damit zeigte sich, dass ResNet50 auf RGBI insgesamt die Beste Performance hatte, allerdings andere Algorithmen und Datensätze ebenfalls gute Detektionsraten erzielen konnten. Insbesondere die kombinierte Klassifikation von Baumart und Vitalität in 2) wurde von ResNet101 besser gelöst. Der konventionelle KI Algorithmus Random Forest zeigte eine deutlich schlechtere Performance als die CNN Algorithmen.

II.3.1.3.10 Weitere Datenanalysen

Es wurde nach Aufnahme der Baumvitalität in einem Bestand bei St. Peter durch AWI unter Einbeziehung interner Mitarbeiter ein Ansatz versucht, mit Hilfe des depth-to-water-ratio ein Modell zu entwickeln, dass auf Grund der den Wasserabfluss beeinflussenden Bodenstruktur lokale Trockenheit und damit eine Abnahme der Pflanzenvitalität vorhersagt. Dieser Modellansatz war in einer frühen Phase des Projektes nicht erfolgreich, kann aber als Verwertungsansatz nach dem Projekt mit unterstützenden z.B. den teils hochaufgelösten Bodendaten des European Soil Data Center angereichert und durch die später im Projekt in größerer Menge zu Verfügung stehenden Baumdaten erneut aufgegriffen werden.

Es wurde eine Bachelorarbeit betreut, die sich mit der Abstraktion der Drohnenbilddaten auf eine von Satelliten verwendete Auflösung beschäftigte. Ziel war die Untersuchung, ob Satellitenbilder mit einer GSD von 10m (z.B. Sentinel 2) überhaupt das Potential haben Waldschäden, in diesem Fall Entnadelung, zu erkennen. Im Ergebnis stand fest, dass dies nicht der Fall ist. Die berechneten Korrelationen für Drohnenbilder ohne Segmentierung (Vergleich zu Satellitenbildern, bei denen keine Segmentierung von Einzelbäumen möglich ist) lag bei $r_s = 0 - 0,46$ für den NDVI über die Schadklassen nicht, leicht, mittel und stark entnadelte, während die Korrelation bei Satellitenbildern über die gleichen Schadklassen bei $r_s = 0 - 0,28$ lag. Die Verwendung eines anderen Vegetationsindex (MCARI/OSAVI) führte zu keiner Verbesserung der Korrelationen. Damit eignen sich Satellitenbilder und nicht segmentierte hochaufgelöste Drohnenbilder nicht für die Detektion von Entnadelung.

II.3.1.4 Electronic Nose (AI4)

Im Rahmen des Projektes wurde zunächst Hardware beschafft (DJI Manifold), die sich nahtlos in die vorhandene Drohnenhardware integrieren lässt. Durch den Partner Felis wurde eine Softwareintegration der beschafften Electronic Nose über das DJI SDK Interface durchgeführt. Dadurch konnte das RTK Signal der Drohne mit den Sensordaten fusioniert werden, wodurch eine georeferenzierte Darstellung der Electronic Nose Daten möglich wurde. Weiterhin wurde durch AWI die Electronic Nose Hardware auf der Drohne integriert, was die Messung der Emissionen außerhalb der Rotorwinde der Drohne möglich machte.

Die Electronic Nose wurde auf einem Sensorteststand auf VOCs getestet, die potentiell über Laubmischwäldern zu erwarten sind. Ausgewählt wurden Isopren, als Zeiger für die allgemeine tagesabhängige physiologische Aktivität, und Hexanal, als Produkt des LOX Zyklus, welches bei physikalischer Blattbeschädigung freigesetzt wird (z.B. Raupenfraß). Abbildung 5 zeigt die relativen Widerstandsänderungen der drei Wirkschichten des Triple Sensors.

Es wird deutlich, dass man die beiden VOCs voneinander unterscheiden kann, da jeweils unterschiedliche Intensitätsmuster über die drei Wirkschichten zu erkennen sind.




Abbildung 5: Reaktion des Triplesensors (drei Wirkschichten) auf Isopren und Hexanal bei der optimalen Oberflächentemperatur 420 °C.

Die drohnenbasierte Electronic Nose wurde über einem Laubmischbestand bei Göttingen getestet. Die Fluggeschwindigkeit betrug um die 1 m/s, wobei eine optimale Kontrolle der Geschwindigkeit nicht möglich war, da die Drohne manuell in Kronendachnähe gesteuert werden musste. Dies gestaltete sich schwierig, da zwar die Manövrierfähigkeit der Drohne gut war, die Oberflächenstruktur der Waldkronen aber sehr komplex war, was häufige und starke Höhenwechsel erforderlich machte. Dadurch variierte auch der Abstand der Drohne zum Kronendach.

Die E-Nose-Daten wurden zusammen mit den RTK Daten der Drohne mit Hilfe einer in R programmierten Softwareroutine ausgewertet und mit den Daten aus der Bestandesbegehung verglichen, um die Aufklärungsrate von Baumschäden zu berechnen. Abbildungen 6 – 8 zeigen den Workflow zur Visualisierung der Daten. Abbildung 9 zeigt ein exemplarisches Ergebnis für eine mit Borkenkäfer befallene Fläche im Harz bei Clausthal-Zellerfeld. Die Befliegung der Laubmischwaldfläche führte zu keinen Detektionen, da vermutlich die Quellstärke bei den Laubbäumen zu gering war. Vielversprechender wäre eine Fläche mit Blattfraßschädlingen gewesen, die aber im Projekt nicht zur Verfügung stand. Eine Kooperation innerhalb der Fakultät mit dem Projekt RiMa konnte aufgebaut werden, eine Drohnenbefliegung von mit Eichenprozessionsspinner befallenen Flächen in Brandenburg mussten aber wegen Sturmwarnung abgebrochen werden.




Abbildung 6: zeigt die Glättung des Sensorsignals für die nachfolgende Peakdetektion




Abbildung 7: zeigt die Identifikation von lokalen Minima und Maxima zur Peakdetektion




Abbildung 8: zeigt die abstrahierten Sensorpeaks (obere blaue Striche) und macht damit die Georeferenzierung der Sensorergebnisse und den Vergleich zu den Bodendaten (Baumvitalität) möglich




Abbildung 9: zeigt ein Ergebniss der Electronic Nose im Harz. Die Fläche war stark mit Borkenkäfer befallen (Infested Trees)

II.3.1.5 Validierung Einzelbaumzustandsprognosen (AI5)

Das AP AI5 wurde nahtlos in die KI basierten Datenanalysen integriert, da hier Testdatensätze ausgewiesen wurden, um die Performance der KI Algorithmen zu testen. Somit wurden die Bodendatenaufnahmen in AI3 mit den Bodenaufnahmen in AI5 parallelisiert.

II.3.1.6 Fazit

Die AWI koordinierte das Projekt FOREST^{CARE} und übernahm Teilaufgaben über die gesamte Prozesskette, von Datenaufnahme bis zur KI-gestützten Datenauswertung. Der Wissensgewinn war sehr hoch, beginnend bei GNNS Systemen für die Baumaufnahme bis hin zur Programmierung von Datenanalyseroutinen in Python. Es wurden Daten für drei noch ausstehende Publikationen gesammelt, die sich aktuell in unterschiedlichen Bearbeitungsstadien befinden. Damit kann das durch die AWI durchgeführte Teilprojekt als erfolgreich abgeschlossen gelten.

II.3.2 Ergebnisse Partner Felis

II.3.2.1 Planung und Ablauf des Vorhabens (FE1)

II.3.2.1.1 AP FE1 Internes Projektmanagement

Interne Vernetzungen mit dem Graduiertenkolleg ConFoBi und externe Vernetzungen mit der Forstlichen Versuchs- und Forschungsanstalt Baden-Württemberg (FVA-BW) wurden etabliert. Ein ConFoBi-Testgebiet wurde schließlich als Testgebiet in ForestCare aufgenommen, aber die von der FVA bereitgestellten Daten im 2021 reichten nicht aus, um Testgebiete auszuwählen. Später im Jahr 2022 wurden gemeinsam mit der FVA-BW weitere Testflächen identifiziert, die jedoch nicht mehr in die Analyse einbezogen werden konnten, da die Feldarbeit und die detaillierten Drohnenflüge in der verbleibenden Projektzeit nicht mehr durchgeführt werden konnten. Darüber hinaus leistete die FVA- BW Unterstützung bei der Identifizierung geeigneter Testgebiete auf der Grundlage von artenspezifisch gestörten Waldbeständen, die im Projekt verwendet wurden.

II.3.2.1.2 AP FE2 Bestandsaufnahmen

In Absprache mit dem Projektpartner AWI wurde eine Feature-Katalog nach forstwirtschaftlich relevanten Kriterien erstellt und auf Basis dieser Kriterien wurden mit der von CONTERRA entwickelten App Felddaten auf den Testflächen erfasst.

Die erhobenen Daten basieren auf 4 Hauptkriterien, nämlich: Allgemeine Informationen - Baumart, Standort; Durchmesser auf Brusthöhe (DBH) - mehrere Messungen und durchschnittlicher DBH; Zustand des Stammes - mehrere Parameter geprüft; Zustand der Krone - mehrere Parameter geprüft.

Insgesamt wurden 5 Testgebiete mit Gesamtfläche von ca. 20 ha vollständig gemessen. 3 dieser Flächen befanden sich in der Nähe von Sankt Peter und 2 in der Nähe von Turner. Der ursprüngliche Plan, 20 Plots anzulegen, konnte nicht realisiert werden, da der Aufwand für die Feldmessungen und die UAV-Datenerfassung höher war als ursprünglich geschätzt. Es wurden Übersichtsdrohnenflüge in 100 m Höhe mit einer RGB-Kamera durchgeführt, und die Daten wurden verarbeitet, um Orthomosaik für alle ausgewählten Testgebiete zu erstellen. Diese wurden als Hintergrundkarten in der CONTERRA- App verwendet. Die visuelle Identifizierung anhand dieser Karte sowie die Basis-Rover-Konstellation mit hochpräzisen EMLID Reach RS2 GNSS-Geräten wurden zur Markierung einzelner Bäume in der App verwendet. Nach der Markierung eines Baumes wurden die Informationen zu den im zuvor erwähnten Merkmalskatalog definierten Parametern so detailliert wie möglich erfasst.

II.3.2.1.3 AP FE3 Datenaufnahmen LiDAR / Multispektral

Da wir mit zwei verschiedenen passiven (MicaSense RedEdge-P und Zenmuse P1) und einem aktiven Sensor (Zenmuse L1) gearbeitet haben, war es wichtig, die Leistung unter verschiedenen Flugbedingungen (Höhe, Geschwindigkeit, Überlappung usw.) für jeden der Sensoren zu verstehen, um die Flugplanung zu optimieren. Die Flugplanungs- und Steuerungssoftware UgCS wurde für die Erstellung der Flugpläne verwendet und ermöglichte nach dem Hochladen auf die

Drohne das automatische Fliegen und die Datenerfassung.

Die beiden passiven Sensoren nehmen in einem eingestellten Zeitintervall Bilder auf, aus denen mittels "Structure for motion" /Photogrammetrie(PG) ein Orthomosaik (Ortho), digitales Geländemodell (DGM) oder eine 3D-Punktwolke (PointCloud) erstellt wird. Damit in der PG ein Modell errechnet werden kann, müssen sich die einzelnen Bilder überlappen. Bei dem aktiven Sensor werden kontinuierlich Daten aufgenommen. Ähnlich wie bei der PG sollten sich die Flugstreifen beim LiDAR auch überlappen, damit z.B. bei höheren Objekten von jeder Seite aufgenommen werden.

Es hat sich etabliert Flugbahnen abzufliegen, damit möglichst genau der seitliche Abstand eingehalten werden kann. Um die 3D-Modell Qualität zu erhöhen wurde zusätzlich noch einmal im 90 Grad Winkel dazu geflogen, ein Doppelgrid. Dadurch wird jedes Objekt aus 4 Himmelsrichtungen aufgenommen. In diesem Projekt sollten möglichst genaue und hochauflösende Aufnahmen erstellt werden, weshalb bei jedem Parameter versucht wurde, den mit der höchsten Aufnahmequalität zu finden. Unter Testbedingungen erwies sich eine Höhe von 25 m über der Bestandeshöhe und eine 90 % Überlappung (über Bestandeshöhe) der Bilder nach vorne und zur Seite als optimal für die Erstellung hochauflösender Orthofotos, und diese Spezifikationen wurden für die Hauptdatenerfassungsflüge verwendet. Außerdem wurden die Sensorparameter wie Blende, ISO und Belichtungszeit für die passiven Sensoren und Erfassungsfrequenz, Winkel, Abtastmuster und Anzahl der Wiederholungen für den LiDAR-Sensor nach ausgiebigem Testen verschiedener Optionen ebenfalls optimiert.

Aufgrund von Lieferschwierigkeiten bei der Beschaffung des Drohnensystems und der Sensoren (L1- LiDAR-Sensor, P1-RGB und die Multispektralsensoren) konnten diese erst gegen Ende des ersten Projektjahres beschafft werden. Daher wurden die Flüge zur Parameterbestimmung mit einem geliehenen Sensor durchgeführt. Die vom AWI beschaffte Drohne und die Kameras wurden ebenfalls in einem gewissen Umfang genutzt, aber umfangreiche Flugkampagnen konnten erst im Jahr 2022 durchgeführt werden.

II.3.2.1.4 AP FE4 Satellitendatenauswertung

Die Satellitendaten in ForestCare müssen bestimmte Qualitätskriterien in Bezug auf räumliche, spektrale und zeitliche Auflösung erfüllen. Räumlich sollten die Daten eine sehr hohe Auflösung haben, damit die detaillierte Variabilität in den Reflexionen der einzelnen Bäume erfasst wird.

Spektral sollten die Daten das nahe Infrarot und möglichst auch die roten Randwellenlängen abdecken, die beide empfindlicher für den Zustand der Vegetation sind als reine RGB-Wellenlängen. Drittens sollten die Satellitenbilder einerseits aus der Belaubungs-/Vegetationszeit stammen und andererseits zeitlich so nah wie möglich an den Daten der Feldbeurteilung der Bäume liegen, um eine realistische Korrelation zwischen Feld- und Fernerkundungsbeobachtungen zu erhalten.

Die Beschaffung von Satellitendaten mit den gewünschten Spezifikationen erwies sich als schwieriger als erwartet, und schließlich kam man zu dem Schluss, dass die Menge der Satellitendaten, die wir erwerben konnten, entgegen früheren Schätzungen sehr begrenzt war.

Für die meisten Standorte im Schwarzwald konnten für die Jahre 2021 und 2022 zwei Aufnahmen pro Jahr - eine im Frühsommer und eine im Hoch- und Spätsommer – erworben werden.

Für die Testgebiete in Harz wurden die Feldarbeiten im Jahr 2022 durchgeführt, so dass nur Bilder aus dem Jahr 2022 genutzt werden konnten. Der Satellitensensor, der unsere Anforderungen an allen Standorten erfüllte, war Pleiades 1 (0,5 m Pixelauflösung), und es wurden alle wolkenfreien Bilder erfasst. Zusätzlich wurden Sentinel-2-Daten erfasst, da sie eine bessere zeitliche Auflösung haben, wenn auch mit einer viel geringeren Pixelauflösung von 10 m.

II.3.2.1.5 AP FE5: Parametrische Analysen

Ziel der parametrischen Analyse ist es, unabhängig vom Deep-Learning-Ansatz der GWDG, Korrelationen zwischen Feld- und Fernerkundungsparametern zu ermitteln, um die Fernerkundung schließlich für die Klassifizierung des Baumzustands zu nutzen. Die wichtigsten Schritte sind die Segmentierung einzelner Bäume, die Parameterextraktion und die statistischen Analysen.

Segmentierung: Parallel zu der vom Projektpartner AWI durchgeführten manuellen Segmentierung wurden hier zwei Ansätze verfolgt. Der eine verwendete Puffer um die Spitzen der einzelnen Bäume, der andere einen Wasserscheide-Algorithmus. Die Eingabe für beide Algorithmen sind die Spitzen der einzelnen Bäume, die durch das Auffinden lokaler Maxima im digitalen Oberflächenmodell der Punktwolke erkannt werden. Beim Wasserscheiden-Ansatz wird die topografische Morphologie analysiert, um einzelne Wasserbecken zu identifizieren, die einzeln oder in bestimmten Fällen nach weiterer Analyse zusammengeführt werden können, um einzelne Baumgrenzen darzustellen. Weitere Verbesserungen in Form einer Vorverarbeitung von Punktwolken wurden etabliert, um Punkte in einem bestimmten Abstand zum Boden zu entfernen und so die Erkennung von Baumkronen zu verbessern.

Extraktion der Parameter: Die mit verschiedenen Segmentierungsmethoden ermittelten Einzelbaumgrenzen wurden verwendet, um die den Einzelbäumen entsprechenden Pixelwerte aus allen Fernerkundungsdatensätzen außer den LiDAR-Bildern, d. h. RGB-Bildern, Multispektralbildern und Satellitenbildern, auszuschneiden.

Analysen: Die vorprozessierten UAV- und Satellitendaten aus den oben genannten Abschnitten wurden mit statistischen und maschinellen Lernmethoden analysiert, um ihre Effektivität bei der Klassifizierung verschiedener Gesundheitszustände von Bäumen zu bewerten.

II.3.2.2 Bestandsaufnahmen (FE2)

Tabelle 2 und Abbildung 10 zeigen die Flächenaufteilung der ausgewählten Versuchsflächen, die für die Datenerhebung in der Region Südschwarzwald genutzt wurden.



Abbildung 10: Übersicht über die Versuchsflächen

Plotnummer	Fläche [ha]
F101	5,6
F102	4,9
F103	3,7
F301	2,6
F302	1,8

Tabelle 2: Größe der Versuchsflächen

Bei der Baumaufnahme wurde darauf geachtet, jeden Baum mit einem Durchmesser von mehr als ca. 20 cm aufzunehmen. Dadurch gibt es vereinzelte Bäume, die nicht bis an die vorherrschende Kronendecke reichen und somit aus der Luft nicht sichtbar sind. Lediglich LiDAR kann diese Bäume erkennen. Die meisten Bäume hatten einen Durchmesser von etwa 50 cm, wobei der größte Umfang 85 cm betrug.

II.3.2.2.1 Feature-Katalog

In Absprache mit dem Projektpartner AWI wurde der Feature-Katalog nach forstwirtschaftlich relevanten Kriterien erstellt. Der Katalog, der letztendlich in die Feldvermessungssoftware implementiert wurde, ist in vier Abschnitte unterteilt:

1. Allgemeine Daten - Dieser Abschnitt enthält allgemeine Baumdaten wie Baumart/Klasse und Position. Bäume werden als Nadel- oder Laubbaum klassifiziert, was die Anzeige relevanter Kriterien in den Abschnitten 3 und 4 erleichtert und die Feldarbeit beschleunigt.
2. Brusthöhendurchmesser (BHD) - Der BHD wird durch bis zu vier Messungen mit Kreuz-Kluppen erfasst, gespeichert werden jedoch nur die ersten beiden Messungen und der Durchschnittswert.
3. Stammzustand - Der Gesundheitszustand des Stammes wird als gesund oder leicht, mittel, schwer geschädigt eingestuft. Bei gesunden Stämmen werden nur nicht gesundheitsrelevante Kriterien wie Zwiesel, Krebs oder Verformungen erfasst. Bei Schäden können zusätzliche Merkmale wie Harzfluss, Pilzbefall oder mechanische Schäden in verschiedenen Schweregraden angegeben werden. Zudem wird die Stammform (gerade oder schief) erfasst.
4. Kronenzustand - Ähnlich wie beim Stamm gibt es einen allgemeinen Gesundheitszustand und spezifische Merkmale wie Käferbefall, Nadel/Blatt-Verfärbung, Verlichtung, Hexenbesen und andere Schäden.

II.3.2.2.2 Baumaufnahmen

Die Baumaufnahmen begannen mit der Erstellung einer georeferenzierten Übersichtskarte (Orthomosaik) für die ForestCare App. Eine RGB-Kamera an einer Drohne in 100 Metern Höhe, mit RTK oder Ground-Control-Points (GCP), wurde zur Kartierung genutzt. Im Gelände wurden GNSS- Geräte in einer Basis-Rover-Konstellation eingesetzt, um eine genaue GPS-Positionierung zu gewährleisten. Fehlerkorrekturen wurden über UHF von der Basisstation zum Rover gesendet. Beide EMLID Reach RS2 Geräte boten zentimetergenaue Positionsgenauigkeit. Bei schlechtem GPS- Empfang erfolgte eine manuelle Korrektur der Position in der App mithilfe der Hintergrundkarte. Der Rover wurde über Bluetooth mit dem Feldtablett verbunden und per Franson Gate mit der App synchronisiert. Bei jedem Baum wurden Basisparameter wie Art, Position (Kreuzmessung) und BHD aufgenommen. Die aufnehmende Person stand direkt am Stamm, um den Baum aus verschiedenen Entfernungen und Blickwinkeln auf Schäden zu untersuchen. Kleine Schäden wie Läuse wurden so frühzeitig erkannt, höhere Schäden oft nur von bestimmten Positionen. Unterschiedliche Personen erfassten die Daten, wobei eine Benutzerkennung gespeichert wurde, um Abweichungen in der Schadensinterpretation zu berücksichtigen. Vorab wurden alle Personen durch gemeinsame Baumaufnahmen geeicht, um Unterschiede zu minimieren. Bei nassen Stämmen, Schnee, Eis oder Dunkelheit wurde keine Feldarbeit durchgeführt, um verdeckte Merkmale zu vermeiden.




Abbildung 11: Verteilung der gemessenen Bäume: nach Baumart (oben) und nach Kronen- und Stammvitalität (unten)

Abbildung 11 zeigt die Verteilung der gemessenen Bäume auf die verschiedenen Baumarten. Außerdem wird die Anzahl der Bäume dargestellt, die nach Kronen- und Stammvitalitätsparametern kategorisiert wurden.

Die Fichte hat mit 1853 Bäumen einen großen Anteil an der Gesamtzahl der Bäume in den ausgewählten Gebieten, was auf die allgemein hohe Anzahl von Fichten im Schwarzwald und den hohen Anteil befallener Fichtenbäume zurückzuführen ist. Gefolgt werden sie von Buche (271) und Weißtanne (132). Die übrigen Arten wie Bergahorn, Lärche, Esche und Eberesche sind weniger häufig vertreten.

Die Vitalitätsdaten zeigen, dass die meisten Bäume in gutem Zustand sind, sowohl bezogen auf ihre Stämme als auch ihre Kronen. Es gibt jedoch auch eine signifikante Anzahl von Bäumen mit leichten bis schwere Schäden sowie abgestorbene Bäume. Insgesamt wurden sehr viele Rückeschäden, Risse und Harzflüsse entdeckt, im Mittelfeld kamen Hexenbesen und Kronenbruch vor, selten waren Lausbefall, Verfärbung und Käferbefall. Die Versuchsflächen im Schwarzwald sind somit nicht sonderlich ergiebig.

II.3.2.2.3 Flugplanung

Die Drohnenflüge werden automatisiert durchgeführt, wobei die Drohne präzise Wegpunkte im dreidimensionalen Raum ansteuert und währenddessen umfassende Datensätze aufzeichnet. Die passiven Sensoren erfassen in festgelegten Zeitintervallen Bilder, die mittels „Structure for Motion“ (Struktur aus Bewegung) / Photogrammetrie (PG) für die Erstellung von Orthomosaiken (Ortho), digitale Geländemodelle (DGM) und 3D-Punktwolken (Point-Cloud) genutzt werden. Eine effektive PG erfordert eine Überlappung der Einzelbilder. Auch der aktive Sensor nimmt kontinuierlich Daten auf. Ähnlich der PG sollten sich auch die Flugstreifen des LiDAR überlappen, um beispielsweise bei höheren Objekten eine vollständige Datenerfassung zu gewährleisten.




Abbildung 12: Flugplanung in UgCS: Die Flugroute wird in Grün dargestellt, die Flugfläche auf dem Boden in Gelb. Eine Satellitenkarte ist in 2.5D vorhanden und es können Links die Parameter eingestellt werden

Bei der Flugplanung sind die optimale Flughöhe, Fluggeschwindigkeit und Überlappungsgrade (seitlich und bei PG auch vorwärts) für jeden Sensor von entscheidender Bedeutung. Die Festlegung spezifischer Flugbahnen hat sich bewährt, um einen präzisen seitlichen Abstand einzuhalten. Zur Verbesserung der 3D-Modellqualität wurde zusätzlich ein Doppelgrid geflogen, bei dem jedes Objekt aus vier unterschiedlichen Perspektiven erfasst wird. Zu sehen ist eine Beispielroute in Abbildung 12.

Das übergeordnete Ziel dieses Projekts war die Erstellung äußerst präziser und hochauflösender Aufnahmen, weshalb bei jedem Parameter auf die bestmögliche Aufnahmequalität geachtet wurde.

Flughöhe

Zunächst wurde die niedrigstmögliche Flughöhe (>12m über dem Ziel, d.h. über der Baumkrone) für ein Testgebiet gewählt, um die Bildaufnahme zu maximieren. Jedoch führte selbst bei optimalen Einstellungen diese Höhe zu unvollständigen Orthomosaiken, trotz zusätzlicher schräger Bilder in Winkeln wie 75 Grad. Das Ziel war es, geometrische Verzerrungen und Datenlücken im Orthomosaik zu minimieren. Verzerrungen entstehen durch Vereinfachungen im 3D-Modell, oft bedingt durch unzureichende Daten. Lücken entstehen dort, wo die Kamera aufgrund von Hindernissen keine Bilder aufnimmt, z.B. zwischen Bäumen oder in Kronenverzweigungen.

Die Flughöhe wurde dann von 15m über dem höchsten Baumpunkt auf 25m erhöht, doch blieben weiterhin Lücken im Orthomosaik bestehen, was höhere Flughöhen erforderte. Um hochauflösende Orthomosaiken zu erreichen, wurde auch ein Ansatz mit erhöhter Überlappung getestet.

Überlappung

Die Mindestüberlappung beträgt 50%, damit jeder Pixel des Bildes mit einem benachbarten Bild verglichen werden kann. Der maximale Grad von 100% bedeutet, dass sich Bilder an derselben Stelle überlappen. Üblicherweise wird eine Überlappung von 60-90% gewählt, was sich besonders bei hohen Objekten positiv auf die Modelle auswirkt. Die Überlappung wird durch die Flughöhe und den Kameraöffnungswinkel bestimmt, wobei das Ergebnis die Überlappung am Boden ist. Da viele Flugplanungssoftware nur bis zu 90% Überlappung zulassen, wurde dies auf 25m Flughöhe eingestellt und die Höhe dann entsprechend angepasst. Dies ermöglicht eine effektive 90%ige Überlappung, selbst bei maximaler Baumhöhe.

Fluggassenabstände

Die Fluggassenabstände errechnen sich durch Flughöhe und gewünschter Überlappungsgrad. Die Fluggassenabstände als auch anderer Parameter wurde automatisch von der Flugplanungssoftware (UgCS) errechnet und konnten nicht verändert werden. Auswahlmöglichkeit gibt es noch für die Option eines Doppelgrids, welche ausgewählt wurde.

Fluggeschwindigkeit

Die Fluggeschwindigkeit ergibt sich aus dem gewünschten Vorwärts- Überlappungsgrad als auch der Zeit, die der Sensor braucht, um das Bild aufzunehmen, zu verarbeiten und abzuspeichern. Dieser Wert ist in der Regel angegeben und beträgt 1 Sekunde. Im Sinne der maximalen Datenaufnahme wurde somit die langsamste auswählbare Fluggeschwindigkeit ausgewählt: 1 Meter pro Sekunde. Ein nachträgliches, künstliches Erhöhen der Fluggeschwindigkeit ist teilweise möglich durch zum Beispiel die Auswahl jedes 2. Bildes für die Verarbeitung.

Sensorparameter (RGB und Multispektral)

Die Sensorparameter sind entscheidend für die Datenerfassung und müssen neben den Flugparametern optimiert werden. Für die RGB-Kamera sind die Belichtungszeit, ISO-Empfindlichkeit und Blende von Bedeutung. Andere Einstellungen wie Farbtemperatur und Auflösung sind auf maximale Neutralität eingestellt, der Dateityp ist JPG und der Shutter auf „Global Rolling“.

Eine weit geöffnete Blende erhöht die Lichtmenge auf dem Sensor, führt jedoch zu begrenzter Tiefenschärfe. Eine Erhöhung der Blendenzahl auf 5.6 oder 8 verbessert die Tiefenschärfe, reduziert jedoch die Lichtmenge und erfordert längere Belichtungszeiten.

Die ISO wird minimal eingestellt, um Rauscheffekte zu minimieren. Kleine ISO-Werte bedeuten weniger Licht auf dem Sensor und längere Belichtungszeiten.

Kurze Belichtungszeiten minimieren Bewegungsunschärfe, sowohl durch Objekte als auch durch Kamerabewegungen. Die Pixelgröße des Sensors, Fluggeschwindigkeit und Flughöhe sind entscheidend für die Belichtungszeit.

Die gewählten Parameter umfassen eine Flughöhe von 25m über dem Bestand, 90% Überlappung (horizontal und vertikal) auf Kronenspitzenhöhe, Fluggeschwindigkeit von 1m/s, Blende 8, automatische ISO und eine Belichtungszeit von 1/1000 Sekunde.

Es ist wichtig, während des Fluges die Sensorparameter möglichst stabil zu halten, da insbesondere bei passiven Sensoren die Belichtung von der Sonneneinstrahlung abhängt und Schwankungen auftreten können. Der Sonnenstand variiert je nach Tageszeit, was die Beleuchtung beeinflusst. Zusätzlich können Wolken die Lichtverhältnisse ändern. Idealerweise sollten Aufnahmen an bedeckten Tagen ohne Wind gemacht werden, doch solche Bedingungen waren während der Flugsaison selten anzutreffen. Häufig gab es entweder rein sonnige Tage oder wechselnde Bewölkung, letzteres ist problematisch, da es zu großen Beleuchtungsunterschieden zwischen den Aufnahmen führt. Dies können die festen Parameter wie Blende und Belichtungszeit herausfordern und zu erhöhtem Rauschen durch hohe ISO-Werte führen.

Wind stellt ein weiteres Problem dar, da er Bäume in Bewegung versetzt und dadurch unterschiedliche Formen erzeugt. Die ungleichmäßige Bewegung von Ästen führt zu Schwierigkeiten bei der Ausrichtung der Bilder und der Berechnung der Punktwolke durch die Software. In der Orthofotografie treten weniger Probleme auf, da sie aus mehreren Bildern zusammengesetzt wird. Häufig wird nur ein kleiner Bereich jedes Bildes verwendet, was zu einem Schachbrettmuster führt. Bei starkem Wind können jedoch Verzerrungen an den Kanten der Bereiche auftreten, in denen Bäume abgebildet sind.

Die lange Flugdauer bei hoher Auflösung führt zu veränderten Beleuchtungsrichtungen durch die Sonne. Nach mehreren Stunden Flug verändert sich der Sonnenstand erheblich, was zu unterschiedlichen Belichtungswinkeln und damit zu inkonsistenten Schattenflächen führt.

Dies kann durch die Unterteilung der Fläche in kleinere Bereiche gelöst werden, was jedoch andere Herausforderungen wie das Zusammenführen der Abschnitte mit sich bringt.

Der Multispektralsensor hat die gleichen Parameter wie die RGB Kamera und somit auch die gleichen Herausforderungen. Leider lässt sich die Multispektralkamera nicht ausrichten, sie ist fest im 90 Grad Winkel nach unten montiert.

Sensorparameter (LiDAR)

Da der aktive Sensor selbst für die benötigte Beleuchtung sorgt, ist dieser Unempfindlich für äußere Beleuchtungsänderungen. Gewählt werden kann die Aufnahmefrequenz, der Aufnahmewinkel, das Abtastmuster und die Anzahl der Returns.

Die Aufnahmefrequenz wurde auf die höchste Option eingestellt, um eine maximale Aufnahmedichte zu erreichen. Es wurde jedoch festgestellt, dass die Theorie einer erhöhten Strahlungsintensität bei niedrigeren Frequenzen weder durch die Dokumentation noch durch Praxistests bestätigt werden konnte.

Bei Abtastmuster, stehen zwei Optionen zur Verfügung: Repetiv und Non-Repetiv. Das Repetiv-Muster ähnelt dem Raster bei passiven Sensoren, wobei die Pixel im Bild kontinuierlich und gleichmäßig abgetastet werden. Das Non-Repetiv-Muster verwendet hingegen ein rotierendes Blumenmuster, was zu einer schnelleren und besseren Abdeckung der Geometrie im Sichtfeld des Sensors führt.

Der LiDAR kann im 90-Grad-Winkel nach unten ausgerichtet werden, aber auch in anderen Winkeln wie zum Beispiel nach vorne. Der 90-Grad-Winkel bietet eine maximale Entfernung der Laserstrahlen und minimiert somit Messfehler. Ein leichter Winkel (z.B. 75 Grad) und das Non-Repetiv-Muster führten zu einer höheren Punktedichte an Baumstämmen im Vergleich zum 90-Grad-Winkel.

Es können bis zu drei Returns für jeden ausgesendeten Laserstrahl aufgenommen werden, was eine detaillierte Datenerfassung ermöglicht. Der LiDAR tastet einen Trichter ab, dessen Größe mit der Entfernung zunimmt. Dadurch können auch kleine Objekte in großer Entfernung erfasst werden, was LiDAR für die Datenerfassung im Bestand besonders geeignet macht. Die Farbinformationen der Punkte werden durch gleichzeitig aufgenommene RGB-Bilder bereitgestellt, jedoch können nur oberflächennahe Punkte die korrekte Farbe haben. Dies führt dazu, dass Punkte im Bestand eine falsche Farbe aufweisen können.

Die Beleuchtung hat keinen Einfluss auf die reinen LiDAR-Datenaufnahmen, im Gegensatz dazu kann Wind die Qualität der Aufnahmen erheblich beeinträchtigen. Ähnlich wie bei der Photogrammetrie (PG) führt Wind bei LiDAR zu bewegten Bäumen oder Ästen. Während bei PG pro Sekunde ein Bild aufgenommen wird und Bewegungen nicht erkennbar sein sollten, erfasst LiDAR bis zu 240.000 Datenpunkte pro Sekunde. Wenn sich ein Objekt während der Aufnahme bewegt, wird es in mehreren Positionen erfasst und kann gestreckt erscheinen. Bewegt sich das Objekt entgegen der Flugrichtung, werden weniger Datenpunkte erfasst und das Objekt kann gestaucht wirken.

Aufgrund des Doppelgrids entstehen durch mindestens vier Überflüge mit unterschiedlichen Zeitpunkten vier verschiedene Posen oder Formen des Baumes bei starkem Wind. Dies kann zu einem verwaschenen Datensatz führen, wodurch die Konturen des Baumes unscharf werden.

Die Fluggeschwindigkeit ist entscheidend für die Menge und Qualität der LiDAR-Datenerfassung. Langsamere Fluggeschwindigkeiten führen zu einer höheren Datendichte, aber auch zu mehr Verwaschungen bei Wind. Es wurde festgestellt, dass die Kalibrierung des LiDAR im Flug nur effektiv funktioniert, wenn alle 100 Sekunden eine bestimmte Geschwindigkeitsveränderung vorliegt. Der Ansatz, eine maximale Datendichte zu erreichen, führte zu einer minimalen Fluggeschwindigkeit von 1 m/s, was jedoch zu Verwaschungen und Verwackelungen (und damit zu einer schlechten Kalibrierung während des Fluges) führte. Daher wurde die Fluggeschwindigkeit erhöht, die Flughöhe auf 15 m über dem Kronendach festgelegt und die Überlappung auf 90% angepasst.

II.3.2.2.4 Übertragung der Flugroute zur Drohne

Der Hersteller der Desktop Software UgCS, welche für die Flugplanung genutzt wurde, hat auch eine App für die Fernsteuerung der DJI Drohne, welche allerdings nur genutzt werden kann, solange während des Fluges ein Laptop mit im Feld ist. Alternativ kann die Route als .kml-Datei exportiert und auf der Fernsteuerung importiert werden.

II.3.2.2.5 Vorbereitungen vor dem Flug

Vor dem Flug muss die Genehmigung zum Fliegen auf der Fläche beim Grundstückbesitzer eingeholt werden, in unserem Fall den Staatswaldförstern. Die notwendigen Bedingungen zum Fliegen der Drohne müssen überprüft werden, wie Abstand zu Flugplätzen, Bundesfernstraßen, Menschen, Wohngebieten o.Ä. Am Tag des Fluges muss nochmal das Wetter überprüft werden, dabei sollte auf die Windgeschwindigkeit, Temperatur und die Niederschlagswahrscheinlichkeit geachtet werden. Ein weiterer wichtiger Punkt sind noch die NOTAMS die überprüft werden müssen, dort können kurzfristig eingerichtete Flugverbotszonen veröffentlicht werden.

II.3.2.2.6 Durchführung

Für den Drohnenflug wird zunächst das RTK-System der Drohne eingerichtet. Da dieses System keine direkte Verbindung zu Korrekturdiensten herstellt, wird die Position zuerst mit einem separaten System vermessen. So weit bekannt, mittelt die DJI RTK Station ihre Position und merkt diese sich für ein erneutes Aufstellen in der Nähe. Dies sorgt für relativ korrekte Datensätze, allerdings stimmt die globale Position nicht notwendigerweise. Für präzise Positionierung wird ein EMLID Reach RS2 mit NTRIP (über eine integrierte Mobilfunkverbindung) genutzt, um die Position zu bestimmen und in die DJI RTK Station einzugeben.

Anschließend werden die Drohne und die Sensoren aufgebaut. Vor jedem Flug werden die SD-Karten formatiert und alle Flugeinstellungen wie maximale Flughöhe, Startposition und maximale Flugentfernung überprüft. Die RTK-Station wird verbunden, die gemessenen Koordinaten werden eingegeben, und dann werden die Drohne und die Fernsteuerung neu gestartet.

Danach erfolgen die Einstellungen für die Sensoren wie ISO, Blende, Belichtungszeit und Ausrichtung.

Die Flugroute wird von der Fernsteuerung auf die Drohne hochgeladen. Bei einem Flug mit der Multispektralkamera wird nun manuell das Reflektanzpanel fotografiert, indem die Drohne über das Panel gehalten wird und auf dem Sensor der Auslöser gedrückt wird. Dabei ist zu beachten, dass das Panel in der Sonne ist als auch der Lichtsensor der Multispektralkamera.

Bei Flügen mit passiven Sensoren wird die Route gestartet, und die Drohne fliegt automatisch die Flugroute ab. Beim LiDAR muss manuell gestartet werden und auf ausreichender Höhe die IMU kalibriert werden. Erst danach kann die Route beim LiDAR gestartet werden. Beim ersten Wegpunkt des Gebietes wird händisch die Aufnahme gestartet, beim letzten Wegpunkt die Aufnahme händisch beendet. Bei der Multispektralkamera wird noch einmal das Panel am Schluss fotografiert. Im Falle eines Akkuwechsels wird bei der Multispektralkamera auch nochmal das Panel fotografiert. Die Akkus können einzeln gewechselt werden, wobei die Drohne eingeschaltet bleibt und die Einstellungen erhalten bleiben. Ein Neustart der Drohne erfordert jedoch eine erneute Verbindung des RTK und kann zum Löschen einiger Einstellungen führen, z. B. der Farbgebung der PointCloud beim LiDAR.

Nutzung von Ground Control Points (GCPs)

Die Multispektralkamera verfügt nicht über eine RTK- Integration und nutzt somit nicht die RTK-Daten der Drohne. Daher sind Ground Control Points (GCPs) erforderlich, die vor dem eigentlichen Flug ausgelegt und mit dem EMLID vermessen werden. Für die Nutzung von Ground Control Points (GCP) werden spezielle Markierungen, in unserem Fall gekreuzte weiße Längsstreifen, auf der Versuchsfläche platziert. Diese Markierungen werden an Orten positioniert, die von der Drohne aus sichtbar sind, vorzugsweise vertikal unter einer Baumücke. Dabei wird darauf geachtet, dass die gesamte Versuchsfläche abgedeckt ist, insbesondere die äußeren Bereiche.

Anschließend wird das EMLID System als Base-Rover Konfiguration aufgebaut. Die Basisstation wird genau vermessen und über NTRIP werden die GCPs mit dem Rover vermessen. Die Base-Rover Konfiguration verspricht in der Theorie einen guten Empfang der Korrekturdaten im Bestand, da diese über Radiowellen von der Basis zur Rover-Einheit gesendet werden. Dadurch benötigt der Rover im Bestand keinen direkten Handyempfang für NTRIP, sondern muss lediglich in Reichweite der Basisstation sein und ausreichend Satellitensignale empfangen. In der Praxis gibt es jedoch oft das Problem der Messgenauigkeit von über 30cm.

Die beiden DJI Sensoren - P1 und L1 verfügen über RTK-Integration, was bedeutet, dass die erzeugten Daten nahezu übereinstimmen werden, bis auf wenige Zentimeter.

II.3.2.2.7 Datenvorverarbeitung mittels Photogrammetrie oder „Struktur from Motion“ (SfM):

Die Datenvorverarbeitung unterscheidet sich zwischen aktiven und passiven Sensoren. Während der aktive Sensor nur eine minimale Vorverarbeitung benötigt, ist für die passiven Sensoren ein komplexerer Prozess mit speziellen Softwaretools erforderlich.

Im Folgenden wird einer der leistungsfähigsten Workflows für passive Sensoren in der Software Agisoft Metashape vorgestellt. Eine sehr empfehlenswerte Quelle für detaillierte Informationen ist das Handbuch des United States Geological Survey (USGS): "Processing Coastal Imagery With Metashape Professional Edition, Version 1.6 - Structure From Motion Workflow Documentation":

1. Projekt erstellen - Es wird ein neues Projekt erstellt, optionaler Weise mit mehreren "Chunks" zur Verarbeitung großer Datensätze in kleinere Abschnitte.
2. Bilder hinzufügen - Alle Bilder werden dem Projekt hinzugefügt. RGB-Bilder werden als Einzelbilder gespeichert, während jeder Kanal einer Multispektralkamera separat in einer TIFF-Datei gespeichert wird. Metashape fragt nach dem Typ der Bilder (Einzelkamera-System oder Mehrkamera-System) und stellt bei der Multispektralkamera den Hauptkanal auf „Panchromatic“.
3. Bilder Ausrichten (Alignment) - Die Software bestimmt automatisch die genaue Position und Ausrichtung der Bilder anhand von gemeinsamen Features. Es gibt Einstellungen zur Genauigkeit des Alignments, zur Bildauswahl und zur Vermeidung unnötiger Punkte.
4. Kamera Optimieren - Die Kameraparameter werden optimiert, einschließlich Fokuspunkt, Verzerrungen und Neigungen. Optionen für verschiedene Kameras und Kovarianzberechnungen sind verfügbar.
5. DenseCloud erstellen - Aus den Bildern entsteht eine dichte Punktwolke, wobei Einstellungen zur Genauigkeit, Farb- und Konfidenzberechnung sowie zur Tiefenfilterung angepasst werden können.
6. DEM erstellen - Ein digitales Höhenmodell kann basierend auf den Bildern oder der Punktwolke erstellt werden, wobei verschiedene Qualitäts- und Koordinateneinstellungen möglich sind.
7. Orthomosaik erstellen - Auf Basis des DEMs wird ein Orthomosaik erstellt. Optionen wie „Hole filling“ und „Ghost Filter“ können deaktiviert werden, um Analysen auf den Pixelwerten der Orthomosaiks zu verbessern. Unterschiedliche DEM-Varianten beeinflussen die Qualität und Oberflächengenauigkeit des Orthomosaiks.

Allgemeine Einstellungen

Das UTM98 Koordinatensystem wurde für alle Schritte eingestellt, um eine nahtlose Auswertung der Daten zu gewährleisten.

Große Datensätze

Hohe Datendichten führten zu Speicherproblemen. Die Rohdaten von ca. 7 TB für 5 Versuchsflächen (ca. 20 ha) erforderten eine aufwendige Verarbeitung. Jede Fläche musste mehrmals unterteilt werden, was zu Problemen mit Artefakten und Farbunterschieden führte. Eine Option zur Reduzierung der Hardwareressourcen war die Verringerung der DenseCloud-Qualität von High auf Medium.

GPS-Probleme

Die Genauigkeit der GPS-Positionen variierte je nach Kamera. Die DJI P1 RGB- Kamera verwendete RTK-Positionen präzise, während die MicaSense RedEdgeP ihre eigenen GPS- Daten verwendete und daher die Positionen relativ ungenau waren. Nach einem Sensor-Neustart traten teilweise Höhenunterschiede von ca. 50 m auf, die durch eine Alignment ohne Preselection und mit Guided Image matching Ausrichtung gelöst werden konnten, allerdings mit längerer Berechnungszeit.

Verarbeitungszeiten - Die Verarbeitungsdauer war ein zentrales Problem aufgrund hoher Datendichten. Das Bilder-Alignment und die DenseCloud-Berechnung erforderten mehrere Stunden bis Tage, während andere Schritte schneller durchgeführt werden konnten.

II.3.2.3 Segmentierung (FE3)

Für den Deep-Learning-Ansatz und die parametrische Analyse ist eine Segmentierung der Sensordaten für alle Bäume erforderlich, die im Feld erfasst wurden. Es gibt verschiedene Ansätze zur Segmentierung auf Orthomosaiken (Yao et al., 2021; Pu, 2021), auf DEMs und auf 3D-Punktwolken. Letztere versprechen die höchste Genauigkeit und Qualität, weshalb diese ausgewählt wurden.

Für die Baumkronenerkennung wird eine Segmentierung der Punktwolken aller drei Sensoren vorgenommen. Aus beiden photogrammetrischen Datensätzen kann eine dreidimensionale Punktwolke erstellt werden, die der Punktwolke des LiDAR Sensors ähnlich ist. Anhand der dort enthaltenen Höheninformationen der Datenpunkte kann eine Segmentierung der Bäume mittels verschiedener Algorithmen durchgeführt werden. Die Segmentierung lässt sich in zwei Abschnitte unterteilen: Dem Lokalisieren der Baumspitzen und dem Bestimmen der Umrisse eines jeden Baumes.

II.3.2.3.1 Positionsbestimmung

In 3D Punktwolken lassen sich die Positionen von Bäumen durch eine lokale Maxima-Suche bestimmen (Birdal et al., 2017; Caruso et al., 2019; Novotný et al., 2011; Korpela et al., 2006). Dafür wird im DOM nach lokalen Maxima gesucht (siehe Abbildung 14). Hierbei ist der Radius des Suchgebietes wichtig, da bei einem zu klein gewählten Radius zu viele lokale Maxima gefunden werden (was nicht nur Baumspitzen sondern auch hervorstehende Äste sein können) und bei einem zu großem Radius, eng bei einander stehende Bäume nicht korrekt erkannt werden. Zusätzlich werden potenzielle Bäume unterhalb der halben maximalen Baumhöhe bzw. Bestandeshöhe entfernt.



Abbildung 14: DOM mit drei Baumpositionen



Abbildung 13: Seitenansicht Beispielbaum P1 3D Punktwolke mit rot hervorgehobenen Ausreißern

Bei der Auswertung der Ergebnisse wurden Fehlerkennungen sichtbar, welche von Ausreißern verursacht wurden. Die Datensätze werden mit einem Statistical Outlier Removal (SOR) gesäubert, allerdings nicht gründlich genug. Deshalb wurde nach einer Iteration SOR mit den Standardparametern (SOR mit 6 Punkten für die durchschnittliche Distanzberechnung und einem nSigma von 1.00) noch zwei weitere Iterationen mit einer stärkeren Filterung angewandt (SOR mit 12 Punkten und einem nSigma von 2.00). Dadurch werden deutlich mehr Ausreißer entfernt, welche bei den hochauflösenden Bildern der RGB Kamera am häufigsten vorkamen. In Abbildung 13 sind Ausreißer in der Nähe eines Baumes zu erkennen. Bei Fehlern in der Ausrichtung der Bild können diese verstärkt auftreten und somit durch SOR nicht entfernt werden. Grund hierfür können neben der falschen Ausrichtung auch die zu große Anzahl an Bildern und die zu geringe Distanz von Kamera zu Bestand.

II.3.2.3.2 Umrissbestimmung



Abbildung 15: Umrissbestimmung mittels Watershed

Mittels der Wasserscheiden-Methode (englisch: „Watershed“: WS) werden nach der Positionsbestimmung die Umrisse für jeden Baum bestimmt. Dabei wird in einem umgedrehten DOM beginnend bei den lokalen Maximas der Einlauf von Wasser simuliert. Bei jeder Iteration steigt der Wasserstand und breitet sich somit in jedem Pool aus.

Ein Pool entspricht der Ausdehnung eines Baumes. Treffen zwei Pools beim Wachsen aufeinander, entsteht eine Wasserscheide, welche den Umriss des Baumes bestimmt. Das Ergebnis ist in 15 zu sehen.

Ablauf

Nachdem die 3D-Punktwolke in Metashape erstellt wurde, lassen sich in CloudCompare SOR-Iterationen durchführen. Danach folgt die Berechnung der DEMs, Baumpositionen und Umrisse. Die DEMs können mit verschiedenen Softwarelösungen erstellt werden, während die Algorithmen für die Baumpositionen und Umrisse in eigener Software implementiert sind. In ArcGIS werden aus diesen Daten Polygone erstellt, die zum Ausschneiden der Einzelbäume in den Orthomosaiks genutzt werden. Dafür werden die Segmente als ASCII-Datei importiert, gefiltert und ein Puffer um die Punkte gezeichnet. Danach werden Punkte mit gleicher BaumID zu einem Polygon zusammengefügt und der Umriss verkleinert.

Weitere Analysen erfolgen in ArcGIS/QGIS. Die Berechnung von DBM, DOM und CHM, das Auffinden von Baumpositionen mittels lokaler Maxima und die Segmentierung mittels Wasserscheide werden durchgeführt. Die Ausgabe erfolgt als Positionsdatei mit nummerierten Baumspitzen (Punkte) und als Segmentdatei mit Punkten und Baumnummer, beide als ASCII-Datei.

In ArcGIS wird die Segmentdatei importiert und die XY-Daten angezeigt. Es werden Segment-Punkte ausgewählt, die mindestens 10 Datenpunkte und eine relative Höhe von mindestens 5m aufweisen. Ein Buffer wird um jeden Punkt erstellt (0.1m Auflösung, Buffer 0.07m) und nach ObjectID zusammengefügt (Dissolve). Anschließend wird der Buffer um -0.07m verkleinert.



Abbildung 16: L1 Datensatz: Daten in RGB Farben.
Punkte: Erkannte Baumspitzen eingefärbt nach relativer Höhe; Kreise: Nicht erkannter Baum



Abbildung 17: Rechts: Baum mit Umriss in Pink, verkleinerter Umriss in Blau; Links: Hervorgehoben eine Detailansicht

Bei der Positionserkennung werden nicht alle Bäume gefunden (siehe 16). Gründe hierfür sind dicht beieinanderstehende Bäume, großer Höhenunterschied zu Nachbarbäumen, geringere Erkennungsrate bei Laubbäumen und abgebrochene Kronen. Nadelbäume haben eine eindeutige Baumspitze, außer bei Kronenbruch. Laubbäume haben oft keine klare Spitze, und mehrere lokale Maxima müssen gefiltert werden. Ein flexibler, auf der Oberflächengeometrie basierender Radius könnte die Erkennung verbessern.

Probleme bei der Umrissfindung

Umrisse werden zu weit um den eigentlichen gewünschten Umriss herum gezeichnet. Dies kann zwar mittels Verkleinerung des Umrisses verbessert werden, allerdings werden noch immer Bodenpixel mit ausgeschnitten (siehe 17). Grund hierfür sind zum einen die Auflösung des DOM, welche mit 10cm deutlich über den ca 0.6cm des Orthomosaiks liegen und zum anderen, dass Lücken zwischen Ästen nicht vom DOM erfasst werden. Eine höhere Auflösung des DOMs führt zu einer exponentiell längeren Verarbeitungszeit und stößt somit schnell an die Grenzen der Workstation.

II.3.2.3.3 Fazit Segmentation

Die Segmentation mittels lokaler Maxima und der Wasserscheide-Methode liefert gute Ergebnisse, es werden in einem Beispieldatensatz 40 von 60 Bäume erkannt. Probleme gibt es hier bei Laubbäumen oder Störungen wie z.B. abgebrochenen Kronen, unterständige Bäume, mehreren Spitzen oder zu eng beieinanderstehenden Bäumen. Anzeichen für eine verbesserte Segmentierung mittels der geometrischen Features gibt es, dies muss an weiteren Datensätzen untersucht werden.

II.3.2.4 Fernerkundungsbasierte Analyse (FE4)

In diesem Abschnitt wird die Wirksamkeit von UAV- und hochauflösenden Satellitenbildern bei der Klassifizierung des Gesundheitszustands von Bäumen und der Identifizierung von geschädigten Bäumen analysiert. Konkret werden in der Studie vor allem folgende Aspekte untersucht: i) Prüfung der Unterscheidbarkeit von Gesundheitszustandskategorien auf der Grundlage von spektralen Response-

Vergleichen und Vegetationsindizes; ii) Entwicklung und Vergleich von Modellen zur Klassifizierung von aus UAV- und Pleiades-Satellitendaten abgeleiteten Variablen für den Gesundheitszustand unter Verwendung von Random Forest (Breiman, 2001).

II.3.2.4.1 Untersuchungsgebiete

Das Untersuchungsgebiet umfasst drei verschiedene Regionen: den Schwarzwald im Südwesten Baden-Württembergs sowie die Regionen Göttingen und Harz in Niedersachsen. Innerhalb dieser Regionen wurden bestimmte Waldflächen für die Datenerhebung ausgewählt. Im Schwarzwald wurden insbesondere die Flächen F101, F102, F103 und F301, im Göttinger Wald die Fläche G006 und in der Harzregion die Fläche G005 verwendet.

Die Waldflächen des Schwarzwaldes sind überwiegend durch Nadelholzarten, vor allem Fichten, geprägt, vereinzelt auch durch Lärchen oder Weißtannen. Auch Laubbaumarten wie Bergahorn und Buche kommen in diesen Gebieten vor, wenn auch in geringer Zahl (Storch et al., 2020). In ähnlicher Weise wird die Teilfläche im Harz von Nadelholzarten, vor allem Fichten, dominiert. Dagegen weist die dritte Fläche im Göttinger Wald neben der Fichte einen höheren Anteil an Laubbaumarten, insbesondere Buche und Eiche, auf. Fichten machen in den Untersuchungsgebieten fast drei Viertel aller untersuchten Bäume aus.

Plots	Baumanzahl	Anzahl der Laubbäume	Anzahl der Nadelbäume
F101	403	72	331
F102	334	1	333
F103	122	19	103
F301	232	50	182
G005	117	0	117
G006	183	157	26
Summe	1391	299	1092

Tabelle 3: Anzahl der segmentierten Bäume für jedes Teilgebiet, aufgeteilt in Laub- und Nadelbäume

II.3.2.4.2 Referenzdaten

Die Daten wurden konsolidiert, um einen umfassenden und vielfältigen Datensatz zu erstellen. Zunächst wurde jeder Baum einzeln mit GPS-Koordinaten georeferenziert und mit einer breiten Palette von Attributen verknüpft, die im Feld gemessen wurden. Zu diesen Attributen gehörten die Baumklasse, die Baumart, der Durchmesser in Brusthöhe, der Gesundheitszustand von Stamm und Krone

sowie Faktoren, die zu Schäden oder Krankheiten beitragen. Anschließend wurde die genaue Kronenabgrenzung für jeden Baum manuell durchgeführt und als Feature-Layer in die ArcGIS Pro Software integriert. Dieser Prozess führte zur Erstellung von 1392 vollständig abgegrenzten Baumpolygonen, die mit den entsprechenden Informationen über die sechs Flächen verknüpft wurden (siehe Tabelle 3).

II.3.2.4.3 UAV- und Satellitendaten:

Die multispektralen UAV-Daten wurden zwischen 2021 und 2023 bei verschiedenen Flügen mit unterschiedlichen multispektralen Sensoren gesammelt. Bei diesen Flügen wurde ein konstanter Zielabstand von 15-20 Metern eingehalten. Die RedEdge MX Dual Camera wurde eingesetzt, um Bilder mit einer Bodenabtastdistanz (GSD) von 82 Zentimetern pro Pixel (pro Band) in einer Höhe von 120 Metern über dem Boden (AGL) aufzunehmen. Die Aufnahmen der RedEdge-Kamera bestanden aus fünf Bändern, die in der folgenden Reihenfolge aufgenommen wurden: Blau, Grün, Rot, Nahinfrarot und RedEdge.

Der von der französischen Raumfahrtagentur CNES verwaltete Satellit Pleiades liefert hochdetaillierte optische Bilder, die sich in verschiedenen Anwendungsbereichen als äußerst wertvoll erwiesen haben. Der Satellit arbeitet in vier Spektralbändern - Blau, Grün, Rot und Nahinfrarot - und erfasst mit einer räumlichen Auflösung von 2 Metern einen umfassenden Blick auf die Erdoberfläche.

In den panchromatischen Bändern erreicht er sogar eine noch feinere räumliche Auflösung von 50 cm pro Pixel, was seine Fähigkeit zur Erfassung komplizierter Details noch verbessert.

Preprocessing

Bei der Vorverarbeitung der UAV-Daten wurden alle Bilder mittels Nearest Resampling auf eine Auflösung von 2 cm umgerechnet. Für die Pleiades-Satellitendaten wurden die multispektralen Bänder mit NNDiffuse pan-sharpening auf 0,5 m Auflösung geschärft. Die atmosphärische Korrektur wurde dann mit dem ENVI Quick Atmospheric Correction (QUAC) Algorithmus durchgeführt.

Generierung von Feature layer und Datenextraktion

Für die UAV-Bilder wurden sechs Vegetationsindizes (VI) berechnet, nämlich **ARVI** (Atmospherically resistance vegetation index - Kaufman and Tanre, 1992), **NDVI** (Normalized difference vegetation index – Tucker, 1979), **PSRI** (Plant senescence reflectance index - Merzlyak et al., 1999), **GNDVI** (Green normalized difference vegetation index - Gitelson et al., 1996), **CIG** (Chlorophyll index green - Gitelson et al., 2003), und **RNDVI** (Red Edge Normalized difference vegetation index - Merzlyakb, 1994). Diese Indizes haben sich bei der Einschätzung der Mortalität von Bäumen im Wald und bei der Bewertung der Waldgesundheit als effektiv erwiesen (Oumar und Mutanga, 2013; Navarro-Cerrillo et al., 2019; Liu et al., 2021). Da Pleiades-Daten nur vier Bänder aufweisen, wurden vier VI einschließlich ARVI, NDVI, GNDVI und RNDVI berechnet. Anschließend berechneten wir den Mittelwert, das Maximum, das Minimum, den Bereich, die Standardabweichung und den Variationskoeffizienten für jeden Layer pro Baumkrone. Wir vermuteten, dass diese Variablen potenziell zwischen den verschiedenen Kategorien von Kronenentlaubungen unterscheiden könnten.

II.3.2.4.4 Datenanalyse

Die Datenanalyse wurde in zwei Stufen durchgeführt: i) eine erste Phase der explorativen Analyse, die sich auf die Bewertung der Unterscheidbarkeit von Schadensklassen durch einen Vergleich von Vegetationsindizes konzentrierte, und ii) eine anschließende Modellierungsphase mithilfe des Random- Forest-Algorithmus. Die Felddaten dienten als Referenz sowohl für Trainings- als auch für Validierungszwecke. Darüber hinaus wurde in der Modellierungsphase die Leistung von vier verschiedenen Klassifizierungsszenarien bewertet, und zwar:

- Szenario 1 mit den ursprünglichen fünf Klassen, die im Feld identifiziert wurden (gesund, leicht geschädigt, mittel geschädigt, stark geschädigt, tot);
- Szenario 2, das die drei Klassen geschädigter Bäume (gesund, leicht geschädigt + mittel geschädigt + stark geschädigt, tot) zu drei Klassen zusammenfasst;
- Szenario 3, das zwischen lebenden und toten Bäumen (gesund + leicht geschädigt + mittel geschädigt + stark geschädigt, tot) in zwei Klassen unterscheidet; und
- Szenario 4, das gesunde und geschädigte Bäume trennt (gesund vs. geschädigt).
Beschädigt: Leicht beschädigt + Mittelstark beschädigt + stark beschädigt + Tot)

II.3.2.4.5 Ergebnisse UAV-Daten

Analyse der Baumgesundheit anhand von Vegetationsindizes

Bei allen VIs wurde ein deutlicher Unterschied zwischen lebenden und toten Bäumen festgestellt, wobei die VI-Werte der lebenden Bäume durchweg höher waren als die der toten Bäume. Ergebnisse zeigten, dass sich die VI-Werte der verschiedenen Klassen überschneiden, wobei die Werte je nach VI und Klasse variieren. Besonders deutlich waren die Überschneidungen zwischen gesunden und leicht geschädigten sowie mittelstark geschädigten Bäumen. Mittelstark und stark geschädigte Bäume wiesen eine größere Überlappung auf, insbesondere bei CIG, PSRI, GNDVI und NDVI, sowie eine größere Streuung im Vergleich zu den anderen Lebendklassen bei den meisten Indizes, mit Ausnahme des ARVI.




Abbildung 18: Konfusionsmatrizen für das RF-Modell (UAVdaten) in vier Klassifizierungsszenarien mit unterschiedlichen Klassen

Die ANOVA-Analyse ergab signifikante Unterschiede bei den VI-Werten zwischen den verschiedenen Klassen.

Mehrfache Mittelwertvergleiche zeigten, dass alle VIs effektiv zwischen toten und lebenden Bäumen unterschieden. Die Ergebnisse des Wilcoxon-Tests deuteten jedoch darauf hin, dass die Unterschiede bei den meisten VIs (mit Ausnahme des ARVI) zwischen mittelstark und stark geschädigten Bäumen nicht signifikant waren. Außerdem wiesen leicht und mittelstark geschädigte Bäume bei den meisten VIs (außer PSRI) keine signifikanten Unterschiede auf.

Klassifizierung der Baumgesundheitsstadien

Bei der Klassifizierung aller Klassen (5 Klassen) erreichte das RF-Modell eine Gesamtgenauigkeit von 66,43% (Abbildung 18), wobei die Genauigkeit für gesunde und abgestorbene Klassen höher war, gefolgt von leicht beschädigten. Die Genauigkeit war für mittel- und stark beschädigte Klassen bemerkenswert schlecht.

Nach dem Zusammenführen der Schadensklassen verbesserte sich die Gesamtgenauigkeit auf 70,26%. Fehlklassifizierungen traten hauptsächlich zwischen Schaden und gesunden Klassen auf, wobei ähnliche Fehlklassifizierungen in Szenario 4 auftraten. Bei der Klassifizierung von lebenden und abgestorbenen Bäumen (Szenario 3) erreichte die Genauigkeit 99,76%, mit vergleichbarer Genauigkeit für abgestorbene Bäume (Producer accuracy (PA) = 0.883; User accuracy (UA) = 1).

Feature importance

VIs spielten in allen Modellen eine entscheidende Rolle, wobei ARVI, NDVI und GNDVI in dem Fünf-Klassen-Modell eine höhere Bedeutung zeigten. In anderen Modellen waren ARVI und GNDVI signifikant. Zusätzlich waren Red Edge Bänder im Fünf-Klassen-Modell wichtig, während das NIR-Band in anderen Szenarien an erster Stelle stand. Statistische Maße wie Bereich, CV und SD hatten ebenfalls eine hohe Bedeutung.

II.3.2.4.6 Ergebnisse – Satellitendaten

Analyse der Baumgesundheit anhand von Vegetationsindizes

Die Unterscheidung zwischen gesunden und leicht oder mittelmäßig geschädigten Bäumen war bei allen VIs offensichtlich. Allerdings wurden erhebliche Überschneidungen zwischen geschädigten und toten Bäumen festgestellt. Sowohl gesunde als auch tote Bäume wiesen bei allen VIs eine starke Überlappung auf. Während die ANOVA-Analyse signifikante Unterschiede bei den VI-Werten zwischen den verschiedenen Klassen ergab, zeigten die Mehrfachvergleiche der Mittelwerte aus dem Wilcoxon-Test, dass die VI-Werte vieler Klassen nicht signifikant waren, insbesondere zwischen mittelstark und stark geschädigten Bäumen. Nur die gesunden und leicht geschädigten Bäume wiesen durchweg signifikante Unterschiede bei allen VI auf. Darüber hinaus deuteten die Ergebnisse des Wilcoxon-Tests darauf hin, dass die Unterschiede bei den meisten VIs (außer ARVI) für mittelstark und stark geschädigte oder tote Bäume statistisch nicht signifikant waren. Außerdem wiesen gesunde und tote Bäume bei den meisten VIs keine signifikanten Unterschiede auf.

Klassifizierung der Baumgesundheitsstadien

Bei der Klassifizierung aller Klassen (5 Klassen) erreichte das RF-Modell eine Gesamtgenauigkeit von 71,7 % (Abbildung 19).




Abbildung 19: Konfusionsmatrizen für das RF-Modell (Satellitendaten) in vier Klassifizierungsszenarien mit unterschiedlichen Klassen

Die Klassifizierungsgenauigkeit für gesunde und leicht beschädigte Klassen war deutlich höher als für die anderen Klassen. Die Genauigkeit für die Klassen mit mittlerer und schwerer Beschädigung war jedoch bemerkenswert schlecht, wobei die Klassen mit mittlerer und schwerer Beschädigung mit den Klassen mit gesunder und leichter Beschädigung deutlich verwechselt wurden. Nach der Zusammenführung der drei Schadensklassen (Szenario 2) verbesserte sich die Klassifizierungsgenauigkeit des RF-Modells und erreichte eine Gesamtgenauigkeit von 77,46%. Es wurden Fehlklassifizierungen und Auslassungen zwischen den Klassen "beschädigt", "gesund" und "tot" beobachtet, was mit den Ergebnissen in Szenario 4 übereinstimmt. Während sich die Klassifizierungsgenauigkeit bei der Klassifizierung von lebenden und toten Bäumen deutlich auf 98,8 % verbesserte, war die Erkennungsleistung für tote Bäume mit einer PA von nur 0,167 gering.

Feature importance

Die Ergebnisse zeigen, dass das blaue Band in den Szenarien 1, 2 und 4 eine wichtige Rolle spielt, gefolgt von der Kombination aus NIR- und grünem Band, die im CIG-Index verwendet wird, sowie dem NIR-Band. Darüber hinaus ist der CIG-Index auch für die Klassifizierung von lebenden und toten Bäumen von großer Bedeutung (Szenario 3). Sowohl die grüne als auch die rote Bandbreite spielen ebenfalls eine entscheidende Rolle bei der Klassifizierung von lebenden und toten Bäumen sowie bei den Modellen zur Unterscheidung zwischen gesunden und geschädigten Bäumen.

II.3.2.4.7 Fazit Fernerkundungsbasierte Analyse

Wir haben statistische und maschinelle Lernmethoden eingesetzt, um die Fähigkeit von hochauflösenden UAV- und Satellitendaten zur Unterscheidung der verschiedenen Gesundheitszustände von Bäumen zu bewerten. Die Ergebnisse zeigen, dass UAV und Satellitendaten eine relativ gute Genauigkeit bei der Unterscheidung zwischen gesunden und geschädigten Bäumen erreicht, aber sowohl das UAV als auch die Pleiades-Bilder eine suboptimale Leistung bei der Unterscheidung zwischen verschiedenen Schadenskategorien zeigen. Bei den Satellitenbildern war es aufgrund der begrenzten Verfügbarkeit von Bildern nicht möglich, von beiden Standorten Bilder für den gleichen Zeitraum zu bekommen. Mehrere Aufnahmen (am besten Zeitreihen) vom Beginn bis zum Ende der Vegetationsperiode wären ideal gewesen, sind aber derzeit nicht Verfügbar. Sentinel-2-Zeitreihen mit einer sehr groben Auflösung konnten in unserer Analyse nicht verwendet werden.

II.3.3 Ergebnisse Partner GWDG

II.3.3.1 Internes Projektmanagement (GW1)

Das Ziel des Arbeitspaketes war ein effizientes internes Projektmanagement. Dieses umfasst allgemeine Verwaltung und Organisation sowie die externe Repräsentation auf Fachkonferenzen. Die Ziele wurden alle erreicht.

MS1 Organisation

Die GWDG war maßgeblich beteiligt für die Einrichtung von effizienten Kommunikationsstrukturen. Dies beinhaltet die Bereitstellung und Einrichtung des Projekts auf der Dokumentationsplattform OpenProject, die auch eine Aufgabenverwaltung ermöglicht, sowie die Einrichtung eines Mailverteilers.

II.3.3.1.1 MS1 Zwischenbericht

Der Zwischenbericht wurde pünktlich eingereicht. Es wurde klar kommuniziert, dass eine Verschiebung der Prioritäten hinsichtlich der Auswertung der Electronic Nose zu der Entwicklung der neuronalen Netze stattfinden wird.

II.3.3.1.2 MS1 Fachkonferenz

Die Forschungsergebnisse wurden in der Form eines Papers dargestellt und weitere Ergebnisse auf einer Fachkonferenz (ISC High Performance) dargestellt.

II.3.3.1.3 MS2 Organisation

Die Kommunikationskanäle wurden beibehalten.

II.3.3.1.4 MS2 Zwischenbericht

Der Zwischenbericht wurde pünktlich eingereicht.

II.3.3.1.5 MS2 Fachkonferenz

Weitere Forschungsergebnisse wurden auf verschiedenen Fachkonferenzen dargestellt (ForestSAT, NHR-Konferenz). Es ergab sich ein reger Austausch mit der Forschungsgemeinschaft insbesondere auf der ForestSAT, welche zu Zusammenarbeit mit weiteren Kooperationspartnern geführt hat. Darüber hinaus wurde das Projekt für ein EU-weites Strategiepapier aufgeführt, im Rahmen der Lehre für einen Workshop genutzt und eine Masterarbeit im Projekt ermöglicht. Die vollständige Liste aller Publikationen ist im Kapitel Publikationen aufgeführt.

II.3.3.2 Algorithmus Electronic Nose Auswertung (GW2)

Das Ziel des Arbeitspaketes Algorithmus Electronic Nose Auswertung war die Auswertung der Sensordaten der auf der Drohne befestigten Electronic Nose (MS1) unter Berücksichtigung des Windes (MS2). Wie im ersten Zwischenbericht bereits angekündigt, erfolgte eine Verschiebung der Prioritäten zwischenzeitlich zugunsten Arbeitspaket GW4, da eine unzureichende Datenlage für eine Auswertung inklusive Windkorrektur vorlag.

II.3.3.2.1 MS1 Heatmap und Quellbäume

Der verfügbare Datensatz der Electronic Nose wurde in einer Heatmap visualisiert. Diese ist eingebettet in das geographische Koordinatensystem. Allerdings lagen keine Winddaten vor, sodass eine Korrektur noch nicht erfolgen konnte.

II.3.3.2.2 MS2 Windkorrigierte Heatmaps

Aus Ermangelung an Daten hinsichtlich der Windkorrektur war ein weiteres Ausbauen der Windkorrektur nicht möglich. Unsere Aktivitäten verschoben sich, wie auch mit dem Projektgeber kommuniziert, zugunsten von GW4.

II.3.3.3 HPC Serversupport (GW3)

Das Ziel des Arbeitspaketes HPC Serversupport war die Bereitstellung von Ressourcen und Datenverarbeitungskapazitäten hinsichtlich Storage, HPC und Cloud-Computing. In diesem Arbeitspaket wurden alle Ziele erreicht.

II.3.3.3.1 MS1 Serversupport für Datenupload und Datenverarbeitung

Unser Support gliedert sich in die Bereitstellung von Storage, von Computing-Ressourcen und deren Schnittstelle. Für den Datenupload wurde allen Projektpartnern mittels der ownCloud-Plattform ein einfach zu bedienendes Frontend bereitgestellt. Durch die von uns geschriebenen Skripte wurde die Spiegelung der Daten auf das HPC System, auf welchen weiteren Analysen stattfanden, vorgenommen. Dieser Prozess wurde benutzerfreundlich gestaltet, insbesondere im Hinblick auf ein versehentliches Löschen von Rohdaten. Ergebnisse konnten so zurück in die Owncloud geschrieben werden, die Rohdaten, welche von der ownCloud auf das HPC-System gespiegelt wurden, konnten aber nicht zurück überschrieben werden. Zusätzlich wurden regelmäßige Backups der Daten auf dem HPC-System gemacht, um einen Datenverlust zu vermeiden. Hinsichtlich der Datenverarbeitung wurden alle notwendigen Ressourcen zur Datenanalyse bereitgestellt. Dies beinhaltet eine HPC-Umgebung, welche das Training von neuronalen Netzen und anderen rechenintensiven Aktivitäten ermöglicht. Für die notwendigen Skriptsprachen (R, Python) wurden zusätzliche Services (JupyterHub, RStudio) bereitgestellt.

Darüber hinaus wurden Lizenzen für die Software Agisoft Metashape besorgt und auf dem Cluster installiert, sodass alle Partner für Orthomosaik die HPC-Umgebung nutzen konnten.

II.3.3.3.2 MS2 Nutzung der Ressourcen

Die Ressourcen wurden weiterhin bereitgestellt. Hinsichtlich der Software und Hardware wurden weitere Verbesserungen vorgenommen. Auf dem Cluster wurde eine weitestgehend automatisierte Pipeline gebaut, sodass oben genannte Software Agisoft Metashape parallelisiert nutzbar gemacht wurde. Dies führte zu einer Optimierung der Laufzeit. Beispielsweise konnte durch Parallelisierung die Berechnung der Orthomosaik von mehreren Tagen auf wenige Stunden verkürzt werden. Dieser Workflow steht auch in der Zukunft auf dem Cluster bereit.

Darüber hinaus wurde die Pipeline hinsichtlich des Arbeitspaketes GW4 verbessert. Dies beinhaltet eine Datenqualitätsanalyse (Pixelwertkontrolle und Kurtosisbetrachtung), welche die Inputdaten der neuronalen Netzwerke automatisch auf Ausreißer oder nicht zulässige Werte kontrolliert. So konnten korrupte Dateien und Ausreißer herausgefiltert werden. Darüber hinaus entwickelten wir eine erste quantitative Datenanalyse, die mit allen Projektpartnern geteilt wurde.

Hinsichtlich der Hardware wurde Anfang 2023 mit der Bereitstellung von zusätzlichen A100 GPUs das Training der neuronalen Netzwerke deutlich beschleunigt. Auf diesen wurde auch die Orthomosaikberechnung für die Partner durchgeführt. Durch die Nutzung der neuen Hardware wurde zudem der Nachhaltigkeitsfokus des Projektes gestärkt, da die angeschafften GPUs deutschlandweit die energieeffizientesten Rechner sind (siehe Green500-Benchmark).

II.3.3.4 Entwicklung Artificial/deep convolutional NN (GW4)

Das Ziel des Arbeitspakets GW4 war die Entwicklung von neuronalen Netzen, die Baumzustände anhand einer Einzelbaumanalyse durchführen können. In diesem Arbeitspaket wurden alle Ziele erfüllt. In Ermangelung an ausreichend Daten verbleiben einige Ergebnisse der Datenanalyse optimierbar. Bei weiteren Datenerhebungen können die entwickelten Pipelines genutzt werden.

II.3.3.4.1 MS1 Algorithmenauswahl und Trainingsbeginn

Es wurden verschiedene Architekturen von neuronalen Netzen, insbesondere von pretrained convolutional neural networks, betrachten und hinsichtlich ihres Potenzials ausgewertet. Alle Architekturen (Alexnet, VGG16, ResNet, Inceptionv3) können in PyTorch auf den Grafikprozessoren genutzt werden. Die Pipeline, bestehend aus Data-Loading, Datenqualitätscheck und Training, für das supervised learning wurde fertiggestellt.

Da allerdings an diesem Zeitpunkt trotz der üblichen Data-Augmentation-Techniken noch nicht genügend Daten für ein sinnvolles Training vorhanden waren, wurde eine Evaluation von Deep Learning Methoden und Explainable AI anhand eines öffentlichen Blätterdatensatz vorgenommen.

II.3.3.4.2 MS2 Abschluss DeepNN-Entwicklung

Die Auswertung hinsichtlich Baumvitalität und Artenerkennung wurde mit den vorhandenen Daten abgeschlossen. Es wurden Arten und Zustand anhand der Orthophotos klassifiziert.

Der Datensatz umfasste uns alle zur Verfügung stehenden Daten, insgesamt, nach Eliminieren von korrupten Daten, 1041 Bäume. Es wurden die Netzwerke AlexNet und VGG16 genutzt (als Foundation Models mit vortrainierten Gewichten und ohne vortrainierte Gewichte).

Die Erkennung zwischen Laub- und Nadelbäumen liegt bei 64%, was besser als Zufall ist, aber durch mehr Trainingsdaten deutlich verbessert werden könnte. Für die Klassifizierung des Zustands (gesund vs. nicht gesund, wobei als gesund alles bis leichter Schaden gefasst wird) beträgt die Genauigkeit 60%. Da eine hohe Imbalance zwischen Laub- und


Nadelbäumen bestand (nur 135 Laubbaume), wurden letztere von der Zustandsanalyse ausgeklammert. Auch hier sind mehr Daten notwendig, um eine bessere Klassifizierung zu erreichen. Die aufgebaute Pipeline ermöglicht ein zusätzliches Laden von LiDAR Daten für jeden Datenpunkt. Da vortrainierte Netzwerke hinsichtlich von Baum-LiDAR-Daten in der Forschung nicht für unseren Nutzungsfall zu finden waren, priorisierten wir den Aufbau eines synthetischen Datenflows, welcher das Vortrainieren von Netzen für den multimodalen Anwendungsfall vorbereitet und auch von anderen Forschern eingesetzt werden kann.

II.3.4 Ergebnisse Partner GISCON

II.3.4.1 Parametrische Analyse (GC2)

Es war zunächst zu prüfen, in welcher Form eine Parametrische Analyse mit den Bestandesdaten durchgeführt werden kann, da ihren Merkmalen keine numerischen Werte, sondern Kategorien zugewiesen wurden. Für die Anforderungen an eine Parametrische Analyse ist jedoch erforderlich, dass die Daten normalverteilt, linear abbildbar sind und über dieselben Intervalle verfügen. Für die Auswahl der zu untersuchenden Parameter wurden dann anhand der GIS-Karten die multi-dimensionalen Datensätze für jeden Einzelaspekt heruntergebrochen und visualisiert. Es eigneten sich nicht alle untersuchten Parameter für eine weitere statistische Analyse, da es sich um einen relativ gesunden Baumbestand handelte und die Anzahl der betroffenen Bäume sehr gering ist. Insgesamt waren von 987 Einzelbäumen (290 Laub- und 697 Nadelbäume) Begehungsdaten verfügbar, sie wurden von den Projektpartnern zur Verfügung gestellt.

Von den 290 erfassten Laubbäumen wiesen 222 in allen Merkmalen keine oder nur eine leichte Schädigung auf, 68 Laubbäume sind in mindestens einem Merkmal mittel oder schwer geschädigt.




Laubbäume

1ForestCare18_03_2022_2_Laub_gesundUndLeichterSchaden_vs_mittlererUndStarkerSchaden [290]

● laub_gesund_leichterSchaden [222]

● laub_mittlerer_schwerer_Schaden [68]

Von den 697 Nadelbäumen wiesen 509 in keinem Merkmal eine Schädigung oder nur eine leichte Schädigung auf, während 188 Nadelbäume in mindestens einem Merkmal mittel bis schwer geschädigt waren. Insgesamt galten für die weitere Untersuchung von den 987 Einzelbäumen 156 als geschädigt.



Nadelbäume

1ForestCare18_03_2022_2_Nadel_gesundLeichterSchaden_vs_mittlererSchwererSchaden [697]

◆ nadel_gesund_leichter_Schaden [509]

◆ nadel_mittlerer_schwerer_Schaden [188]

Da der Datenbestand der Begehungsdaten nicht-normalisiert war, wurde im Arbeitspaket „Parametrische Analyse“ eine nicht-parametrischen Analyse vorgenommen, die aber ebenfalls eine Korrelationsanalyse ermöglicht, solange die untersuchten Schadensmerkmale in ausreichender Anzahl vorkommen. Die Chi-Quadrat-Analyse ist ein statistisches Verfahren, das verwendet wird, um zu bestimmen, ob es einen signifikanten Unterschied zwischen erwarteten und beobachteten Häufigkeiten in einem Datensatz gibt.


Die Chi-Quadrat-Analyse basiert auf der Berechnung der Differenz zwischen den erwarteten und beobachteten Häufigkeiten in einem Datensatz, die quadriert und durch die erwarteten Häufigkeiten dividiert wird. Der resultierende Wert wird als Chi-Quadrat-Statistik bezeichnet. Wenn dieser Wert groß genug ist, wird angenommen, dass die Abweichung zwischen den beobachteten und erwarteten Häufigkeiten signifikant ist und es besteht ein Zusammenhang zwischen den untersuchten Variablen.

Das Verfahren wird hier verwendet, um zu testen, ob die Ausprägungen zweier Merkmale der Datensätze korrelieren.


Das im Rahmen des Arbeitspakets „Parametrische Analyse“ erstellte Programm dient der Berechnung von Vegetationsindizes für jedes Pixel einer Rasterkarte.

Der Ablauf beim Verwenden der erstellten Software ist wie folgt:


Auswahl der Analyse-Funktion aus der Werkzeugleiste




Auswahl des Vektor-Layers für die Analyse



Auswahl der Attribute für die Korrelationsanalyse




Berechnung der beobachteten Werte




Spalten und Zeile für die Aggregation auswählen, da eine Mindestanzahl der Ausprägungen eines Merkmals von 4 erreicht sein muss.


Wie hier an der rot eingefärbten Zahl zu erkennen ist, ist die Mindestanzahl der Ausprägungen für ein Merkmal nicht erreicht. Da es sich aber nur um Testdaten handelt, wird die Vorgehensweise der Datenanalyse im Folgenden dennoch erläutert.



Berechnung der erwarteten Werte



Berechnung und Interpretation des Chi-Square-Wertes




Mit dieser Software konnten aus den Begehungsdaten Korrelationen ermittelt werden zwischen:

- Stamm- und Kronenschäden
- Baumtyp und Einzelschaden
- Baumart und Einzelschaden
- Einzelschaden des Stammes mit Einzelschaden der Krone (nach Baumtypen getrennt)
- Beliebiger Einzelschaden mit beliebigem Einzelschaden (nach Baumtypen getrennt)

II.3.4.2 Entwicklung Artificial NN Baumvitalität (GC3)

Eingangsdaten sind Rasterbilder mit RGB-Kanälen und einem NIR-Kanal. Da hier ausschließlich Baumkronen relevant sind, kann man im GIS eine Verschneidung mit Baumpolygonen vornehmen, die Baumpolygone wurden von unseren Projektpartnern zur Verfügung gestellt. Dadurch reduziert sich die Berechnungszeit und die Datenmenge erheblich.

1. Sentinel 2-Rasterkarte mit RGB-/NIR-Kanälen



2. Sentinel 2-Rasterkarte mit RGB-/NIR-Kanälen und Vektorkarte mit Baumpolygonen



3. Rasterkarte als Ergebnis der Verschneidung von 1. und 2. Diese Karte dient als Eingangskarte für die hier aufgeführten Berechnungen.




Im ersten Entwurf ist die Berechnung der Vegetationsindizes MCARI/OSAVI und NVDI implementiert. Dabei werden für jedes Pixel der Eingangskarte die RGB/NIR-Werte sowie die Positionsdaten ausgelesen und die zuvor ausgewählten Vegetationsindizes berechnet. Basiskarten hierfür sind eine Mehrkanal-Rasterkarte und eine Vektorkarte mit Baumpolygonen, aus denen eine Baummaske verschnitten wurde, Ergebniskarte ist wiederum eine Rasterkarte. Die weiteren Operationen sind zwar auch auf einer Mehrkanal-Rasterkarte ohne Verschneidungsoperation möglich, wären aber rechenintensiv und unnötig, da uns hier nur die Vegetationsindizes der Baumvegetation interessieren.


MCARI/OSAVI ist eine Variante des Modified Chlorophyll Absorption in Reflectance Index (MCARI), der den Optimal Soil-Adjusted Vegetation Index (OSAVI) enthält. MCARI/OSAVI ist ein zweiteiliger Vegetationsindex, der robuster gegenüber Bodenhintergrundeffekten ist und die Empfindlichkeit gegenüber Chlorophyllgehalt im Vergleich zu MCARI allein verbessert. Die OSAVI-Komponente des Index ist eine modifizierte Version des bodenbereinigten Vegetationsindex (SAVI), der den Einfluss der Bodenreflexion auf die Vegetationsindizes reduzieren soll. OSAVI optimiert SAVI weiter, indem es den Bodenhintergrundeffekt basierend auf dem Reflexionsgrad des blauen Bands anpasst.

Der Normalized Difference Vegetation Index (NDVI) wird mithilfe von Satelliten- oder Luftbildern berechnet, um den Zustand und die Dichte der Vegetation zu bewerten und zu überwachen. Es misst den Unterschied zwischen dem roten und dem nahen Infrarot (NIR)-Band des elektromagnetischen Spektrums. Die NDVI-Werte reichen von -1 bis 1, wobei Werte nahe -1 auf nicht bewachsene Flächen hinweisen (z. B. Wasser oder nackter Boden), Werte nahe 1 auf dichte und gesunde Vegetation hinweisen und Werte um 0 auf wenig oder keine Vegetation hinweisen. NDVI wird in verschiedenen Anwendungen eingesetzt, beispielsweise in der Land- und Forstwirtschaft, der Umweltüberwachung und der Landbewirtschaftung. Es hilft bei der Identifizierung von Bereichen mit Vegetationsstress, Dürre, Krankheiten oder anderen Faktoren, die die Pflanzengesundheit beeinträchtigen. NDVI-Daten können auch zur Schätzung der Vegetationsbiomasse, zur Verfolgung von Landbedeckungsänderungen und zur Bewertung der Wirksamkeit von Vegetationsmanagementpraktiken verwendet werden.


Der Ablauf beim Verwenden der erstellten Software ist wie folgt:



Auswahl der Analysefunktion aus der Werkzeugleiste




Auswahl des Vektorlayers für die Analyse




Auswahl des zu berechnenden Vegetationsindizes. Informationen zu den möglichen Indizes können über den Info-Button abgerufen werden. Der Dialog kann hier mit weiteren Vegetationsindizes erweitert werden. Die Software kann dazu in einer weiteren Version ein Eingabeformular zur Verfügung stellen.

Beim Erstellen der Ergebniskarten wird für jeden ausgewählten Vegetationsindex ein Layer mit dem Geometrietyp „Punkt“ erzeugt, der die Werte des Index für jeden Pixel des Ausgangslayers berechnet. Im Hintergrund werden hier die Baumpolygone in neongrün dargestellt. Die Ergebnislayer werden dann softwareseitig über Standard-Werte der Vegetationsindizes kategorisiert.


Ergebniskarte MCARI/OSAVI



Ergebniskarte NDVI



Zur weiteren Visualisierung der Ergebnisse werden automatisch Boxplots für jeden ausgewählten Vegetationsindex erzeugt



Die Software-Komponenten für die Berechnung der statistischen Analyse und der Vegetationsindizes bieten für die GISCON Systems GmbH die Grundlage für eine weitere Produktentwicklung.

II.3.5 Ergebnisse Partner con-terra

Ziel des Verbundvorhabens war es, mit Hilfe von Drohnen- und Satellitenbilddaten Merkmale einzelner Bäume, wie Entlaubung, Borkenkäferbefall oder Stammform zu identifizieren, um das Waldwachstum auf regionaler Ebene mit Methoden der künstlichen Intelligenz (KI) zu bewerten und Wiederbewaldungsmaßnahmen standortoptimiert zu unterstützen. Das Training der KI erfordert Zieldaten, die den Eingangsdaten der Drohnen gegenübergestellt werden. Ziel des Arbeitspakets CT2, mit dem die con terra GmbH betraut wurde, war die Entwicklung einer KI-basierten App zur Einzelbaumzustandserfassung zum Aufbau einer umfangreichen, qualitativ hochwertigen Datenbasis.

In der ersten Projektphase wurde eine erste Version der Erfassungssapp für die notwendige in situ Datenerfassung vor Ort implementiert. Dazu wurde auf Basis von map.apps und map.apps FGL offline eine individuelle App implementiert, in der die erfassten Baumstandorte und Attribute angezeigt, kontrolliert und editiert werden können. Dank der bestehenden Software-Komponenten der con terra konnte die App mit sehr geringem Entwicklungsaufwand bereitgestellt werden. Die dafür beantragten Lizenzkosten konnten nicht wie beantragt abgerechnet werden und wurden später im Projekt umgewidmet.

In Zusammenarbeit mit den Projektpartnern (AWI, FeLIS) wurden die zu erfassenden Parameter definiert und anhand dieser das Datenmodell erstellt. Die erfassten Einzelbäume wurden als Punktgeometrien angelegt, die neben dem Standort und der Baumart auch Parameter für den BHD (Brusthöhendurchmesser) und Stamm- (z.B. Drehwuchs, Zwiesel, Käferbefall) sowie Kronenparameter (z.B. Vitalität, Verlichtung) enthalten.

Die Anbindung einer elektronischen Kluppe per Bluetooth-Verbindung zur Bestimmung des BHD wurde eingerichtet, sodass per Klick an der Kluppe das entsprechende Feld in der App für den BHD befüllt wird. Die Anbindung einer GNSS-Antenne zur präzisen Verortung wurde eingerichtet. Das Signal der verwendeten GeoMax-Antenne wurde über das GPS Gate abgriffen und direkt an die App weitergeleitet, sodass die Punktgeometrie am aktuellen Standort der Antenne angelegt wird. Zur Datenhaltung und Qualitätssicherung wurde eine virtuelle Maschine aufgesetzt, ein ArcGIS Server für den benötigten Feature Service eingerichtet sowie gegen unbefugten Zugriff mittels security.manager abgesichert. Dank des Rollensystems im security.manager konnten den verschiedenen Projektpartnern schreibende (Datenerfassung) bzw. lesende Rechte (Weiterverarbeitung der Daten) zugeordnet werden, um eine gute Datenqualität sicherzustellen.

Auch eine erste Version der offline verfügbaren, KI basierten Spracherkennung zur Unterstützung der Datenaufnahme wurde früh im Vorhaben erstellt. Dafür wurde zunächst ein bestehendes offline ASR-System integriert und die benötigten Schlüsselwörter mittels Mapping zugeordnet. Diese Umsetzung erlaubte auch synonyme Wortbezeichnungen, die das gleiche Kommando ausführen. Beispielsweise konnte statt „Vitalität leichter Schaden“ auch „wenig Schaden“ ausgesprochen werden, was das Feld für Vitalität gleichermaßen befüllte.

Die zentrale Instanz ermöglicht darüber hinaus seitens der weiteren Partner und Arbeitspakete den Zugriff auf die erhobenen in situ Daten (AI5, FE5, GW4, GC2-4).

Der Zeitplan konnte gut eingehalten werden, sodass eine Zustandserhebung der Einzelbäume inkl. genauer Verortung schon früh im Vorhabenszeitraum möglich war (AI3, FE2). Im weiteren Verlauf des Vorhabens wurde die Erfassungssapp optimiert und Projektpartner bei ihrer Arbeit unterstützt. Insbesondere die Genauigkeit der GNSS-Antenne im Wald und die Übertragung des Signals an die App wurden in mehreren Iterationen optimiert. Zunächst wurden dafür die Genauigkeiten des Base-Rover und Rover-Rover Setups miteinander verglichen. Außerdem wurden die im GPS-Gate abkommenden Signale verglichen. Auch wurde die App mit einer Genauigkeitsanzeige ausgestattet, sodass die aufnehmende Person entscheiden kann, ob die Position ausreichende Genauigkeit aufweist. Schlussendlich wurde auch ein nachträgliches Editieren des Standorts erlaubt. Dies war vor allem dann hilfreich, wenn ein Orthophoto vom zu erfassenden Gebiet vorlag, mit dem der Standort des Baums abgeglichen werden konnte. Basierend auf den Rückmeldungen und Erfahrungen der mit den Außenaufnahmen betrauten Personen wurde auch die KI basierte Sprachsteuerung sukzessive verbessert und hinsichtlich

des forstlichen Fachvokabulars optimiert (AI3, FE2). Der anfängliche Mapping-Ansatz, der bei komplexeren Erfassungsmasken an seine Grenzen stößt, konnte im weiteren Projektverlauf von einem Ansatz abgelöst werden, bei dem ein vortrainiertes ASR-System mit einfachen Mitteln nachtrainiert werden kann. Dafür war es ausreichend, das Sprachmodell nachzutrainieren, sodass forstliches Fachvokabular und hier insbesondere die in der Erfassungssapp benötigten Begriffe, erkannt werden. Dafür wurde ein Textkorpus erstellt, der die zu erkennenden Begriffe und Sprachkommandos enthält, aber darüber hinaus auch allgemeines Vokabular, um falsch positive Ergebnisse zu vermeiden.

Die Erkennungsqualität wurde durch diesen Ansatz um ein Vielfaches gesteigert. Die Erkennungsqualität lässt sich in diesem Kontext nur schwer quantifizieren, da sie auch stark von Faktoren wie Sprecher (Geschlecht, Alter, Akzent), Hardware (insb. Mikrofon) und der Geräuschkulisse im Wald (z.B. Kettensäge) abhängt. Dass dieser Ansatz dennoch sehr erfolgreich ist, war zu Beginn des Vorhabens nicht klar und offenbarte sich erst durch eine umfassende Marktanalyse und Verprobung verschiedener ASR-Systeme. Da dieses Feld noch sehr innovativ ist, ist die Situation sehr dynamisch und hatte sich im Vergleich zum Projektbeginn bereits verändert. Diese Arbeiten konnten dank der kostenneutralen Projektlaufzeitverlängerung und Umwidmung von Material- in Personalkosten (s.o.) durchgeführt werden.

Damit konnte im Rahmen des Vorhabens erstmals eine offline-fähige KI-Spracherkennung in einer auf con terra Technologies basierende Erfassungssapp implementiert werden, die es ermöglicht, domänenspezifisches Fachvokabular in deutscher Sprache einzusprechen und damit eine effiziente Datenerfassung zu unterstützen. Kartierende haben so bei ihrer Arbeit die Hände frei und sind nicht gezwungen, zwischen Mess- und Eingabegerät zu wechseln. Damit ist die Aufnahme einer deutlich größeren Anzahl von Kontrollpunkten im ausgewählten Zeitraum im Vergleich zu bisherigen Verfahren möglich. Akustisches und visuelles Feedback unterstützen darüber hinaus die Datenerhebung und helfen, Fehler zu minimieren.

Der gewählte Ansatz ist für weitere App-Umsetzungen auf Basis von con terra Technologies nachnutzbar. Im Sinne des Verwertungsplans ist geplant, das Spracherkennungsmodul weiterzuentwickeln und in weitere map.apps Lösungen zu integrieren. Dafür laufen bereits Gespräche mit Kunden der con terra, eine Lösung wurde bereits beauftragt, eine weitere befindet sich für den Landesforst MV bereits in der Umsetzungsphase.

Der Hauptteil der Fördermittel wurde verwendet, um die entstandenen Personalkosten zu decken. Diese sind bei der Implementierung der App inklusive Einrichten der VM, des Dienstes etc., Entwicklung der offline-fähigen Sprachsteuerung und Unterstützung der Projektpartner entstanden.

Ursprünglich beantragte Mittel zur Deckung von Lizenzkosten für con terra technologies konnten nicht abgerechnet werden. Die Mittel wurden im Rahmen der kostenneutralen Projektlaufzeitverlängerung in Personalkosten umgewidmet, sodass eine umfassende Marktanalyse bestehender ASR-Systeme und Optimierung der individuellen offline-fähigen KI Spracherkennung für forstliches Fachvokabular ermöglicht wurden. Da das Feld der KI-Spracherkennung sich rasant entwickelt und stets neue, viel versprechende Systeme den Markt erreichen, war die nachträgliche Marktanalyse und Umstellung des verwendeten ASR-Systems notwendig. Beispielhaft ist das Whisper-Modell des OpenAI Consortiums zu nennen, welches im Vorhabenszeitraum veröffentlicht und daher verprobt wurde. OpenAI hat durch den Chatbot ChatGPT viel Aufsehen erregt und auch im Bereich der ASR vielversprechende Ansätze veröffentlicht. Zum jetzigen Zeitpunkt eignen sich die multilingualen, meist großen Modelle jedoch nicht für den mobilen Einsatz im Wald. In Zukunft ist damit zu rechnen, dass OpenAI auch für den mobilen Einsatz passende, deutschsprachige Modelle bereitstellt. Ob diese für den Forst adaptiert werden können, müsste ebenfalls geprüft werden.

Reisekosten fielen für einen Besuch in Göttingen an, um die Erfassungssapp zusammen mit dem Projektpartner (AWI) zu testen. Materialkosten fielen für die virtuelle Maschine an, auf der der ArcGIS Server lief, um die erhobenen Daten qualitätsgesichert und zugriffsgeschützt abzulegen.

III. Zusammenarbeit mit anderen Stellen außerhalb des Verbundprojektes

Die Zusammenarbeit mit externen Stellen außerhalb des Verbundprojektes war von entscheidender Bedeutung für den Erfolg des Projekts FOREST^{CARE}. Durch die Kooperation mit verschiedenen Partnern konnten wir unser Wissen erweitern, Ressourcen bündeln und Synergien schaffen, die es uns ermöglichten, innovative Lösungen zu entwickeln und komplexe Herausforderungen zu bewältigen.

Zu den bedeutenden Kooperationen zählten die gemeinsamen EU-Anträge AlteroX und EcoSentinel, die im Wesentlichen Robotik-Entwicklungen für den Wald waren. Diese Projekte ergänzten und erweiterten die Forschungsbemühungen von FOREST^{CARE}, indem sie zusätzliche Ressourcen und Expertise in verwandten Bereichen wie der Umweltüberwachung und der nachhaltigen Landwirtschaft einbrachten. Durch die enge Zusammenarbeit konnten wir gemeinsame Ziele verfolgen und von den Erfahrungen und Erkenntnissen anderer Projekte profitieren.

Ein weiterer wichtiger Partner war das Fraunhofer WKI im Rahmen eines VDI-Antrags zu einem Forensikthema mit Drohnen und E-Nose. Diese Zusammenarbeit ermöglichte es uns, neue Anwendungen und Technologien im Bereich der forensischen Untersuchungen zu erdenken.

Des Weiteren arbeiteten wir eng mit Experten zusammen, um das PVY-Kartoffelpflanzenvirus zu analysieren. Diese Kooperation ermöglichte es uns, unsere Forschungsergebnisse in einen breiteren Kontext zu stellen und die Auswirkungen von Krankheiten auf landwirtschaftliche Nutzpflanzen besser zu verstehen. Durch den Austausch von Daten und Erkenntnissen konnten wir neue Erkenntnisse gewinnen und zur Entwicklung effektiverer Bekämpfungsstrategien beitragen.

Zusätzlich zu diesen Projekten wurde auch mit dem Lehrstuhl für Geoinformatik an der Universität Würzburg zusammengearbeitet, was zur Veröffentlichung von Forschungsergebnissen führte.

Diese Zusammenarbeit ermöglichte es uns, unsere Ergebnisse einem breiteren Publikum zugänglich zu machen und den wissenschaftlichen Austausch zu fördern. Eine weitere Publikation ist derzeit in Arbeit, was zeigt, dass die Zusammenarbeit mit externen Partnern kontinuierlich fortgesetzt wird und neue Erkenntnisse hervorbringt.

Über den Partner GWDG haben wir neben intensiven Diskussionen auf Fachkonferenzen auch einen Austausch mit Stuart Krause vom Thünen-Institut organisiert, einem Experten im Bereich der dronenbasierten Fernerkundung für das Monitoring von Wäldern. Zusätzlich waren wir in engem Kontakt mit Jannika Schäfer vom KIT und Hans Henniger vom UFZ für die Entwicklung eines Ansatzes zur Erzeugung synthetischer LiDAR-Daten.

Schließlich haben wir auch am runden Tisch Digitalisierung der FNR zum Thema KI mitgewirkt. Diese Zusammenarbeit ermöglichte es uns, unsere Expertise im Bereich der künstlichen Intelligenz einzubringen und an der Entwicklung von Richtlinien und Strategien zur Förderung der Digitalisierung in der Forstwirtschaft mitzuwirken. Durch den Austausch von Ideen und Erfahrungen konnten wir dazu beitragen, die Zukunft der Forstwirtschaft zu gestalten und innovative Lösungen für die Herausforderungen von morgen zu entwickeln.

IV. Veröffentlichungen, Vorträge Referate, etc.

1. Anwander, J., Brandmeier, M., Paczkowski, S., Neubert, T., & Paczkowska, M. (2024). Evaluating different deep learning approaches for tree health classification using high-resolution multispectral UAV data in the Black Forest, Harz region, and Göttingen Forest. **Remote Sensing, 16**, 1-21.
2. Paczkowski, S. (2024). Vitalitätsmonitoring von Pflanzen mit Hilfe von Gassensoren. Praxisforum „Intelligenter Pflanzenschutz“, Alte Mensa, Göttingen, 11.03.2024.
3. Dæhlen, M. (2023). Insight Paper: The Twin Transition Century - The role of digital research for a successful green transition of society? **The Guild Insight Paper No. 5**. doi:10.48350/184458.
4. Doosthosseini, Ali; Kirchner, Hauke; Sommer, Dorothea; Kunkel, Julian (2023). Large-Scale Synthetic Forest Point Cloud Generation on HPC Systems. **NHR Conference 2023**, Zuse Institute Berlin, Sep. 2023.
5. Farby, Irina; Stöcker, Martin (13-2023): FORESTCARE – Datenerhebung im Wald per Sprachsteuerung. Hg. v. AFZ DerWald. Online verfügbar unter https://www.digitalmagazin.de/marken/afz-derwald/hauptheft/2023-13/aktuell-produktschau/046_forestcare-datenerhebung-im-wald-per-sprachsteuerung, zuletzt aktualisiert am 02.07.2024, zuletzt geprüft am 02.07.2024.
6. Paczkowski, S. (2023). Von elektronischen Nasen und Drohnen: Ein digitales Waldökosystemmonitoring (ForestCare). DigitalGreenTech Konferenz, Bundesministerium für Bildung und Forschung, Karlsruhe, 17-18.10.2023.
7. Neubert, T., & Paczkowski, S. (2023). Dronenbasierte Frühdetektion von Borkenkäferbefall mit Hilfe von Geruchssensor und multispektralen Kameras. Forstwissenschaftliche Tagung, Dresden, 11.09.2023.
8. Hüttnerová, T., Paczkowski, S., Neubert, T., Jirosová, A., & Surový, P. (2023). Comparison of Individual Sensors in the Electronic Nose for Stress Detection in Forest Stands. **Sensors, 23**, 1-16.
9. Paczkowski, S. (2023). Implementierung eines drohnengestützten Borkenkäferfrühdetektionsverfahrens in die forstliche Praxis. Copernicus Nutzerkonferenz, Copernicus Netzbüro Wald, Thünen-Institut, Braunschweig, 30.03.2023.
10. Cheng, X., Doosthosseini, A., & Kunkel, J. (2022). Improve the Deep Learning Models in Forestry Based on Explanations and Expertise. **Frontiers in Plant Science**. doi:10.3389/fpls.2022.902105.
11. Kirchner, Hauke; Müller, Dorothea; Doosthosseini, Ali; Kunkel, Julian; Paczkowski, Sebastian. (2022). Monitoring Forest Quality Using Satellite and Drone Data. **ForestSAT Association for Forest Spatial Analysis Technologies**, Freie Universität (FU) Berlin, Sep. 2022.

12. Müller, Dorothea; Doosthosseini, Ali; Gronberg, Hauke, Paczkowski, Sebastian; Kunkel, Julian (2022). Monitoring Forest Quality Using Satellite and Drone Data.
ISC High Performance, Hamburg, Mai 2022.
13. Paczkowski, S. (2022). Implementierung eines drohnengestützten Borkenkäferfrühdetektionsverfahrens in die forstliche Praxis. Statusseminar Digitalisierung Forst und Holz, Fachagentur für Nachwachsende Rohstoffe, Bundesministerium für Ernährung und Landwirtschaft, Kassel, 10.11.2022.
14. Paczkowski, S. (2022). Von elektronischen Nasen und Satelliten-Daten: Ein digitales Waldökosystemmonitoring (ForestCare). DigitalGreenTech Konferenz, Bundesministerium für Bildung und Forschung, Göttingen, 07.11.2022.
15. Kirchner, H., & Sommer, D. (2022). Forests in HPC [Workshop], GWDG Göttingen, 13.12.2022.
16. Speckenwirth S (2024); Instance segmentation at single tree level using multispectral UAV images, Masterthesis supervised by Prof. Dr. Melanie Brandmeier, Dr. Sebastian Paczkowski, at the technical university Würzburg-Schweinfurt, Attendorn, February 19, 2024
17. Sommer, D., Meisel, T., & Kirchner, H. (2022, 2023, 2024 - geplant). Deep learning with GPU cores [Workshop], GWDG Göttingen - ForestCare as use case.
18. Doosthosseini, A. (2023). Enhancing Tree Segmentation in Large Forest Point Clouds with Synthetic Data, GWDG Göttingen. (Masterarbeit - unveröffentlicht).