

## FINT-CH (Find individual trees in CH)

Grossflächige Erfassung von Waldstrukturen und dazugehörigen Kennzahlen mittels Waldstrukturabgrenzung und Einzelbaumdetektion basierend auf luftgestützten Fernerkundungsdaten

### Projekt-Schlussbericht

AutorInnen: Luuk Dorren, Gaspard Dumollard, Alexandra Erbach, Hannes Horneber, Manuel Kurt, Dominik May, Christian Rosset, Christoph Schaller (alle BFH-HAFL)  
Christian Ginzler, Christoph Fischer, Lars Waser, Dominique Weber (alle WSL)  
Peter Bebi (WSL-SLF)

Auftraggeber: Bundesamt für Umwelt BAFU, Kanton BE, BS/BL, GR, LU, SO, VD, VS, Fürstentum Liechtenstein, SBB

Datum: 04.06.2021

## Versionen

Version	Datum	Status	Bemerkungen
0.1	04.06.2021	Entwurf	-

## Danksagung

Wir danken das Bundesamt für Umwelt BAFU, die Kantone BE, BS/BL, GR, LU, SO, VD und VS, das Fürstentum Liechtenstein sowie die SBB für die finanzielle Unterstützung. Weiter geht unser Dank an die Projektbegleitgruppe (alle Auftraggeber sowie der Forstbetrieb der Burgergemeinde Bern) für die Projektbetreuung und an Julia Menk für ihren Beitrag am Code für die Aufbereitung der Referenzdaten.

## Zitervorschlag

Dorren L., Bebi P., Dumollard, G., Erbach A., Fischer C., Ginzler C., Horneber, H., May, D., Rosset C., Schaller C., Waser L., Weber D. (2020). FINT-CH (Find Individual Trees Schweiz) - Grossflächige Erfassung von Waldstrukturen und Kennzahlen mittels Waldstrukturabgrenzung und Einzelbaumdetektion basierend auf luftgestützten Fernerkundungsdaten. *Projekt-Schlussbericht BFH-HAFL Zollikofen, WSL Birmensdorf/Davos*: 56 p.

# Inhaltsverzeichnis

<b>1. Einleitung</b>	<b>1</b>
<b>2. Allgemeine Projektmethodik</b>	<b>3</b>
2.1. Gelieferte Produkte . . . . .	4
<b>3. Definition der Waldstrukturtypen</b>	<b>5</b>
<b>4. Verwendete Daten</b>	<b>7</b>
4.1. Daten für die Vegetationshöhenmodelle (VHM) . . . . .	7
4.2. Referenzdaten für die Einzelbaumdetektion (EBD) . . . . .	7
<b>5. Bestimmung des Mischungsgrades</b>	<b>9</b>
<b>6. Abgrenzung der Waldstrukturtypen</b>	<b>11</b>
6.1. Funktionsweise TBk . . . . .	11
6.2. Resultate . . . . .	12
<b>7. Detektion der Einzelbäume</b>	<b>17</b>
7.1. Methodik der Einzelbaumdetektion (EBD) . . . . .	17
7.2. Ergebnisse der EBD . . . . .	19
<b>8. Fallbeispiele</b>	<b>31</b>
8.1. Fallbeispiel 1: Lokalisieren dominanter FINT-CH Bäume . . . . .	31
8.2. Fallbeispiel 2: Kartierung von Lücken im Wald . . . . .	42
8.3. Fallbeispiel 3: Automatische Kartierung von potenziellen Anrissgebieten im Lawinen-Schutzwald . . . . .	45
8.4. Fallbeispiel 4: Bestimmung der Waldgrenze . . . . .	48
<b>9. Schlussfolgerungen und Ausblick</b>	<b>51</b>
<b>Literaturverzeichnis</b>	<b>55</b>
<b>A. Anhang - Boxplots mit Detektionsraten</b>	<b>57</b>
<b>B. Anhang - QQ-Plots der EBD</b>	<b>59</b>



# 1. Einleitung

Daten aus luftgestütztem Laserscanning (auf Englisch: Airborne Laser Scanning oder abgekürzt ALS) haben ein grosses Potenzial für die quantitative Charakterisierung von Waldstrukturen und dazugehörigen Kennzahlen wie Stammzahl, Grundfläche und Deckungsgrad. Die aus ALS ableitbaren rasterbasierten Vegetationshöhenmodelle (VHM) finden dabei eine breite Verwendung (siehe z.B., [1]; [2]; [3]). Für die Einzelbaum-Detektion (EBD) werden potenzielle Kronenspitzen mithilfe der lokalen Höhenwertmaxima im VHM extrahiert. Verschiedene Arbeiten (z.B., [4]; [5]) haben aktuelle, auf ALS-Daten beruhende Methoden der EBD im alpinen Raum untersucht. Daraus lässt sich schliessen, dass der kronenspitzenorientierte Ansatz mit lokalen Höhenmaxima gute Ergebnisse liefert, er aber noch verbessert werden kann durch die Berücksichtigung der Waldstruktur in den verwendeten Detektionsalgorithmen.

Neben dem Nutzen von ALS-Daten für die EBD sind diese Daten auch geeignet für die Ermittlung von Bestandesgrenzen. Dies kann erreicht werden mit dem an der HAFL entwickelten Toolkit zur Erarbeitung von Bestandeskarten (TBk). Neben den Bestandesgrenzen werden gleichzeitig die Oberhöhe (hdom) und der Deckungsgrad pro Bestand ermittelt. Diese abgeleiteten Daten bieten eine gute Grundlage für eine waldstrukturabhängige EBD. Durch Zusammenfügen von Bestandesgrenzen und Einzelbaumdaten können detaillierte Geodaten und Karten (im Massstab 1:5'000 bis 1:10'000) mit Informationen zu Stammzahl, Deckungsgrad und Baumhöhenverteilungen der detektierten Bäumen und Waldlücken erstellt werden. In Kombination mit den frei verfügbaren Sentinel-2 Satellitenbildern lässt sich zudem der Mischungsgrad (Laub- und Nadelholzanteil) pro Bestand bestimmen (Weber et al., 2018). Zudem lassen sich mit diesen Daten und statistischen Beziehungen abgeleitet von LFI-Daten auch Grundfläche und Vorrat pro Bestand schätzen.

Dieses Projekt zielt auf eine grossflächige Anwendung (> 700'000 ha) der oben beschriebenen Methoden in den Kantonen BE, BS/BL, GR, LU, SO, VD, VS, dem Fürstentum Liechtenstein sowie auf zusätzlichen Waldflächen der SBB ab, welche in ihrer Gesamtheit als Projektgebiete bezeichnet werden. Indem das FINT-CH Projekt auf die EBD basierend auf ALS-Daten aufbaut, ist es komplementär zu den Fernerkundungsansätzen, die im Rahmen des Schweizerischen Landesforstinventars (LFI) durchgeführt werden und in welchen Lücken, Biomasse und Holzvorrat auf Basis von Luftbilddaten abgeschätzt werden. Die Ansätze im FINT-CH Projekt sind, in Gegensatz zu denen im LFI, einzelbaumbasiert.

Das Ziel des FINT-CH Projektes ist es, eine Methodik zu entwickeln, womit auf Basis von Fernerkundungsdaten (ALS-basierten Vegetationshöhenmodellen und Sentinel-2-Bildern) folgende Informationen geliefert werden können:

- Flächige Informationen zu Waldstrukturen und deren Abgrenzungen sowie relevante waldbauliche Kenngrössen (z.B. Oberhöhe, Deckungs- und Mischungsgrad)
- Position, Höhe und BHD der dominierenden und ko-dominierenden Einzelbäume

Dieser Bericht beschreibt die verschiedenen Arbeitspakete, welche im Projekt durchgeführt wurden. Dabei wird jedes Arbeitspaket in einem eigenen Kapitel erklärt.



## 2. Allgemeine Projektmethodik

Auf Basis von ALS-Daten wurden mit dem Tool TBk [6] in den Projekt-Kantonen (BE, BL/BS, GR, LU, SO, VD, VS) sowie auf den übrigen SBB-Waldflächen flächendeckend Bestandesgrenzen erzeugt. Als Grundlage dafür dient die räumliche Verteilung der vorherrschenden Bäume (gekennzeichnet durch die maximale Höhe pro Are eines Vegetationshöhenmodells), sowie der Mischungsgrad, welcher mit Hilfe der bestehenden LFI Mischungsgraddaten, verbessert mit Sentinel-Bildanalyse, bestimmt wird.

Jeder Bestand wurde einem Waldstrukturtyp (WST) zugewiesen, welche im Detail in Kapitel 3 beschrieben sind.

Pro WST wird ein eigenes Set von Regeln für die Einzelbaumdetektion mit Hilfe des Tools FINT (siehe Menk et al. 2017) aufgestellt. Diese Regeln werden auf Basis von den in Kapitel 4 beschriebenen Kalibrierungsdaten

Für jeden abgegrenzten Bestand in den Projektgebieten werden auf Basis der Detektionsregeln Einzelbäume in Abhängigkeit der Ausprägung der Einzelkrone im Kronendach detektiert. Damit können i.d.R. die vorherrschenden, herrschenden und mitherrschenden Bäume detektiert werden (vgl. soziale Stellungen 1, 2 und 3 in Abb. 2.1 mit den Baumklassen nach [7]). Zum Teil können auch beherrschte Bäume mit zwischenständigen Kronen (4a) detektiert werden, nicht aber diejenigen mit teilweise unterständigen Kronen (4b) oder unterständige Bäume (5). Die Einzelbaumdaten werden zur Validierung aggregiert und mit LFI-Daten für den betreffenden WST verglichen. Schlussendlich werden pro WST statistische Beziehungen zwischen den LFI-Daten und den erzeugten aggregierten Einzelbaumdaten hergeleitet, damit jeweils näherungsweise sowohl die Stammzahl, die Grundfläche als auch der Vorrat pro Bestand bestimmt werden können. In der Schlussphase des Projektes werden 4 Fallbeispiele zur Verwendung der generierten Daten in der Praxis ausgearbeitet.

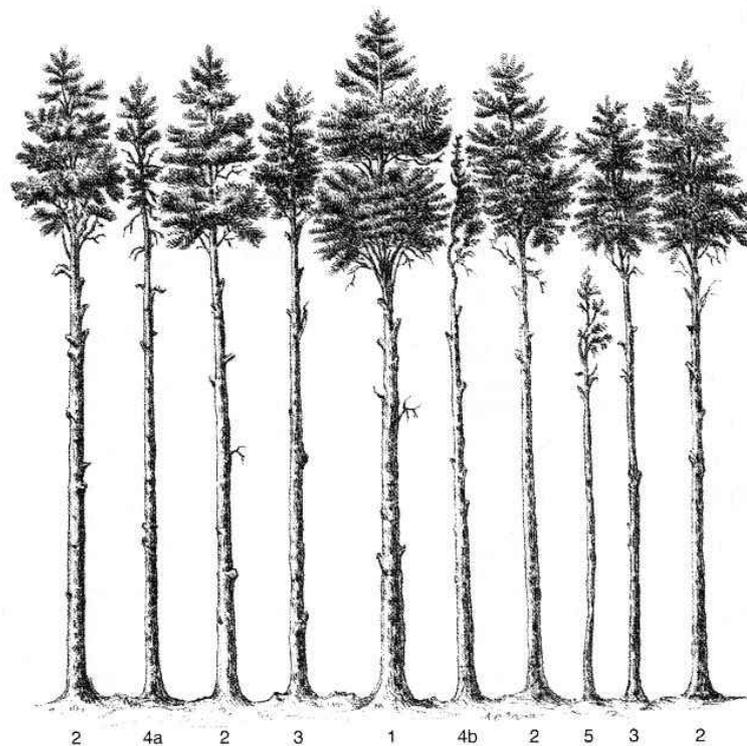


Abbildung 2.1.: Darstellung der Baumklassen nach [7]

## 2.1. Gelieferte Produkte

Zusätzlich zum Bericht werden die im Folgenden aufgelisteten Geodaten an alle Projektpartner zur Verfügung gestellt.

- Bestandesgrenzen (Vektor-Geodaten, Typ Polygon) mit u.a. den Attributen:
  - Grundform (gleichförmig, ungleichförmig)
  - Deckungsgrad
  - Bestandes-Oberhöhe hdom
  - Nadelholzanteil
  - Stammzahl der Oberschicht
  - Grundfläche der Oberschicht basierend auf statistischen Beziehungen mit LFI-Daten
  - Schätzung der Stammzahl, der Grundfläche und des Vorrats basierend auf statistischen Beziehungen mit LFI-Daten
- Detektierte Einzelbäumen (Vektor-Geodaten, Typ Punkt) mit u.a. den folgenden Attributen:
  - Baumhöhe
  - BHD (basierend auf statistischen Beziehungen aus Inventur-Daten)
  - X- und Y-Koordinate
- Waldlücken, Schneisen und Waldgrenzen (Vektor-Geodaten, Typ Polygon)
- Mischungsgrad (Raster-Geodaten)
- Vegetationshöhenmodell (Raster-Geodaten)

Die entwickelte Methodik soll einfach und grossflächig zu verwenden sein und die Möglichkeit bieten, alle 5 bis 10 Jahre kostengünstig (deutlich weniger als 1 CHF/ha) wiederholt zu werden. Die produzierten Daten des FINT-CH Projekts sollen verbesserte Grundlagen für verschiedenste walddrelevante Themen wie betriebliche Planung, Waldbau und Schutzwaldanalyse bieten.

### 3. Definition der Waldstrukturtypen

Die Grundidee des FINT-CH Projekts war, Walsstrukturtypen (WST) aus allen sinnvollen Kombinationen der folgenden Variablen zu definieren:

- LFI Vegetationshöhenstufen (tiefer als subalpine, subalpine)
- Mischungsgrad (MG; Nadelholzanteil: < 30 %, 30 – 70 %, > 70 %)
- Deckungsgrad (DG; offen < 50 %, 50 – 80 %, geschlossen > 80 %)
- Oberhöhe (hdom im VHM: < 8 m, 8 - 18 m, 18 - 32 m, > 32 m)

Damit würde mit 72 WST gearbeitet werden. Nach mehreren Analysen der vorliegenden Referenzdaten aus LFI und den Martelskopen, bzw. LWF-Flächen (siehe Kap. 3), kamen wir zum Schluss, dass für viele von diesen 72 WST keine Referenzdaten vorliegen. Darum wurden schlussendlich, nach Diskussion mit allen Projektmitarbeitenden und in Abprache mit den Projektpartnern, folgende WST für das FINT-CH Projekt festgelegt:

Tabelle 3.1.: Erklärung der Kodierung der Waldstrukturtypen (WST)

WST-Kodeziffer	Variable	Bereich	Wert
1	Mischungsgrad (MG; Nadelholzanteil)	< 30 % (Laubwald)	1
		30 – 70 % (Mischwald)	2
		≥ 70 % (Nadelwald)	3
2	Deckungsgrad (DG; siehe Kap. 6)	< 80 %	1
		≥ 80 %	2
3	Oberhöhe (hdom)	< 22 m	1
		≥ 22 m	2

Somit entspricht der WST-Code *112* einem Laubwaldbestand mit einen Deckungsgrad von weniger als 80% und einer Oberhöhe von min. 22m. Die WST werden v.a. in der Darstellung der Ergebnisse der Einzelbaumdetektion (EBD; s. Kap. 7) verwendet.



## 4. Verwendete Daten

### 4.1. Daten für die Vegetationshöhenmodelle (VHM)

Für die Aufbereitung der Vegetationshöhenmodelle (VHMs) wurden auf die aktuellsten LiDAR Datensätze zugegriffen, welche für die beteiligten Projektgebiete zur Verfügung standen. Einzig der Kanton Luzern konnte für das Projekt die Roh – Punktdaten nicht zur Verfügung stellen, sondern wir bekamen das fertig gerechnete Vegetationshöhenmodell, zugeschnitten auf die Waldfläche des Kantons.

Die LiDAR Daten waren zumeist Daten der kantonalen Befliegungen mit Punktdichten grösser als 15 Punkten pro Quadratmeter. Wallis und Graubünden haben keine eigenen kantonalen Daten. Hier wurden die Daten der ersten landesweiten LiDAR Befliegung von swisstopo aus den Jahren 2005 und 2003 verwendet.

Die Roh – Punktdaten wurden in einem ersten Schritt normalisiert. Bei vorhandener Punktklassifikation nach den ASPRS Klassen wurde die Klasse 'Bodenpunkte' für das Gelände verwendet. Bei den älteren oder nicht klassifizierten Daten das aktuelle SwissAlit3D von swisstopo. Bei der Normalisierung wurde für jeden der Milliarden Punkte die Höhe über Boden berechnet. Gebäude wurden anhand der ASPRS Klassifikation entfernt. Bei fehlender Klassifikation wurden die Gebäudedaten des Topographischen Landschaftsmodells TLM von swisstopo für die Elimination der Gebäude verwendet. In diesen normalisierten Punktwolken können Statistiken für die Vegetation ermittelt werden.

Aus den normalisierten Punkten der LiDAR Daten wurden mittels LAsTools Rasterdaten mit einer Auflösung von 1 x 1m gerechnet. Dabei wurden die Punkteklassen 'Boden' und 'Vegetation' verwendet und alle anderen Punkteklassen (wie zum Beispiel 'Overlap', 'unclassified', 'noise') ausgeschlossen. Bei den Punktwolken der nationalen Kampagne von swisstopo wurde die Punktklasse "Gebäudeausgeschlossen" und alle anderen Punkte verwendet. Es wurde für jede Rasterzelle der höchste LiDAR Punkt verwendet. Bei lokal zu geringer Punktdichte wurden die Lücken linear interpoliert. Für alle Projektgebiete wurden die Daten mit einem Buffer von 1 km berechnet. Für einen Vergleich wurden für jedes Projektgebiet mit einem Buffer von 1 km auch die Daten des Vegetationshöhenmodells LFI ausgeschnitten. Dieser Datensatz ist allerdings für eine Extraktion von Einzelbäumen im Wald nicht geeignet. Die weiteren Analysen waren auf Vegetationshöhenmodelle basierend auf LiDAR Daten beschränkt.

Der Zeitpunkt der Aufnahme der LiDAR Daten und die Punktdichten (Punkte pro Quadratmeter) unterscheiden sich zwischen den kantonalen und den swisstopo Datensätzen (Tabelle 4.1)

Tabelle 4.1.: Verwendete LiDAR Daten zur Berechnung der Vegetationshöhenmodelle

Gebiet	Aufnahmejahr	Mittlere Punktdichte
BE	2011/2012/2013	16.7
BL/BS	2018	44.3
FL	2015	mindestens 4
GR	2003	1.3
LU	2018	mindestens 16
SO	2014	43.2
VD	2015	16.4
VS	2001/2005	1.3

### 4.2. Referenzdaten für die Einzelbaumdetektion (EBD)

Untenstehende Daten (mit den dazugehörigen Quellen, Anzahl Flächen F und Anzahl vermessene Bäume n) wurden zusammengetragen als Referenz für die Kalibrierung der EBD:

- LFI4 (LFI; F=5560; n=63812)

Nachfolgende Daten wurden für die Validierung der EBD verwendet:

- Marteloskope (Fachstelle Waldbau FWB; F=13; n=5047)
- Ertragskundeflächen EFM (WSL; F=34; n=33412)
- Langfristige Waldökosystemforschung LWF (WSL; F=20; n=19851)
- Placettes Permanentes de Suivi Sylvicole PPSS (HAFL; F=52 ; n=6455)
- Marteloskope im Gebirgswald (HAFL; F=4; n=2677)

Diese Datenbank enthält zu allen Bäumen (n = 131'251) mindestens folgende Informationen: X- und Y-Koordinate; BHD, Baumart, Quelle, Aufnahmejahr. Für ca. 30% der aufgenommenen Bäume lag eine Information zur Baumhöhe vor.

## 5. Bestimmung des Mischungsgrades

Der schweizweite Datensatz zum Mischungsgrad (Laub-/Nadelholzanteil) des schweizerischen Landesforstinventars LFI (Waser et al. 2017) wurde für das FINT-CH Projekt überarbeitet und aktualisiert. Während der LFI Datensatz auf digitalen Luftbildern basiert, wurden diesmal Satellitendaten vom Europäischen Copernicus Programm der ESA, Sentinel-1 /-2 verwendet. Diese sind kostenlos verfügbar, haben eine räumliche Auflösung von 10 m und liefern innerhalb weniger Tage wieder Aufnahmen vom gleichen Gebiet – vorausgesetzt aber, es ist wolkenlos. Da dies aber für grössere Gebiete, vor allem solche mit ausgeprägtem Relief, schwierig sein kann, werden neben den optischen Satellitendaten von Sentinel-2 auch wetterunabhängige Mikrowellendaten von Sentinel-1 Synthetic Aperture Radar (SAR) miteinbezogen. Zugleich konnte somit auch die Topographie und einstrahlungsbedingte Schattenproblematik bei optischen Bildern minimiert werden. Letztere führt grundsätzlich zu Problemen bei Klassifikationsverfahren - in unserem Fall wäre dies eine Überschätzung der Nadelbäume in schattigen Gebieten.

Im Rahmen des FINT-CH Projektes wurden zur Bestimmung des Mischungsgrades von Sentinel-1 SAR sowohl Aufnahmen vom März (3 Aufnahmen vom unbelaubten Zustand) und August (2 Aufnahmen vom belaubten Zustand) verwendet (siehe Tab. 5.1). Der Sentinel-2 Datensatz basiert auf einem Mosaik von wolkenfreien Bildern, die während der Hauptvegetationszeit aufgenommen wurden. Damit ein wolkenfreies Mosaik aller Untersuchungsgebiete erstellt werden konnte, wurden insgesamt 354 Einzelaufnahmen verwendet. Da für jedes Pixel mehrere Aufnahmen zur Verfügung standen, wurde anschliessend der Median pro Pixel verwendet. Für das weitere Verfahren wurden vor allem diejenigen Bänder verwendet, welche die spektralen Bereiche zur optimalen Vegetationserkennung abdecken. Es sind dies die Bänder mit einer räumlichen Auflösung von 10 m (B2-B4; B8) und 20 m (B5–B7 B8A, B11, B12). Als zusätzliche Inputdaten (Variablen) wurde das SwissAlti3D Geländemodell von swisstopo verwendet, um Informationen zur Topographie zu erhalten. Um die Klassifikation durchzuführen, wurden alle verwendeten Datensätze auf eine räumliche Auflösung von 10 m harmonisiert. Die Trainingsdaten bestehen aus Laub- und Nadelbaumgruppen, welche aus Luftbildern digitalisiert wurden, wie sie auch in [8] für den ersten Datensatz "LFI Waldmischungsgrad der Schweiz" verwendet wurden. Eine Übersicht zu den verwendeten Daten ist in Tabelle 5.1 gegeben.

Als Klassifikationsverfahren wurde der robuste und vielfach bewährte Random Forest (RF) Algorithmus angewendet (z.B. [9]). Damit die Überschätzung der Nadelgehölze in schattigen und steilen Gebieten vermindert werden konnte, wurden die Untersuchungsgebiete in drei unterschiedliche Hangneigungskategorien (0-10°, 10-30°, >30°) sowie acht verschiedene Expositionsklassen (N, NE, E, SE, S, SW, W, NW) eingeteilt. Daraus resultierten 24 (3x8) RF Modelle, die entsprechend trainiert und validiert wurden.

Tabelle 5.1.: Übersicht der verwendeten Inputdaten. Angegeben sind Datenquelle, abgeleitete Variablen, räumliche Auflösung, Anzahl sowie deren Aufnahmezeitpunkte.

Quelle	Variablen	Räumliche Auflösung	Anzahl Datensätze	Aufnahmezeitpunkt
Sentinel-1	VV, VH, backscatter	20 m	10	Leaf-off: 2015, 2016, 2017
Sentinel-2	B2-B4, B8,	10 m	4	Leaf-on: 2016, 2017, 2018
Sentinel-2	B5-B7, B8A, B11, B12	20 m	6	
SwissAlti3D	Meereshöhe, Hangneigung, Exposition	1 m	20	(Jun-Sep) 2015 - 2018
Laub-/ Nadelpolygone	-	-	~35'000 Laub- und 40'000 Nadelpixel	2017

Die Modellgenauigkeiten waren allgemein hoch und bewegten sich zwischen 0.9 und 0.95 (Gesamtgenauigkeit) sowie 0.88 und 0.91 (Kappa) (Tabelle 5.2). Die produzierten Karten weisen so für jedes Pixel eine Laubholzwahrscheinlichkeit (0-100%) auf (siehe Figure 5.1). Für eine übersichtlichere Darstellung wurde der Datensatz auf das Vegetationshöhenmodell (VHM) ausgeschnitten und beinhaltet nur Gehölze, die höher als 3 m sind.

Tabelle 5.2.: Übersicht der erzielten Genauigkeiten nach Kanton.

Genauigkeit	BL/BS	BE	GR	LU	SO	VD	VS
Overall	0.95	0.93	0.93	0.94	0.94	0.94	0.93
Kappa	0.92	0.89	0.88	0.90	0.92	0.90	0.90

Die Rückmeldungen zur Karte des Mischungsgrades von den beteiligten Partnern waren recht positiv. Die grössten Abweichungen zu Feldbegehungen waren in Mischbeständen zu finden. Der Mischungsgrad stimmt in reinen Beständen etwas besser als in Mischbeständen. Zudem ist eine leichte Tendenz zur Überschätzung von Nadelgehölzen in schattigen Gebieten immer noch zu beobachten. Der Mischungsgrad Schweiz wird zurzeit im Rahmen einer vierjährigen Dissertation mit einer Karte der Hauptbaumarten ergänzt.

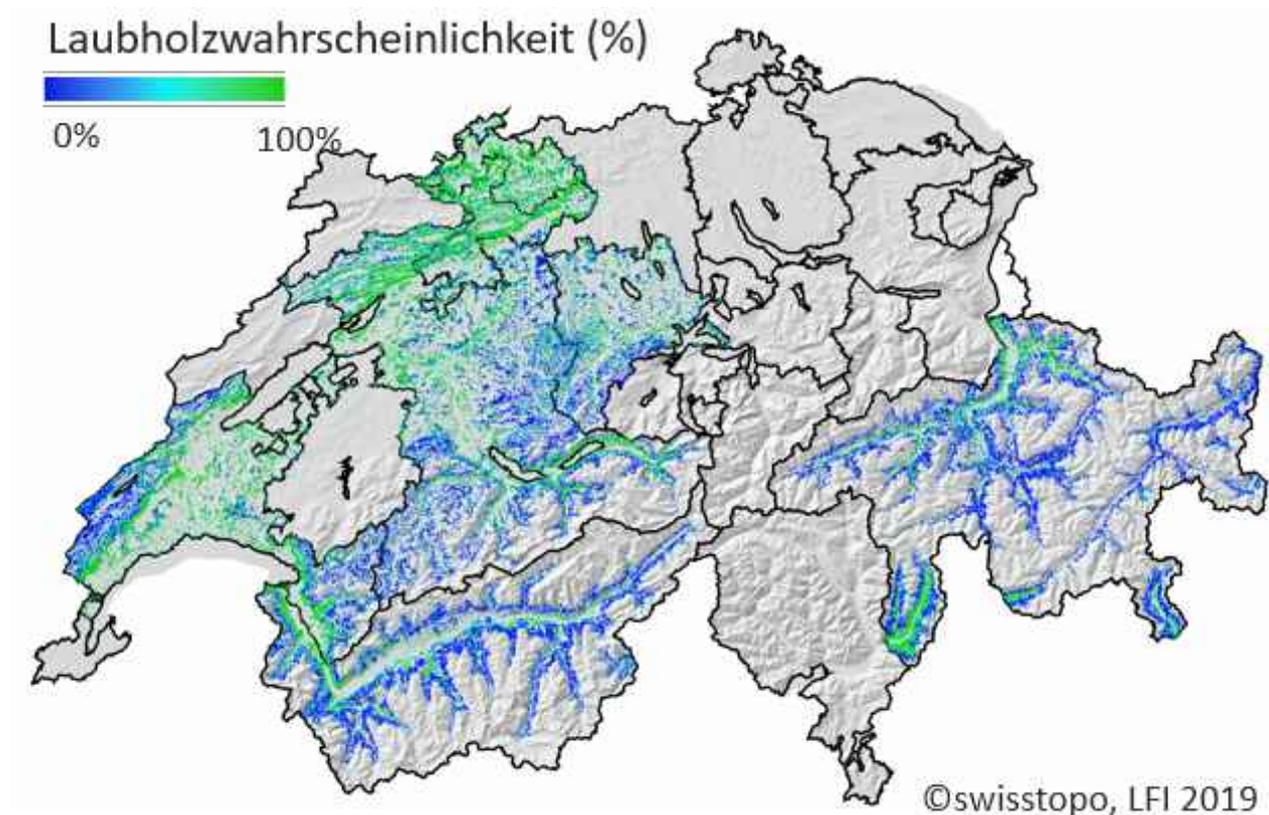


Abbildung 5.1.: Laubholzwahrscheinlichkeit für die 7 Kantonsgebiete.

## 6. Abgrenzung der Waldstrukturtypen

Die Abgrenzung der verschiedenen Waldstrukturtypen basiert auf Bestandesgrenzen, die mit einem regelbasierten Algorithmus (TBk: Toolkit Bestandeskarte; [6]) generiert wurden. Dieser basiert primär auf Open-Source Bibliotheken und ist in Python implementiert. Die Abgrenzung der Bestände erfolgt aufgrund der räumlichen Verteilung der dominierenden Bäume bzw. aufgrund der maximalen Höhe pro Are eines Vegetationshöhenmodells.

Im Rahmen des FINT-CH Projektes wurde diese Analyse flächig für alle Projektflächen durchgeführt. Dabei wurde der Algorithmus dahingehend erweitert, dass für die Bestandesabgrenzung zusätzlich der Mischungsgrad (aus AP5) berücksichtigt wurde. Weiter wurden verschiedene Nachbearbeitungsschritte (z.B. Vereinfachung der Bestandesgrenzen), welche in der ersten Version des Tools noch manuell durchgeführt werden mussten, automatisiert. Auch die Vorverarbeitung des Vegetationshöhenmodells sowie des Mischungsgradlayers wurden in Python implementiert und in separaten Funktionen in das Toolkit integriert. Dadurch konnte der gesamte Ablauf der automatisierten Bestandesbildung mittels TBk standardisiert werden.

Im Folgenden werden die Funktionsweise des Tools sowie sein Output kurz vorgestellt.

### 6.1. Funktionsweise TBk

#### 6.1.1. Input-Daten

Als Inputdaten werden eine Waldmaske als ESRI Shapefile, ein möglichst hochaufgelöstes ( $\leq 1$  m) Vegetationshöhenmodell (VHM) sowie ein Waldmischungsgrad-Raster mit Angaben zu Laub-/Nadelholz benötigt.

Die aktuelle, im Rahmen des FINT-CH Projektes verbesserte TBk-Version enthält zwei separate Skripte zur Vorbereitung der Raster-Inputdaten. So wird das VHM auf 10 m aggregiert, auf die Waldmaske zugeschnitten und Ausreisser in den Werten werden korrigiert. Der Mischungsgradlayer wird am VHM ausgerichtet und, falls nötig, von 0-100 reklassifiziert, so dass pro Pixel der Nadelholzanteil in Prozent beschrieben wird.

#### 6.1.2. Algorithmus

Die Bestandesabgrenzung basiert auf einem sogenannten "Region Growing" Verfahren. Dabei werden innerhalb eines sich bewegenden Fensters ("Moving Window") nebeneinander liegende Pixel mit ähnlicher Vegetationshöhe gruppiert. Diesen "Clustern" wird dann jeweils eine Bestandesnummer zugewiesen und sie werden mit grundlegenden Bestandesattributen wie der Oberhöhe ergänzt. Dieser Ansatz basiert auf dem traditionellen Konzept der Bestandesabgrenzung und folgt klaren, aus forstlicher Perspektive verständlichen Regeln. Die Vegetationshöhe dient dabei als Proxy für die Entwicklungsstufe. Fenstergrösse und Schwellenwerte werden relativ zur Oberhöhe festgelegt, um altersabhängige Unterschiede in der Bestandesstruktur zu berücksichtigen.

Die primäre Eingangsgrösse für die Bestandesabgrenzung ist ein Vegetationshöhenmodell (VHM). Dabei ist eine grobe Auflösung von 10 m zweckdienlich, um auf die vorherrschenden Bäume eines Bestandes zu fokussieren und Fehler aufgrund von Variabilität innerhalb der Krone zu reduzieren. Angefangen mit dem höchsten Wert des 10-m-VHMs werden alle Pixel mit absteigenden Werten iterativ durchgegangen. Jeder Pixel wird als möglicher Kristallisationspunkt für einen neuen Bestand betrachtet, sofern er nicht schon zugewiesen wurde. Die Anzahl an Iterationen ist somit begrenzt und der Algorithmus ist auch für grosse Gebiete effizient.

Für alle potenziellen Kristallisationspunkte werden die folgenden beiden Schritte in zwei sukzessiven, iterativen Durchläufen (äussere und innere Schleife) durchgeführt:

1. Innerhalb eines quadratischen Fensters, dessen Seitenlänge vom Wert des potenziellen Kristallisationspunktes abhängt, werden "Pixel-Kandidaten" innerhalb eines benutzerdefinierten Toleranzbereiches (in Bezug auf die Vegetationshöhe) ausgewählt. Falls eine minimale Anzahl an solchen Pixeln (die Standardeinstellung ist 50%) gefunden wird, werden sie als Kandidaten für einen neuen Bestand gekennzeichnet und der Region Growing Prozess läuft weiter (siehe Schritt 2). Anderenfalls wird der nächste potenzielle Kristallisationspunkt prozessiert.
2. Alle Kandidaten-Pixel werden anhand der in Schritt 1 aufgeführten Kriterien daraufhin überprüft, ob sie als "Wachstumskerne" (Kristallisationspunkte) für den gleichen Bestand dienen können. So wird die Liste potenzieller Wachstumskerne stetig reduziert, und zugleich werden neue Kandidaten-Pixel von validen Wachstumskernen zur Liste hinzugefügt. Dies wird solange wiederholt, bis keine Kristallisationspunkte mehr gefunden werden. Für die finale Ausscheidung eines Bestandes wird eine benutzerdefinierte minimale Anzahl an Kandidaten-Pixeln benötigt. Anderenfalls wird die Nummerierung entfernt und der nächste Kristallisationspunkt wird prozessiert.

Im Anschluss wird wiederum der Pixel mit dem höchsten Wert im Waldgebiet gesucht, der nicht schon zu einem erfassten Bestand gehört, danach beginnt der Prozess von vorne. Der gesamte Prozess wiederholt sich solange, bis möglichst alle Pixel des Waldgebietes genau einem Bestand zugewiesen sind.

In einem ersten Durchlauf wird dabei die Bestandesabgrenzung für Reinbestände gemacht, das heisst ein Kristallisationspunkt ist entweder Laub- oder Nadelholz, und ein Kandidaten-Pixel muss dann auch mindestens  $< 50\%$  oder  $> 50\%$  dieser Klasse sein. Im Anschluss wird die Bestandesabgrenzung in einem zweiten Durchlauf ohne Berücksichtigung des Mischungsgrades für alle Pixel durchgeführt, die bis anhin noch nicht klassifiziert wurden.

Etwaige Restflächen werden, falls ein Nachbarbestand mit einer ähnlichen Oberhöhe existiert, diesem hinzugefügt, und sonst als Restflächen gelassen und gekennzeichnet.

### 6.1.3. Nachbearbeitungsschritte

Nach der eigentlichen Bestandesabgrenzung werden einige Nachbearbeitungsschritte durchgeführt. Dadurch wird die Bestandeskarte besser lesbar und mit wertvollen Attributen angereichert. Kleine Bestände werden, sofern möglich, einem grösseren angrenzenden Bestand mit ähnlicher Oberhöhe hinzugefügt. Die Bestandesgrenzen werden geglättet und an die verwendete Waldmaske angepasst. Die finalen Bestände werden mit Informationen zum Deckungsgrad, Mischungsgrad und zur Grundstruktur angereichert (siehe Abschnitt Resultate). Dabei wird für die Ermittlung des Deckungsgrades auf das hochaufgelöste VHM zurückgegriffen, um eine hohe Genauigkeit zu erreichen.

## 6.2. Resultate

Pro Bestand werden die Oberhöhe ( $h_{dom}$ ), die maximale Höhe ( $h_{max}$ ) und der Deckungsgrad (DG) der Hauptschicht ermittelt und gemeinsam als ESRI Polygon Shapefile zur Verfügung gestellt. Zusätzlich kann die Grundstruktur (gleichförmig oder ungleichförmig) der Bestände grob bestimmt werden. Dabei wird der Deckungsgrad der Haupt-, Mittel- und Unterschicht innerhalb eines Bestandes mithilfe des hochaufgelösten VHM ermittelt und für die Ausscheidung von ungleichförmigen Beständen verwendet. Zudem wird der Laub- ( $\leq 20\%$ ) bzw. Nadelholzanteil ( $\geq 80\%$ ) pro Bestand grob geschätzt. Eine Beschreibung sämtlicher Attribute findet sich in Tabelle 6.1. Abbildung 6.1 zeigt das Beispiel einer TBK-Bestandeskarte für den Williwald im Kanton Bern.

Tabelle 6.1.: Beschreibung der Attribute der TBk Bestandeskarte

Attribut	Beschreibung	Zusatzinformation
ID	ID des Bestandes	Wird der Reihe nach vergeben, beginnend mit dem Bestand mit dem grössten hmax (Kristallisationspunkt, technisches Attribut).
nr	Bestandesnummer	Eindeutige Identifikationsnummer des Bestandes, ohne spez. Bedeutung. Multipart Polygone sind erlaubt (z.B., wenn eine Strasse durch den Bestand verläuft).
hmax	Maximale Höhe der Hauptschicht [m]	Höchster Baum (10m VHM) der Hauptschicht bzw. Kristallisationspunkt für die Bildung des Bestandes. Der effektiv höchste Baum des Bestandes kann höher sein, war dann aber kein Kristallisationspunkt.
hdom	Oberhöhe [m]	Die Oberhöhe des Bestandes. Dies ist der Mittelwert aller als Hauptschicht klassifizierten Pixel (VHM10m_max) innerhalb des Bestandes.
DG	Deckungsgrad der Hauptschicht [0-100%]	> 2/3 der Oberhöhe (entspricht DG_os + DG_ueb). Für Bestände mit hdom < 14 m gilt > 1/3 der Oberhöhe (entspricht DG_ms + DG_os + DG_ueb)
NH	Nadelholzanteil	Schätzung des Nadelholzanteils aufgrund von Sentinel-Satellitenbildern. Für gewisse Gebiete ist die Schätzung aufgrund der Topografie (Nordhänge, Schatten) oder der Waldstruktur (lückig, Waldwiesen etc.) schwierig.
NH_OS	Nadelholzanteil der Oberschicht	Nur die NH-Pixel (10 m Auflösung), die zu mind. 40 % zur Oberschicht gehören wurden berücksichtigt. Bestände, für welche keine Schätzung gemacht werden konnte, sind mit "-1" gekennzeichnet (siehe NH_OS_PIX).
NH_OS_PIX	Anz. Pixel für NH_OS	Gibt an wieviele Pixel (10 m Auflösung) für die Berechnung des NH_OS zur Verfügung standen.
area_m2	Grösse des Bestandes in m2	Die minimale Grösse beträgt 1000 m2, kann in wenigen Fällen aber kleiner sein bei isolierten Beständen und durch den finalen Zuschnitt auf den Perimeter.
struktur	Grundstruktur	Unterscheidung der Grundstruktur: Nicht stufige Bestände = „0“; stufige Bestände = „1“. Kriterien für stufig: hdom ≥ 28m, Fläche ≥ 3000 m2, DG_us ≥ 15%, DG_ms ≥ 20%, DG ≤ 60%.
DG_ks	Deckungsgrad der Krautschicht [0-100%]	< 40cm
DG_us	Deckungsgrad der Unterschicht [0-100%]	40cm bis 1/3 der Oberhöhe
DG_ms	Deckungsgrad der Mittelschicht [0-100%]	1/3 bis 2/3 der Oberhöhe
DG_os	Deckungsgrad der Oberschicht [0-100%]	2/3 der Oberhöhe bis hmax
DG_ueb	Deckungsgrad der Überhälter [0-100%]	> hmax
tbk_typ	TBk Bestandestyp: Klassifiziert ("classified"); Restflächen ("remainder")	Nicht klassifizierte Bestände sind sogenannte Restflächen ("remainder"), welche zu klein oder zu inhomogen waren für die Klassifizierung.

# TBk Bestandeskarte

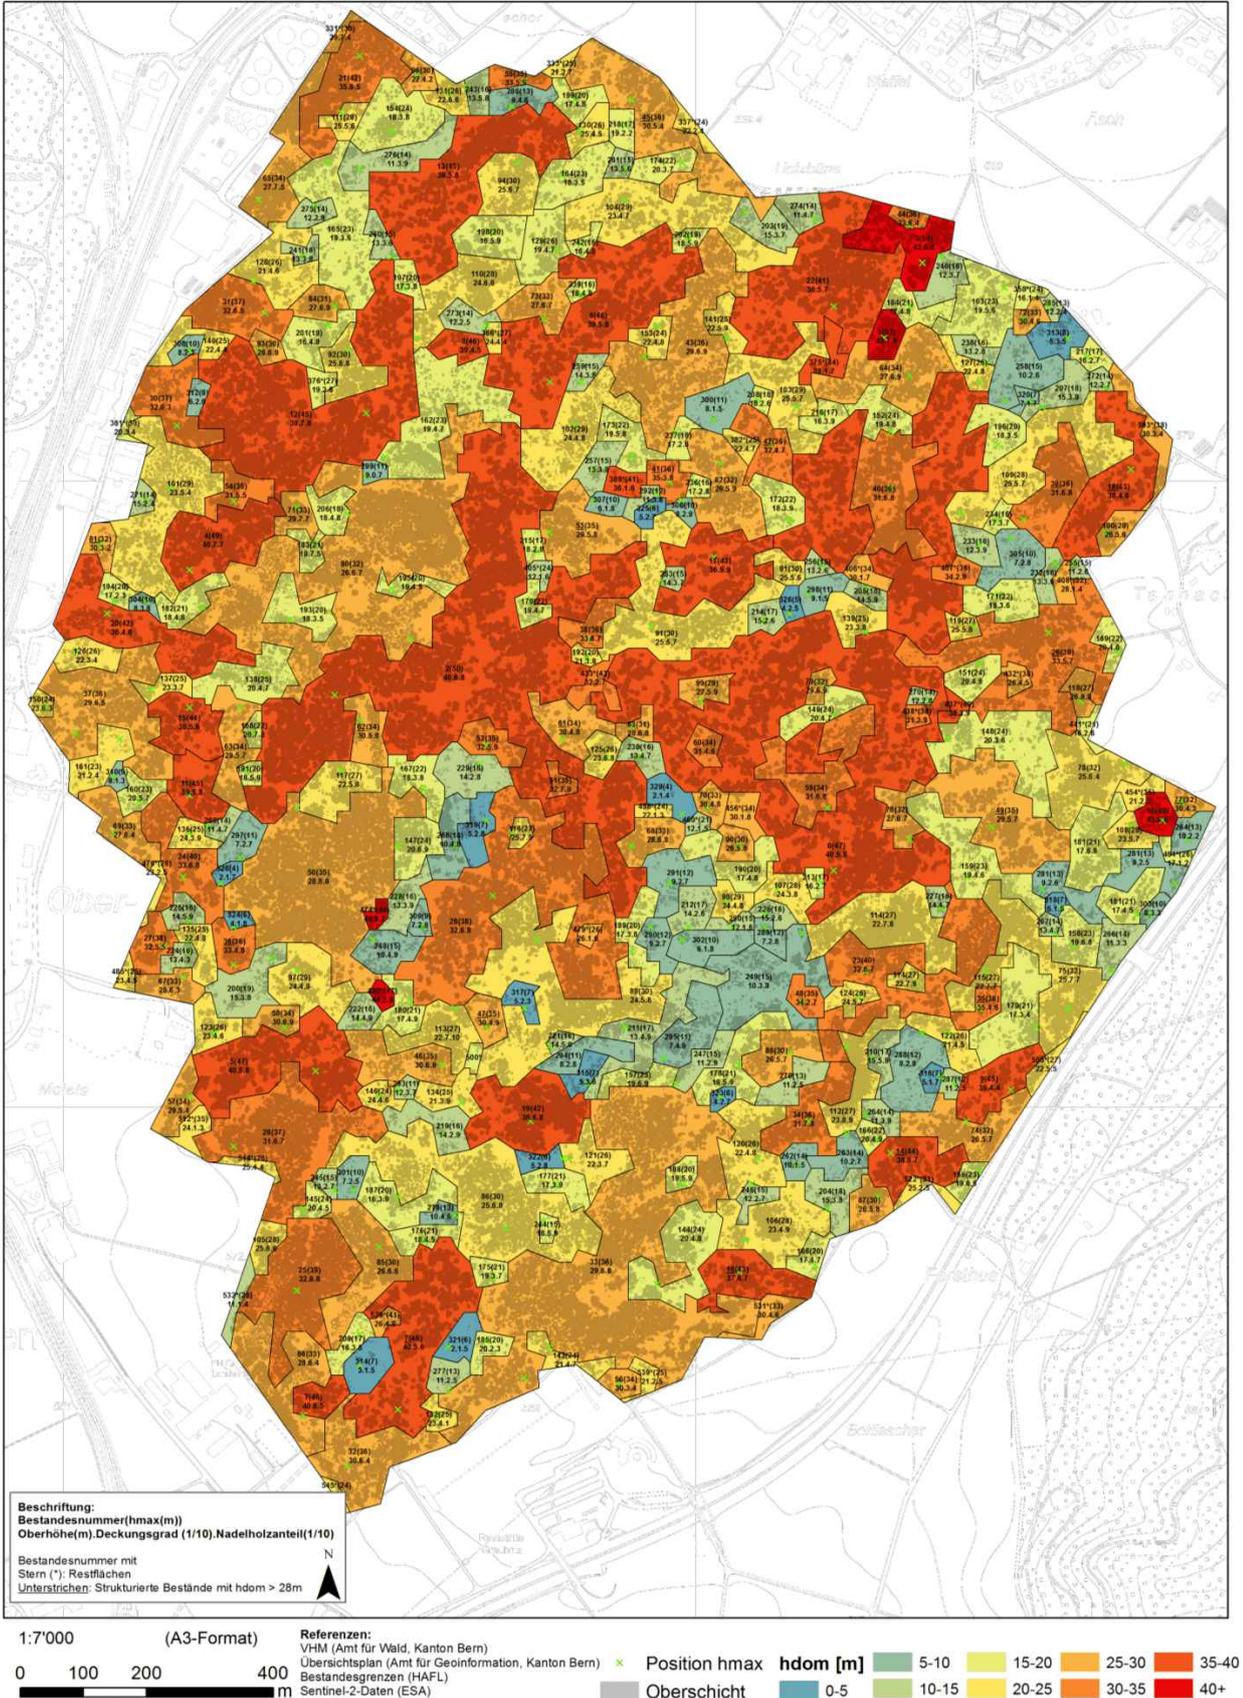


Abbildung 6.1.: Beispiel TBk Bestandeskarte für Williwald (BE).

Die Berechnung erfolgte für sämtliche Projektgebiete. Für Basel-Stadt / Basel-Land, Bern und Solothurn wurde zudem jeweils eine Neuberechnung mit aktuelleren Vegetationshöhenmodellen durchgeführt. Für die Kantone Basel und Luzern folgte zusätzlich eine Validierung der Resultate im Feld, für den Kanton Solothurn und das Fürstentum Liechtenstein ist dies ebenfalls in Planung. Die Rückmeldungen von den beteiligten Partnern waren überwiegend positiv. Die Feldbegehungen mit den Praktikern haben den Nutzen von TBk aufgezeigt, sowie ebenfalls potenzielle Weiterentwicklungsmöglichkeiten (z.B. eine stärkere Differenzierung bei den ungleichförmigen Beständen oder spezielle Berücksichtigung von Jungwaldflächen hinsichtlich Subventionen). Der Kanton Luzern hat die TBk-Daten online zur Verfügung gestellt.



## 7. Detektion der Einzelbäume

Die Detektion der Einzelbäume (i.e., Einzelbaumdetektion oder EBD) im Projekt FINT-CH basiert grundsätzlich auf dem Ansatz der Software FINT (s. <https://www.ecorisq.org/ecorisq-tools>), welche 2006 entwickelt wurde [10]. FINT arbeitet mit hochauflösenden Vegetationshöhenmodellen (VHM) als Input, wobei lokale Maxima in der Oberschicht gesucht werden. Um die Detektion von Einzelbäumen, welche einen detektierbaren Gipfel in der Oberschicht haben, so genau wie möglich durchzuführen, wurde im Projekt ein optimaler Ansatz pro WST gesucht. Dazu wurden viele Kombinationen von verschiedensten Ansätzen ausprobiert und verglichen mit den Referenzdaten, sowohl in der Kalibrierungs- als auch in der Validierungsphase. Nachfolgend fokussieren wir auf die Methodik, welche schlussendlich zu den besten Ergebnissen geführt hat.

### 7.1. Methodik der Einzelbaumdetektion (EBD)

Die verwendete Methode basiert auf folgenden Schritten:

1. Identifizieren von brauchbaren LFI Kalibrierungsplots: diese entsprechen LFI Plots ohne Waldränder innerhalb der Projektgebiete sowie innerhalb den Kantonen ZH, SG, AG und TG, wo gute Laserscanningsdaten vorliegen. Zur Verbesserung der Datenlage bei der Festlegung der performantesten Detektionsmethode haben wir die Daten (LFI-Daten, Mischungsgrad, VHM) dieser Kantone in der Analyse dazu genommen.
2. Berechnen der Stammzahl pro Hektar in den brauchbaren LFI Kalibrierungsplots basierend auf den stehenden, lebenden Bäumen der Oberschicht (laut Angaben LFI) sowohl in der inneren Kreisfläche für Gehölze mit  $12 \text{ cm} \leq \text{BHD} < 36 \text{ cm}$  ( $200 \text{ m}^2$ ; Radius = 7.98 m) als auch der äusseren Kreisfläche für Gehölze mit  $\text{BHD} \geq 36 \text{ cm}$  ( $500 \text{ m}^2$ ; Radius = 12.62 m). Die lokalen Stammzahlen werden auf einen Hektar hochgerechnet und zwar mit den Hochrechnungsfaktoren  $50 \text{ ha}^{-1}$  für die  $200 \text{ m}^2$  und  $20 \text{ ha}^{-1}$  für die  $500 \text{ m}^2$  Kreisfläche. Die hochgerechnete Stammzahl dient als Vergleich zur detektierten Stammzahl.
3. Ausschneiden eines  $25 \text{ m} \times 25 \text{ m}$  Fensters rund um die LFI-Probeflächenzentren im VHM
4. Bestimmung des WST innerhalb jedes  $25 \text{ m} \times 25 \text{ m}$  Fensters basierend auf Mischungsgrad sowie Deckungsgrad und Oberhöhe (hdom). Dieser Ansatz wurde wegen der zu grossen Variation der WST in einzelnen TBK Beständen gewählt, sonst hätten wir die TBK-Polygone als Basis für die EBD verwendet.
5. Einzelbaumdetektion basierend auf lokalen Maxima im VHM innerhalb des  $25 \text{ m} \times 25 \text{ m}$  Fensters. Dabei wurden folgende Varianten vom Input-VHM verwendet:
  - VHM mit 1 m Auflösung (V1m)
  - VHM mit 1.5 m Auflösung (V1\_5m)
  - VHM mit 2 m Auflösung (V2m)
  - VHM mit 1 m Auflösung gefiltert mit Gauss-Filter mit Standardabweichung ( $\sigma$ ) 2 und einen Radius von 3 Zellen (V\_GF2-3)
  - VHM mit 1 m Auflösung gefiltert mit Gauss-Filter mit Standardabweichung ( $\sigma$ ) 2 und einen Radius von 5 Zellen (V\_GF2-5)
  - VHM mit 1 m Auflösung gefiltert mit Gauss-Filter mit Standardabweichung ( $\sigma$ ) 2 und einen Radius von 7 Zellen (V\_GF2-7)

Der Hintergrundgedanke ist, dass in unterschiedlichen Waldstrukturen unterschiedliche Inputdaten zu besseren Ergebnissen führen. Zum Beispiel werden in einem reinen Buchenbestand mit starkem Baumholz i.d.R. zu viele Bäume pro Baumkrone detektiert (Überdetektion), wenn hochaufgelöste VHM's verwendet werden. Eine niedrigere VHM-Auflösung oder ein geglättetes VHM könnte in dem Fall zu besseren EBD Ergebnissen führen. In einem Fichtenbestand hingegen könnte eine EBD auf Basis eines ungefilterten VHM's mit einer Auflösung von 1 m x 1 m sehr gute Ergebnisse liefern.

6. Vergleich der detektierten Stammzahl pro Variante mit den LFI Stammzahlen aus Schritt 2. Zusätzlich wurden auch die Ergebnisse der folgenden zwei kombinierten Ansätze verglichen:
  - Vereinigung der Schnittmengen ( $V_{1m} \cap V_{1.5m}$ ) und ( $V_{1m} \cap V_{GF2-3}$ ). Diese Variante wird weiter  $V_{Kombi1}$  genannt.
  - Vereinigung der Schnittmengen ( $V_{1m} \cap V_{2m}$ ) und ( $V_{1m} \cap V_{GF2-5}$ ) und ( $V_{1m} \cap V_{GF2-7}$ ). Diese Variante wird weiter  $V_{Kombi2}$  genannt.

Der Vergleich mit den LFI Stammzahlen wurde auf Basis von Streudiagrammen, Q-Q Diagrammen (Quantil-Quantil-Diagramm; dies ist ein exploratives, grafisches Werkzeug, in dem die Quantile zweier statistischer Variablen gegeneinander abgetragen werden, um ihre Verteilungen zu vergleichen; siehe auch [11]), Boxplots der Detektionsraten sowie die Wurzel des mittleren quadratischen Fehlers (RMSE; root mean squared error) gemacht. Schlussendlich wurde die meist performante Variante pro WST gewählt. Falls es nicht genügend LFI-Probeflächen für gewisse WST gab, wurde gutachterlich festgelegt, welcher WST am ähnlichsten ist - die dazugehörige meist performante Variante wurde dann übernommen.

7. Unterteilen der Projektgebiete in 25 m x 25 m Zellen und Bestimmung des WST pro Zelle (analog zu Punkt 4, aber dann flächig).
8. EBD in den bestimmten optimalen Varianten flächig durchführen, wobei ein Minimum von 4 m als Schwelle für die Baumhöhe festgelegt wurde. Gleichzeitig wurde jedem detektierten Baum auf Basis seiner Höhe ein BHD zugewiesen. Die hierfür verwendete Formel wurde auf Basis aller Referenzbäume mit eingemessener Höhe (h) gefittet und lautet wie folgt:  $BHD = 2.52 * h^{0.84}$ .
9. Basierend auf den WST pro 25 m x 25 m Zelle die detektierten Einzelbäume aus den flächig detektierten Daten auswählen und zum Resultat hinzufügen.
10. Validierung der Methodik auf Basis der Referenzdaten (siehe Kap. 4.2). Zur Validierung wurden die Einzelbaumdaten auf jeweilige Referenzfläche aggregiert, um Daten zu Stammzahl und Grundfläche pro Hektare zu erhalten.
11. Zusätzlich wurden statistische Beziehungen zwischen den Kalibrierungsdaten und den aggregierten Detektionsdaten hergeleitet, damit der Bereich der zu erwarteten Stammzahl, Grundfläche und Vorrat pro Bestand bestimmt werden konnte. Die Resultate der Modelle wurden analog zu Punkt 11 validiert.

### 7.1.1. IDW Ansatz zur Bestimmung der Detektierbarkeit von Referenzbäumen

Für den Vergleich der Ergebnisse der Einzelbaumdetektion und der Referenzdaten wurde zusätzlich bestimmt, welche der am Boden eingemessenen Bäume im VHM potenziell überhaupt detektierbar sind. Es wird davon ausgegangen, dass dies bei vorherrschenden, herrschenden und mitherrschenden Bäumen der Fall ist, deren Gipfel sich genügend klar vom Kronendach absetzt bzw. aus diesem herausragt. Entscheidend hierfür ist die Baumhöhe (h), welche aber bei weniger als 30% der Referenzbäume tatsächlich vermessen wurde. Deshalb wurden die Baumhöhen auf Basis des BHD anhand einer gefitteten Funktion bestimmt. Für das Fitting dieser Funktion wurden die Referenzbäume mit eingemessener Höhe in sieben Gruppen aufgeteilt und anschliessend eine Funktion auf Basis eines Power-Law gefittet:

- Tanne:  $h = 3.19 \cdot BHD^{0.59}$
- Fichte:  $h = 2.63 \cdot BHD^{0.63}$
- Buche:  $h = 3.02 \cdot BHD^{0.59}$
- Nadelbäume:  $h = 1.66 \cdot BHD^{0.67}$
- Laubbäume:  $h = 2.52 \cdot BHD^{0.62}$

- Strauch:  $h = 2.21 \cdot BHD^{0.67}$
- Lärche:  $h = 5.31 \cdot BHD^{0.41}$
- Unbekannte Art:  $h = 3.16 \cdot BHD^{0.59}$

Der eigentliche Ansatz zur Bestimmung der Detektierbarkeit geht davon aus, dass die Krone eines Baumes ausgehend vom Gipfel nach Aussen hin eine abnehmende Höhe und damit einen abnehmenden Einfluss auf die Detektierbarkeit benachbarter Bäume zu haben. Als detektierbar wird ein Baum angenommen, der sich in genügendem Masse von einer gedachten Oberfläche, die basierend auf den Baumhöhen bestimmt wird, absetzt. Im verwendeten Ansatz wird diese Oberfläche anhand der Inverse-Distance Weighted (IDW) Methode bestimmt. Bei IDW handelt es sich um eine Interpolationsmethode, bei der auf Basis einer Punktemenge mittels gewichtetem Durchschnitt die interpolierten Werte bestimmt werden. Als Gewicht dient dabei die inverse Distanz der berücksichtigten Punkte, wobei die Distanz potenziert wird, um deren Einfluss zu steuern. Je höher der Grad der Potenz, desto stärker der Einfluss der nähergelegenen Punkte. Die Bestimmung der Detektierbarkeit läuft folgendermassen ab:

- Für jeden Referenzbaum wird unter Berücksichtigung aller Nachbarbäume in einem Umkreis von 30 Metern die interpolierte Höhe gemäss IDW Methode bestimmt.
- Die Differenz zwischen der gefitteten Höhe und der interpolierten IDW-Höhe wird bestimmt.
- Wenn die ermittelte Differenz oberhalb eines bestimmten Schwellwertes liegt, wird der Baum als detektierbar betrachtet.

Im Projekt wurden verschiedene Kombinationen von Schwellwerten und Potenzen untersucht. Eine Potenz von 6 bei der Interpolation und ein Schwellwert von 0 m (d.h. die gefittete Höhe des Baumes muss mindestens so hoch sein wie die Höhe der IDW Fläche) erwies sich dabei als guter Kompromiss zwischen lokalem Einfluss und Restriktion beim Schwellwert. Entsprechend wurde diese Parametrisierung der Methode für die Verifikation herangezogen.

## 7.2. Ergebnisse der EBD

Auf Basis aller Q-Q Diagramme, der Boxplots mit den Detektionsraten pro getestete Variante (s. Annexe I / II) und beispielhaft Abb. 7.1) sowie des RMSE zwischen detektierter Stammzahl und Stammzahl des LFI Plots, konnten wir die meist performante Detektionsvariante pro WST festlegen. Diese sind in der Tabelle 7.1 aufgelistet. Als Kriterien wurde bei den Q-Q Diagrammen auf eine möglichst ähnliche Verteilung zwischen Referenzdaten und Detektion geachtet (bei ähnlichen Verteilungen befinden sich die Punkte ungefähr auf der Linie  $x = y$ ). Bei den Boxplots der Detektionsrate wurde auf die Distanz des Medians zum Wert 1 und eine möglichst kleine Streuung geachtet. Der RMSE sollte schliesslich möglichst niedrig sein.

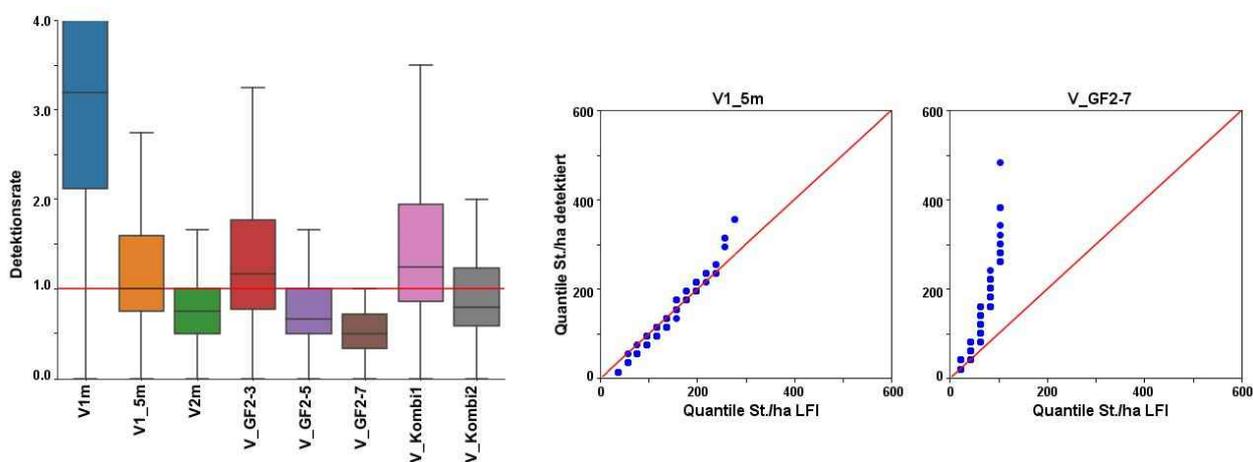


Abbildung 7.1.: Boxplot mit den Detektionsraten und Q-Q Diagramme für 2 Detektionsvarianten für WST 112.

Tabelle 7.1.: Meist performante Detektionsvariante pro WST

Beschreibung Waldtyp/-Struktur	WST	gewählte Detektionsvariante
Laubwald, DG < 80%	111, 112	V1_5m
Laubwald, DG ≥ 80%, hdom < 22 m	121	V_GF2-3
Laubwald, DG ≥ 80%, hdom ≥ 22 m	122	V_Kombi1
Mischwald, DG < 80%, hdom < 22 m	211	V1_5m
Mischwald, hdom ≥ 22 m	212, 222	V_Kombi1
Mischwald, DG ≥ 80%, hdom < 22 m	221	V_GF2-3
Nadelwald (alle Strukturtypen)	311, 312, 321, 322	V_Kombi1

### 7.2.1. Entwicklung pyFINT und Geoprocessing

Die Prozesse rund um die Einzelbaumdetektion und die Analyse der Ergebnisse wurden mit Hilfe von Python umgesetzt. Bei der Aufbereitung der Daten und der eigentlichen Detektion kamen dabei im Sinne von Geoprocessing Skripte zum Einsatz. Bei der Aufbereitung der als Excel angelieferten Referenzbäume kam ArcGIS mit dessen ArcPy Package zum Einsatz. Die Aufbereitung bestand aus den folgenden Schritten:

- Konversion der Daten aus Excel in eine Feature Class in einer File Geodatabase
- Transformation der Koordinaten von LV03 nach LV95
- Zusammenfassen der einzelnen Plots und Bestimmung der konvexen Hülle der Referenzbäume
- Anreicherung mit Informationen zum umgebenden Kanton für die spätere Detektion
- Bestimmung des Waldstrukturtyps pro Referenzfläche
- Bestimmung der Detektierbarkeit der Referenzbäume

Der Prozess zur Detektion der Einzelbäume wurde ebenfalls mit Skripten ausgeführt, welche auf einer Reihe von Open Source Python Packages basieren. Die anschließende Auswertung der Detektionsresultate und deren Visualisierung greift ebenfalls auf die gleichen Open Source Python Packages zurück, wurde aber in Form von Jupyter Notebooks umgesetzt, welche ein interaktiveres Vorgehen als reine Geoprocessing Skripte zulassen.

Die eigentliche Einzelbaumdetektion auf Basis von VHM Rastern erfolgte mittels des Programms FINT. Für das Projekt wurde der aktuelle Stand des FINT Programms nach Python portiert. Der resultierende pyFINT Code wurde überarbeitet und erweitert. Im Vergleich zu FINT wurden einige kleinere Verbesserungen bei der Handhabung von Randpixeln und benachbarten Pixel gleicher Höhe vorgenommen. Zudem wurde pyFINT einerseits um die Möglichkeit erweitert, die Auflösung der Eingaberaster durch Resizing anzupassen und andererseits wurde die Möglichkeit der Filterung des VHM Rasters mittels Gauss-Filter implementiert, wobei Radius und Stärke des Filters angegeben werden können. Resizing und Filterung können auch kombiniert werden, wobei zuerst das Resizing und erst danach die Filterung erfolgt. Im Falle eines angewendeten Resizing Gauss-Filters wird ausserdem die Höhe der detektierten lokalen Maxima auf dem Originalraster bestimmt. Diese Verbesserungen in pyFINT sollen schlussendlich in das FINT Programm zurückfliessen.

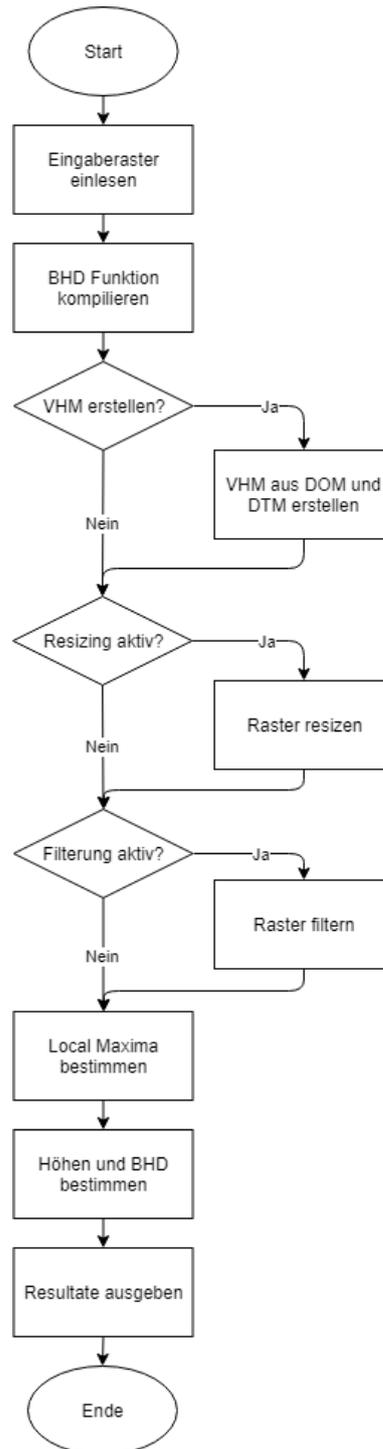


Abbildung 7.2.: Flowchart pyFINT Detektionsprozess.

### 7.2.2. Prozess Einzelbaumdetektion für Referenzflächen

Für die Einzelbaumdetektion in den Referenzflächen, welche als Basis für die Kalibrierung und Validierung des Prozesses dienten, wurde um den pyFINT Kern herum ein Geoprocessing Skript erstellt. Der darin implementierte Prozess setzt sich aus den folgenden Schritten zusammen:

- Einlesen der Perimeter für die Referenzflächen in den Kantonen mit vorhandenen Inputdaten
- Pufferung des Perimeter für die anschliessende Extraktion des VHM

- Detektion der lokalen Maxima mit pyFINT
- Nachbearbeitung und Speicherung der Resultate

Der entwickelte Prozess wiederholt nacheinander diese Schritte für alle Referenzflächen und für verschiedene Filterkombinationen. Um den Vorgang zu beschleunigen, ist der Prozess ausserdem parallelisiert und auf einem performanten Server mit genügend Ressourcen (CPU, RAM und Speicherplatz) ausgeführt worden. Um die von pyFINT einzeln als CSV ausgegebenen Resultate zusammenzuführen, werden die Daten bei der Nachbearbeitung in eine PostGIS Datenbank geschrieben. Dies vereinfacht nicht nur die Analyse auf Basis einer zentralen Datenquelle, sondern ermöglichte in einem abgesetzten Schritt auch die Generierung zusätzlicher Detektionsergebnisse, welche die Resultate mehrerer Filterkombinationen kombinieren. Dabei wurden jeweils die Resultate der Detektion auf 1 m Auflösung zusammen mit Resultaten weiterer Filterkombinationen eingelesen und dann gegeneinander abgeglichen. Im kombinierten Resultat wurden nur Bäume aus der 1 m Detektion übernommen, die in mindestens einem der anderen Resultate ebenfalls detektiert wurden, wobei ein Vergleich der euklidischen Distanz und ein Suchradius von 1.5 m angewendet wurde. Die kombinierten Methoden wurden wiederum in die Datenbank zurückgeschrieben. Der für die Referenzflächen entwickelte Prozess diente als Grundlage für die Entwicklung des Prozesses zur flächendeckenden Einzelbaumdetektion.

### 7.2.3. Prozess flächendeckende Einzelbaumdetektion

Der Prozess zur flächendeckenden Einzelbaumdetektion basiert auf den Erkenntnissen aus der Detektion für die Referenzflächen und der Analyse von deren Resultaten. Der Prozess ist in Abb. 7.3 schematisch dargestellt. Er nimmt zwar Anleihen vom Prozess der Detektion von Referenzflächen, ist aber auf die für die FINT-CH Detektion wesentlichen Schritte reduziert und nicht auf einzelne Plots zugeschnitten. Stattdessen ist die Verarbeitung der Inputs auf die effiziente Verkachelung und Verarbeitung grösserer Gebiete ausgelegt.

Der Prozess arbeitet mit den folgenden Inputdaten:

- Shapefile mit den Grenzen der zu detektierenden Perimeter (hier die Grenzen der Projektgebiete)
- VHM in Originalauflösung für die Detektion
- VHM mit 1.5 m Auflösung für die Bestimmung des Waldstrukturtyps
- Mischungsgradraster mit 10 m Auflösung für die Bestimmung des Waldstrukturtyps
- Shapefile mit einer Waldmaske
- Shapefile mit einer Maske der Trassenflächen von Übertragungsleitungen

Die Zuordnung der einzelnen Inputs zu den Perimetern erfolgte über eine separate CSV Datei, die als Konfiguration des Prozesses dient. Zu Beginn des Prozesses werden die Perimeter eingelesen und in regelmässige Kacheln von 1 km<sup>2</sup> unterteilt. Diese Kacheln sind die Verarbeitungseinheit für die nachfolgenden Schritte. Zunächst werden pro Kachel die Einzelbäume mit Hilfe von pyFINT detektiert. Der Prozess führt dabei nacheinander Detektionen mit allen benötigten Filterkombinationen (1 m, 1.5 m, 1 m mit Gauss-Filter  $\sigma=2$   $r=3$ ) durch. Hierzu wird zunächst aus dem original VHM die Fläche der Kachel extrahiert und dann auf diesem Ausschnitt die Detektionen ausgeführt. Anders als bei den Referenzflächen werden die kombinierten Methoden direkt auf Basis der CSV Outputs berechnet, bevor alle Detektionsresultate in eine Datenbanktabelle gespeichert werden. Nach der Detektion der Einzelbäume wird der Waldstrukturtyp pro Kachel bestimmt. Hierfür wird die Kachel in ein Gitter mit 25 m x 25 m Maschenweite unterteilt und für jede Gitterzelle der Waldstrukturtyp auf Basis des VHM in 1.5 m Auflösung und des Mischungsgradrasters bestimmt. Die Resultate werden wiederum in eine Datenbanktabelle gespeichert. Als letzter Schritt erfolgt die Nachbearbeitung pro Kachel. Dabei werden für jede WST-Gitterzelle die Bäume der zugehörigen Detektionsmethode selektiert und zu einem kombinierten Datensatz zusammengefügt. Dieser wird dann zusätzlich auf die Waldmaske zugeschnitten und optional im Bereich von Übertragungsleitungstrassen um Fehldetektionen bereinigt. Dabei werden alle detektierten Bäume mit Höhe  $\geq 25$  m innerhalb der Trassenflächen ausgefiltert. Der so nachbearbeitete Datensatz wird dann als Endresultat in eine Datenbanktabelle geschrieben.

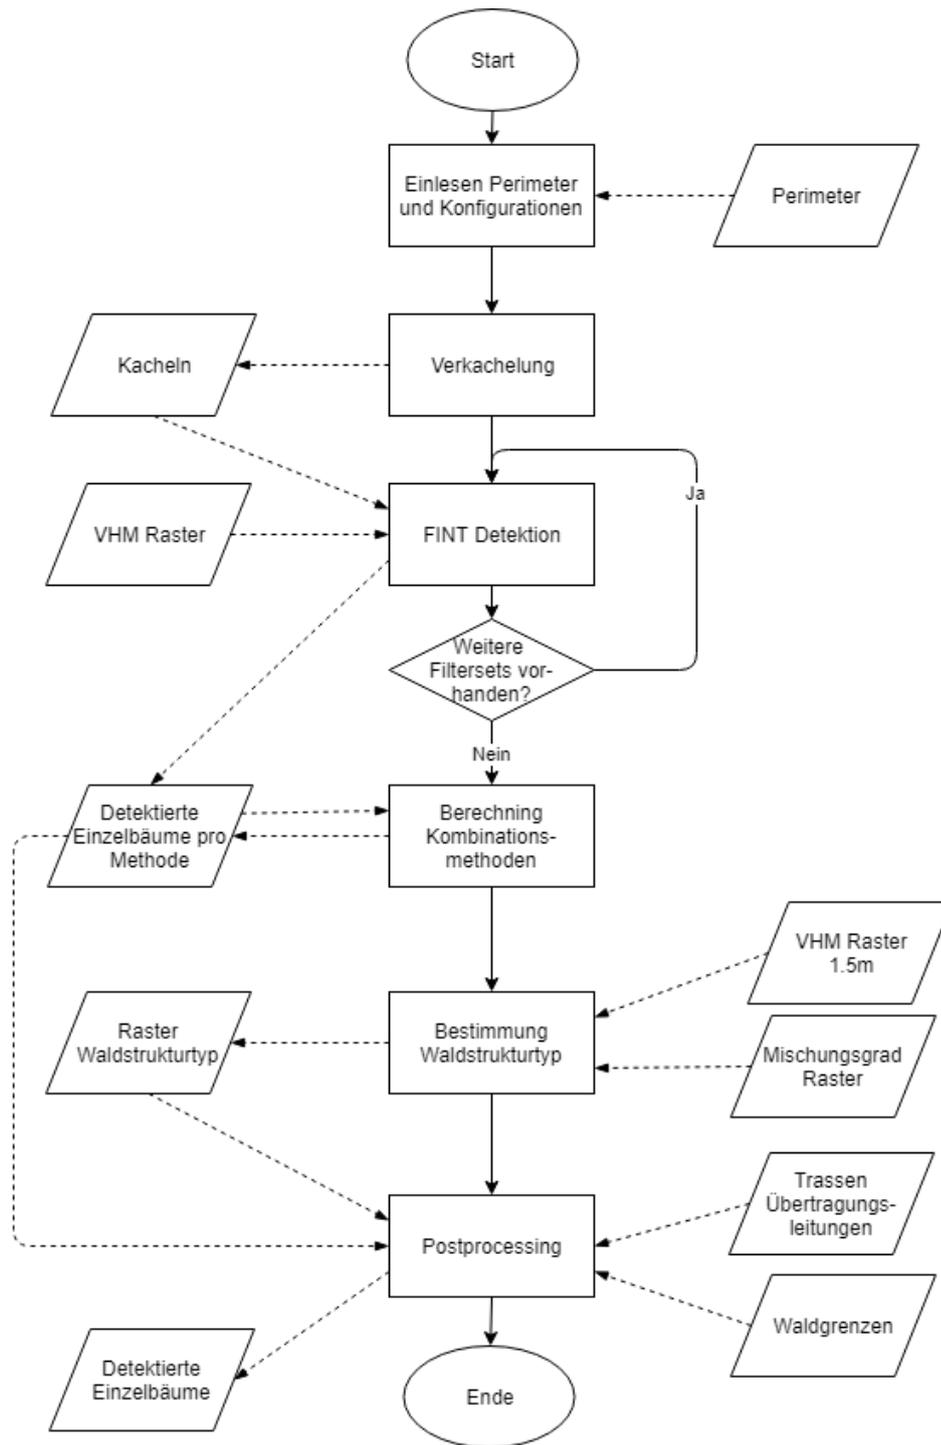


Abbildung 7.3.: Flowchart FINT-CH Prozess für flächendeckende Einzelbaumdetektion.

Um auch grosse Flächen möglichst effizient verarbeiten zu können, wird auch dieser Prozess parallelisiert. Dabei werden die einzelnen Schritte (Detektion, Waldstrukturtyp bestimmen, Nachbearbeitung) jeweils zuerst für alle Kacheln abgeschlossen, bevor mit dem nächsten Schritt fortgefahren wird. Eine PostGIS Datenbank dient dabei als Datenspeicher für die Integration der Resultate der verschiedenen Kacheln und als Quelle für die Erstellung der Datenexporte für die schlussendliche Datenlieferung an die Projektpartner.

## 7.2.4. Verwendete Software und Bibliotheken

Folgende Software wurde im Rahmen der Einzelbaumdetektion verwendet:

Tabelle 7.2.: Bei der EDB verwendete Software

Bezeichnung	Version	Verwendung
Excel	2019	Sichtung und Verarbeitung Referenzdaten
ArcGIS	10.8	Aufbereitung Referenzdaten, Visualisierungen
QGIS	3.10	Aufbereitung Daten, Visualisierungen
GDAL/OGR	2.4.1	Aufbereitung Raster
Python	3.7	Programmierung
Jupyter Lab	3.0.5	Analyse und Visualisierung Ergebnisse

Folgende Software Bibliotheken bzw. Packages wurden bei der Programmierung der Geoprocessing Skripte und der Analyse verwendet. Es werden nur die direkt referenzierten Packages aufgeführt, Abhängigkeiten werden ausgelassen.

Tabelle 7.3.: Für Geoprocessing und Analyse verwendete Python Packages

Bezeichnung	Version	Verwendung
ArcPy	10.8	Aufbereitung Referenzdaten
rasterio	1.0.22	Verarbeitung Rasterdaten
fiona	3.10	Verarbeitung Vektordaten
shapely	1.6.4	Bearbeitung Vektorgeometrien
gdal	2.4.1	Verarbeitung Raster und Vektordaten
numpy	1.16.2	Verarbeitung von Array-basierten Daten
pandas	0.25.3	Verarbeitung und Analyse von Daten
geopandas	0.8.1	Verarbeitung und Analyse von Vektordaten
psycopg2	2.8.3	Zugriff auf PostgreSQL Datenbanken
scipy	1.2.1	Statistik und Modellierung
scikit-learn	0.20.2	Statistik und Modellierung
statsmodels	0.9.0	Statistik, Modellierung und Visualisierung
seaborn	0.11.0	Visualisierung
matplotlib	3.0.3	Visualisierung

## 7.2.5. Statistische Modellierung Stammzahlen

Für die Untersuchung der statistischen Zusammenhänge zwischen den detektierten Stammzahlen in der Oberschicht und den gesamten Stammzahlen in der Fläche wurde zunächst ein kombinierter Datensatz aus Referenzdaten der LFI Plots und Daten aus dem Detektionsprozess erstellt. Für die LFI Plots, in denen eine Detektion vorgenommen werden konnte, wurden neben aggregierten Zahlen zu den einzelnen Referenzbäumen auch Werte aus der LFI Statistik in den Datensatz integriert. Die Daten aus der Detektion basieren vollständig auf der Aggregation der detektierten Bäume. Dabei wurden jeweils nur die Bäume derjenigen Filterkombination berücksichtigt, welche dem Waldstrukturtyp des jeweiligen LFI Plots entsprach. Sowohl für die Referenzdaten als auch für die detektierten Daten wurden neben der gesamten Stammzahl ( $N$ ) auch die Stammzahl unterteilt in vier Kategorien berechnet. Die Unterteilung erfolgte anhand des BHD in die Kategorien  $BHD \leq 12\text{cm}$ ,  $12\text{ cm} < BHD \leq 24\text{ cm}$ ,  $24\text{ cm} < BHD \leq 36\text{ cm}$  und  $BHD > 36\text{ cm}$ . Bei den detektierten Bäumen wurde der BHD mit Hilfe einer Funktion aus der Höhe abgeleitet. Die verwendete BHD Funktion wurde durch Fitting eines Power-Law anhand der Referenzbäume bestimmt und hat die Form  $BHD = 2.52 \cdot h^{0.84}$ . Der resultierende Datensatz umfasst Angaben zu  $N = 4009$  LFI Plots. Weitere 39 Plots wurden bei der Aufbereitung des Datensatzes ausgefiltert, da dort keine Bäume detektiert werden konnten. Es handelt sich um Plots mit nur ein oder zwei Referenzbäumen, welche entweder durch Randeffekte oder wegen zu geringer Höhe nicht detektiert wurden. Der aufbereitete Datensatz wurde in der Statistik Software R mit Methoden der multivariaten Statistik untersucht, um ein Modell für den Zusammenhang zwischen den detektierten Daten

und der Stammzahl (N) oder der Grundfläche (G) zu erhalten. Bei einer initialen, explorativen Analyse der Daten mit Hilfe einfacher Statistiken zur Verteilung sowie von Plots (u.a. Box-Plots und QQ-Plots) wurde festgestellt, dass die Residuen der quadratwurzeltransformierten Zielgrößen nahezu normalverteilt sind (vergleiche auch Beispiel QQ-Plot in Abb.7.4). Dabei sind die Klassen mit den grösseren BHD Werten etwas näher an der Normalverteilung und die Klassen mit kleineren BHD weisen stärkere Abweichungen aus. Grundsätzlich wurde aber auf Grund dieser Ergebnisse die quadratwurzeltransformierten Zielgrößen als Input für die Modellierung verwendet.

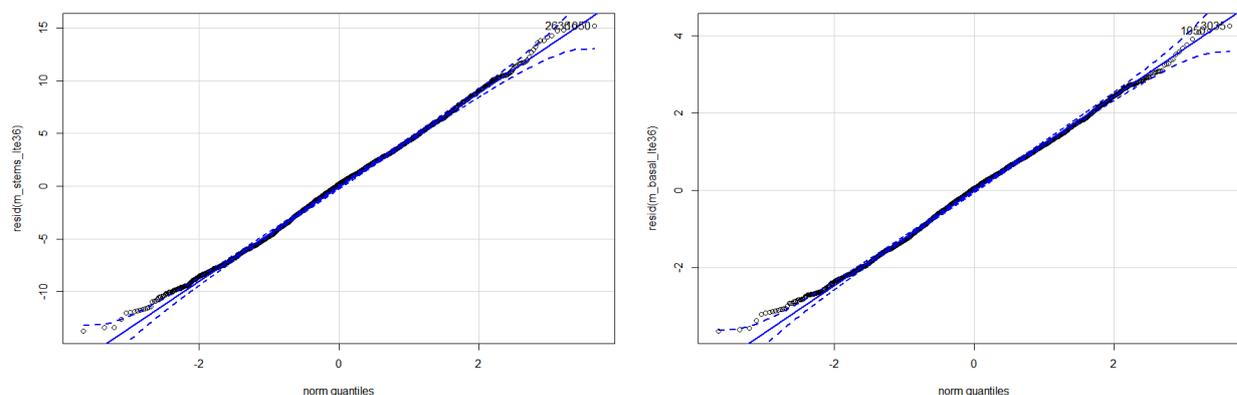


Abbildung 7.4.: QQ-Plot der Residuen für die quadratwurzeltransformierten N und G Werte für  $BHD \geq 36$  cm.

Für die Modellierung wurden primär lineare Regressionsmodelle in verschiedener Zusammensetzung bei den erklärenden Variablen erstellt und mit Hilfe von Anova Analysen ("Type I") auf deren Güte untersucht. Dabei wurden auch Modelle mit faktoriellen Inputs in Form der Codes für Deckungsgrad, Nadelholzanteil und Hdom untersucht, wobei auch Varianten mit und ohne Interaktion berücksichtigt wurden. Diese Modelle mit faktoriellen Inputs schnitten alle aber schlechter ab als Modelle, welche die numerischen Werte für Deckungsgrad, Nadelholzanteil und Hdom verwenden. Auch die Berücksichtigung der Interaktion führte nicht zu einer Verbesserung der Modelle. Deshalb wurden sowohl die faktoriellen Inputs als auch die Interaktion schlussendlich verworfen. Zusätzlich zu den linearen Modellen wurden auch noch Poisson basierte Regressionsmodelle untersucht, welche aber keine Verbesserung brachten und in der Tendenz leicht schlechtere Ergebnisse lieferten. Deshalb wurden schlussendlich die linearen Regressionsmodelle mit numerischen Inputs ohne Interaktion verwendet und explorativ möglichst optimiert.

Tabelle 7.4.: Güte der linearen Regressionsmodelle

Zielgrösse	R-squared (multiple & adjusted)
$N_{Total}$	0.29
$N_{12cm \leq BHD < 24cm}$	0.23
$N_{24cm \leq BHD < 36cm}$	0.21
$N_{BHD \geq 36cm}$	0.46
$G_{Total}$	0.43
$G_{12cm \leq BHD < 24cm}$	0.22
$G_{24cm \leq BHD < 36cm}$	0.21
$G_{BHD \geq 36cm}$	0.47

Die folgende Aufstellung listet die aus den statistischen Modellen abgeleiteten Formeln für die Berechnung der Stammzahl oder der Grundfläche aus den detektierten Daten. Die Quadrierung in der Formel ist auf den Umstand zurückzuführen, dass die Zielvariablen der Modelle mit der Quadratwurzel transformiert wurden.

- $N_{Total} = (4.662 + 0.077 \cdot DG + 0.154 \cdot hdom + 0.02575 \cdot NH + 0.0297 \cdot N_{Det\_Total} - 0.0145 \cdot G_{Det\_Total})^2$
- $N_{12cm \leq BHD < 24cm} = (2.3625 + 0.079 \cdot DG + 0.02978 \cdot hdom - 0.00014 \cdot NH - 0.02233 \cdot N_{Det\_12 \leq BHD < 24} + 0.1415 \cdot G_{Det\_12 \leq BHD < 24} + 0.03614 \cdot N_{Det\_Total} - 0.03698 \cdot G_{Det\_Total})^2$

- $N_{24cm \leq BHD < 36cm} = (-0.0822 + 0.036 \cdot DG + 0.1156 \cdot hdom + 0.02066 \cdot NH + 0.00197 \cdot N_{Det,24 \leq BHD < 36} + 0.0325 \cdot G_{Det,24 \leq BHD < 36} + 0.00368 \cdot N_{Det,Total} + 0.00275 \cdot G_{Det,Total})^2$
- $N_{BHD \geq 36cm} = (2.442 - 0.0029 \cdot DG + 0.1882 \cdot hdom + 0.02777 \cdot NH + 0.0389 \cdot N_{Det,BHD \geq 36} - 0.0438 \cdot G_{Det,BHD \geq 36} - 0.02003 \cdot N_{Det,Total} + 0.04133 \cdot G_{Det,Total})^2$
- $G_{Total} = (1.116 + 0.0122 \cdot DG + 0.0737 \cdot hdom + 0.0124 \cdot NH + 0.00203 \cdot N_{Det,Total} - 0.00438 \cdot G_{Det,Total})^2$
- $G_{12cm \leq BHD < 24cm} = (0.3336 + 0.0122 \cdot DG + 0.005256 \cdot hdom + 0.000188 \cdot NH - 0.004239 \cdot N_{Det,12 \leq BHD < 24} + 0.02278 \cdot G_{Det,12 \leq BHD < 24} + 0.0061 \cdot N_{Det,Total} - 0.00592 \cdot G_{Det,Total})^2$
- $G_{24cm \leq BHD < 36cm} = (-0.0193 + 0.00923 \cdot DG + 0.0329 \cdot hdom + 0.00588 \cdot NH + 0.000368 \cdot N_{Det,24 \leq BHD < 36} + 0.00882 \cdot G_{Det,24 \leq BHD < 36} + 0.00066 \cdot N_{Det,Total} + 0.00125 \cdot G_{Det,Total})^2$
- $G_{BHD \geq 36cm} = (1.0015 + 0.00021 \cdot DG + 0.0809 \cdot hdom + 0.0117 \cdot NH + 0.0145 \cdot N_{Det,BHD \geq 36} - 0.015 \cdot G_{Det,BHD \geq 36} - 0.00823 \cdot N_{Det,Total} + 0.0152 \cdot G_{Det,Total})^2$

Abkürzungen:

- $N$ : Stammzahl pro ha
- $N_{Det}$ : detektierte Stammzahl pro ha
- $G$ : Grundfläche ( $m^2/ha$ )
- $G_{Det}$ : detektierte Grundfläche ( $m^2/ha$ )
- $DG$ : Deckungsgrad (0-100%)
- $NH$ : Nadelholzanteil (0-100%)
- $hdom$ : Bestandesoberhöhe ( $m$ )

## 7.2.6. Validierung der Ergebnisse

Für die Validierung der basierend auf den LFI Plots kalibrierten Einzelbaumdetektion und des erstellten Statistikmodells wurden Bestandesdaten der Referenzflächen aus den übrigen Quellen herangezogen. Diese umfassen unter anderem Marteloskope und PPS Flächen, welche komplett vermessen sind und insgesamt 34'586 Referenzbäume verteilt auf 117 Referenzflächen. Für die Analyse wurde zunächst pro Referenzfläche der Perimeter durch Bildung der konvexen Hülle um die Referenzbäume erzeugt. Die Perimeter der Referenzflächen wurden verwendet, um aus den FINT-CH Resultaten der Projektgebiete die detektierten Bäume zu extrahieren. Diese Bäume wurden mit den 25 m mal 25 m grossen Rasterzellen aus der Detektion verschnitten, um die für die Verifikation sowie das Statistikmodell nötigen Angaben zu Deckungsgrad, Hdom und Nadelholzanteil zu erhalten. Diese Rasterzellen dienen als Vergleichseinheit für die Verifikation, wobei nur Rasterzellen berücksichtigt wurden, die mindestens zu 60 Prozent mit dem Perimeter überlappen, wodurch noch 1006 Zellen übrigblieben. Für die eigentlichen Vergleiche wurden die benötigten Werte auf die Rasterzellen aggregiert. Als Vergleichsgrösse dienten dabei jeweils die Stammzahl  $N$  pro ha und die Grundfläche  $G$  pro ha. Neben den Daten aus den Referenzdaten und der Detektion wurden dem aggregierten Datensatz auch noch die mittels des Statistikmodells berechneten Werte angefügt. In einem ersten Verifikationsschritt wurden die detektierten Bäume mit den potenziell detektierbaren Bäumen verglichen. Hierzu wurden die Referenzbäume gemäss der in Kap. 7.1.1 beschriebenen Methode aufbereitet. Sowohl für die detektierten Bäume als auch für die detektierbaren Referenzbäume wurden jeweils  $N$  und  $G$  einander gegenübergestellt. In der ersten Zeile von Abb. 7.5 sind entsprechende Scatterplots zu sehen. Es zeigt sich hier sowohl bei  $G$  als auch bei  $N$  eine leichte Tendenz zur Unterdetektion. Auch zeigt sich eine relativ grosse Streuung, wobei diese bei  $N$  etwas schwächer ist als bei  $G$  und bei grösseren Stammzahlen tendenziell stärker ausfällt. In einem zweiten Schritt wurden die detektierten Bäume mit dem gesamten Bestand in den Referenzflächen verglichen. Wiederum wurden dabei die Grössen  $G$  und  $N$  einander gegenübergestellt (siehe mittlere Zeile Abb. 7.5). Das Bild ist ähnlich wie beim Vergleich mit den potenziell detektierbaren Bäumen. Allerdings ist die Tendenz zur Unterdetektion wesentlich stärker, da nun auch die nicht klar abgrenzbaren Referenzbäume sowie Referenzbäume der Unterschicht mitberücksichtigt werden. Das Resultat entspricht soweit den Erwartungen und unterstreicht, dass die Methode vorherrschende und mitherrschende Bäume einigermaßen gut detektieren, Bäume unter dem Kronendach aber nicht erfassen kann. Im dritten Verifikationsschritt wurden schliesslich die Werte für Stammzahl und Grundfläche aus dem Statistikmodell mit den Validierungsdaten verglichen. Entsprechende Scatterplots sind in der untersten Zeile der Abb. 7.5 zu sehen.

Es ist ersichtlich, dass sowohl für G als auch für N im Vergleich zur Gegenüberstellung der detektierten Werte mit dem gesamten Bestand die Unterdetektion zumindest teilweise ausgeglichen werden kann. Die Werte aus dem Statistikmodell zeigen noch eine Tendenz zur Unterschätzung, die aber niedriger ausfällt. Beim Modellwert für G ist gleichzeitig eine leichte Verringerung der Streuung ersichtlich. Beim Modellwert von N entsteht im Scatterplot der Eindruck einer leicht grösseren Streuung, im Mittel sind die Abweichungen aber kleiner als bei den detektierten Werten. Die Abweichungen zwischen den Modellwerten und den Referenzwerten werden auf verschiedene Faktoren zurückgeführt. Einerseits sind im Modell der Anteil der unerklärten Varianz immer noch relativ hoch. Andererseits gibt es teils auch zeitliche Abstände zwischen dem Erfassungsdatum der Referenzdaten und der Erfassung der ALS Daten, welche mitunter über 10 Jahre betragen. Zudem gibt es leichte Randeffekte durch die Verwendung der konvexen Hülle als Grundlage für die Perimeter, woraus sich einzelne Zellen ergeben, die zwar im Perimeter liegen, aber wohl auf Grund von deren unregelmässigen Form nicht zur eigentlichen Referenzfläche gehören.

Verifikation Einzelbaum Detektion

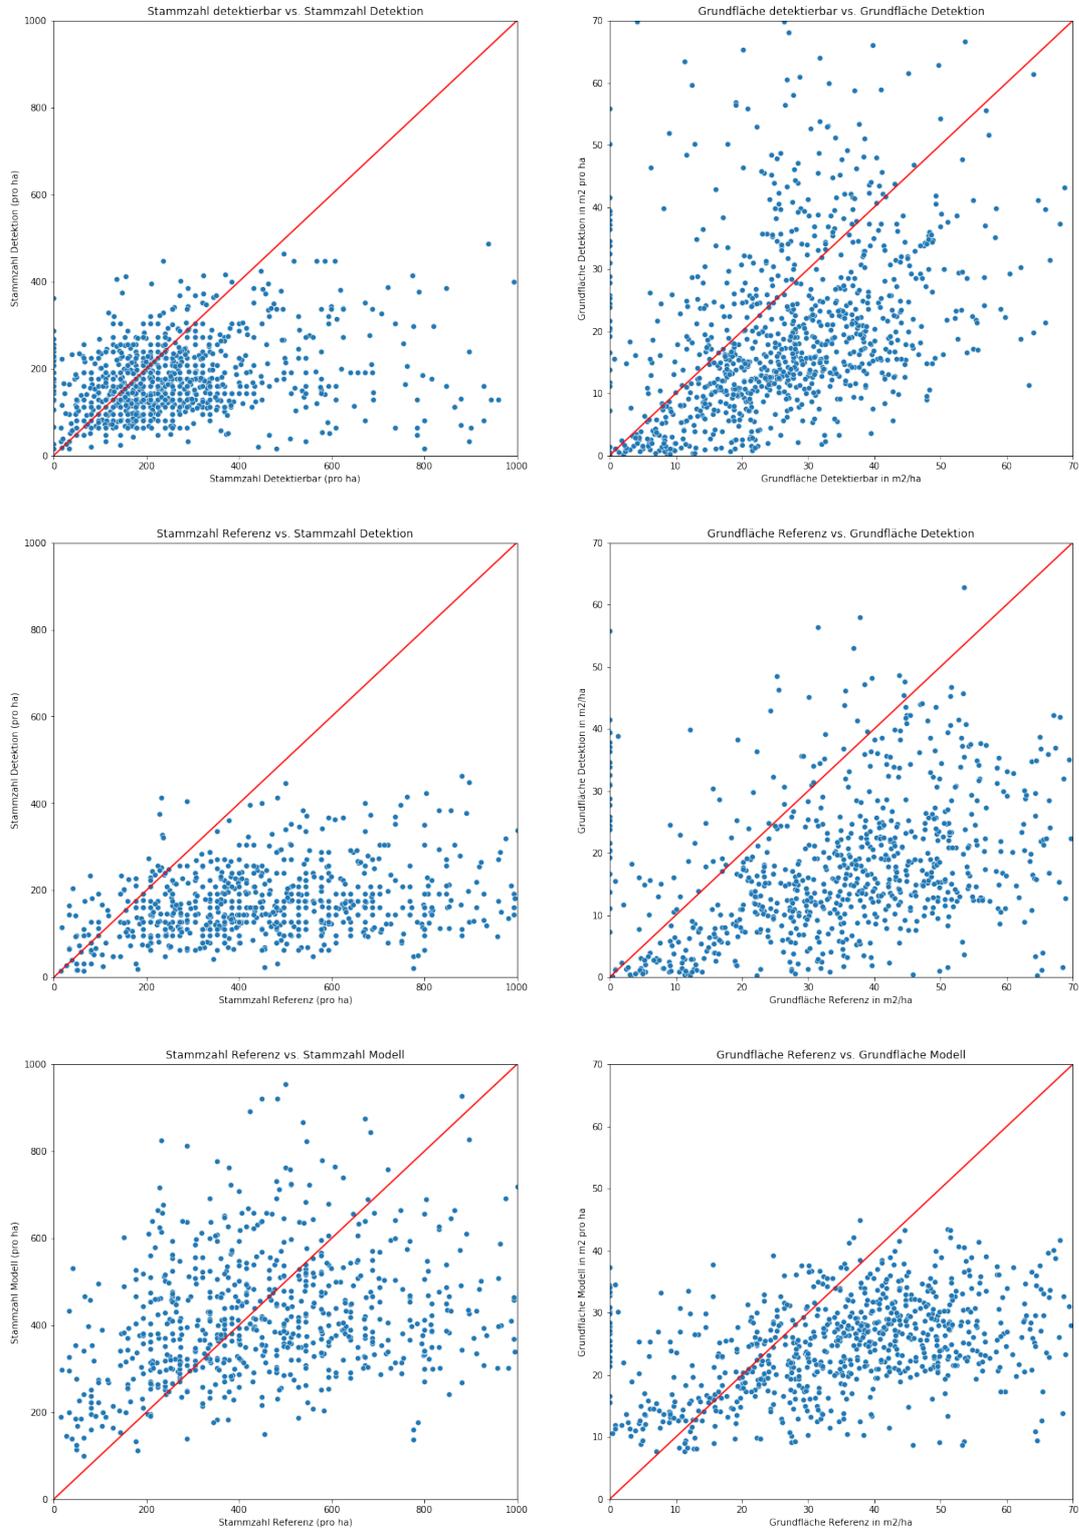


Abbildung 7.5.: Scatterplots zur Stammzahl und Grundfläche. Oben: Detektion vs. IDW-detektierbare Bäume in den Validierungsflächen; Mitte: Detektion vs. Realität in den Validierungsflächen; Unten: Statistisch modellierte Stammzahl vs. Realität in den Validierungsflächen.

### 7.2.7. Modellierung Vorrat

Der Vorrat ist eine wichtige dendrometrische Grösse für die Waldplanung (Waldentwicklungspläne und Betriebspläne). Er ist sowohl ein Indikator für die Bestandsdichte als auch eine wichtige Grundlage für die Berechnung des Hiebsatzes pro Bestand und indirekt auf der Waldgebietsebene. Der Vorrat kann dank terrestrisch erhobener Inventare berechnet oder geschätzt werden. Die Erfassung des Vorrats auf der Ebene der einzelnen Bestände stellt jedoch einen erheblichen personellen und finanziellen Aufwand dar, der die Nutzung flächendeckender terrestrischer Inventuren stark einschränkt. Die Möglichkeit, aus Fernerkundungsdaten den Vorrat flächendeckend und mit ausreichender Genauigkeit (z.B. auf Bestandsebene) zu schätzen, würde einen deutlichen Mehrwert für die Waldplanung bringen. Es könnte auch die Genauigkeit von gross angelegten Waldinventuren, wie z. B. dem Landesforstinventar, verbessern, indem es eine Dateninterpolation zwischen den Parzellen ermöglicht. Im FINT-CH Projekt haben wir das Potenzial der gewonnenen Informationen für die Schätzung des Vorrats auf Bestandsebene getestet.

Der Vorrat wird von der WSL für jede Probefläche des Landesforstinventars (LFI) auf der Basis ihrer Inventur berechnet. Diese berechneten Vorratswerte werden als Trainingsdaten für Machine-Learning-Modelle verwendet. Für jede LFI-Probefläche wird die Fläche des äusseren Probekreises berücksichtigt (d.h. eine Fläche von 500 m<sup>2</sup>). Auf dieser Probefläche werden die einzelnen Bäume, die nach dem im FINT-CH-Projekt entwickelten Algorithmus erkannt und charakterisiert wurden, zur Berechnung der Anzahl der Stämme und der Grundfläche pro Hektar und pro Durchmesserklasse (für diese Anwendung werden 10-cm-Durchmesserklassen verwendet) herangezogen. Zusätzlich zu den Daten der detektierten Bäume werden aus dem Algorithmus des TBk-Tools, der seinerseits auf LiDAR-Daten basiert, die Werte für die Oberhöhe, den Deckungsgrad und den Nadelholzanteil ermittelt, die dem Bestand entsprechen, in dem sich das Zentrum der Probefläche befindet. Nach Ausschluss von Probeflächen, die sich am Waldrand oder an einer Bestandsgrenze befinden, verbleibt ein Datensatz mit 2'229 Probeflächen.

Es wurden verschiedene Machine-Learning-Modelle getestet: eine lineare Regression, eine Ridge-Regression, ein Multilayer-Perceptron (neuronales Netzwerk mit einer versteckten Schicht von Neuronen). Die Leistung der Modelle wird anhand des Bestimmtheitsmasses bewertet und verglichen, das basierend auf einem Set von Testdaten (20 % der Daten) berechnet wird, die nicht für das Training des Modells verwendet wurden.

Unabhängig vom verwendeten Modell wurden die besten Ergebnisse erzielt, wenn der Vorrat als endogene Variable verwendet wurde, ohne transformiert zu werden (keine Skalierung, keine Log-Transformation). Die Ergebnisse waren nach einer Standardskalierung der exogenen Variablen ähnlich oder sogar etwas besser, so dass diese Skalierung beibehalten wurde. Die Einführung von Sekundärvariablen, die den Quadraten oder Logarithmen der oben genannten Primärvariablen entsprechen, brachte keine Verbesserung der getesteten Modelle, daher wurden diese Sekundärvariablen nicht beibehalten. Die Test-Bestimmtheitsmasse, die für die drei getesteten Modelle (und basierend auf der gleichen Aufteilung zwischen Trainings- und Testdaten) erhalten wurden, betragen 57.5% für die lineare Regression, 57.8% für die Ridge-Regression und 58.2% für das Multilayer-Perceptron. Der Unterschied zwischen dem Test- und dem Trainings- $R^2$  war in allen drei Fällen minimal (in der Grössenordnung von 1%, manchmal zu Gunsten des Test- $R^2$ ), was ein Fehlen von Overfitting widerspiegelt. Dieses Fehlen von Overfitting erklärt sich durch die grosse Anzahl von Trainingspunkte (fast 1800) im Verhältnis zur Anzahl der exogenen Variablen (19). Der geringe Leistungsgewinn des Multilayer-Perceptron im Vergleich zu linearen Modellen erklärt sich durch das fehlende Overfitting, aber auch durch das scheinbare Fehlen nichtlinearer Effekte. Aufgrund ihrer schnellen Ausführung wurde die Ridge-Regression auf 100 verschiedenen zufälligen Partitionen der Daten zwischen Trainings- und Test-Sets angewendet, was zu einem durchschnittlichen Test- $R^2$  von 55.3% führte. Ein Verfahren zur Recursive Feature Elimination wurde verwendet, um die exogenen Variablen in der Reihenfolge ihrer Wichtigkeit zu ordnen. Es wird deutlich, dass die Variablen aus dem TBk-Algorithmus (Oberhöhe, Deckungsgrad und Nadelholzanteil) die Wichtigsten sind. Zusammen erlauben sie uns, einen Test- $R^2$  von 53.6% zu erreichen. Dies ist nicht überraschend, da diese auf Bestandsebene aggregierten Variablen einen hohen Informationsgehalt über den Bestand haben, der hoch mit dem Vorrat korreliert. Die Daten zu einzelnen Bäumen, die vom FINT-CH-Algorithmus erkannt werden, ermöglichen jedoch eine Verbesserung der Leistung des Modells. Angesichts der weitgehenden Gleichwertigkeit der drei getesteten Modelle und der Tatsache, dass der Ridge-Regressor auf vielen verschiedenen Partitionen der Daten getestet werden konnte, haben wir uns entschieden, dieses Modell für die Generierung der Ergebnisdaten im FINT-CH Projekt zu verwenden.



## 8. Fallbeispiele

Innerhalb vom FINT-CH Projekt wurden vier Fallbeispiele erarbeitet, in denen die produzierten Daten zu spezifischen Fragenstellungen aus der Praxis angewendet werden. In diesem Kapitel werden diese Fallbeispiele im Detail präsentiert.

### 8.1. Fallbeispiel 1: Lokalisieren dominanter FINT-CH Bäume

Um das genaue Lokalisierungspotenzial einzelner Bäume zu untersuchen, wurden zwei Analysen durchgeführt: eine fernerkundliche Analyse anhand von Z-Baumkoordinaten (Kap. 8.1.1) und die Überprüfung von FINT-CH Bäumen im Feld (Kap. 8.1.2) Die FINT-CH Bäume wurden dafür unter Verwendung der ermittelten Höhe in ein Baumhöhenranking mit vier Klassen unterteilt: 'Top 20', 'Top 50' und 'Top 100' der höchsten Bäume pro Bestandshektar (ein Bestand mit 0.5 ha erhält so 10 Bäume der Klasse 'Top 20', 25 Bäume der Klasse 'Top 50' usw.) sowie eine Sammelklasse 'Rest' für alle anderen Bäume.

#### 8.1.1. Fernerkundliche Analyse anhand von Z-Baumkoordinaten

In einer ersten Analyse wurde untersucht, ob sich die FINT-CH Ergebnisse problemlos mit bekannten Z-Bäumen matchen lassen (hier wird angenommen, dass alle Z-Bäume zu den dominierenden Bäumen gehören). Die Z-Baumkoordinaten wurden von der Burgergemeinde Bern zur Verfügung gestellt. Es wurden insgesamt 6910 Z-Bäume in den Waldgebieten Bremgartenwald und Spilwald untersucht. Die Untersuchung fand mit fernerkundlichen Methoden in QGIS statt und wurde basierend auf den Koordinaten der Bäume durchgeführt.

Ein Toleranzradius  $r$  um die Z-Bäume wurde eingeführt um zwei Arten von Ungenauigkeiten zu kompensieren: (1) ungenaue GPS-Koordinaten der Z-Bäume, die am Stammesfuss erhoben wurden und (2) Abweichung zwischen Burgergemeinde-Koordinaten am Stammesfuss und von FINT-CH detektierter Baumspitze.

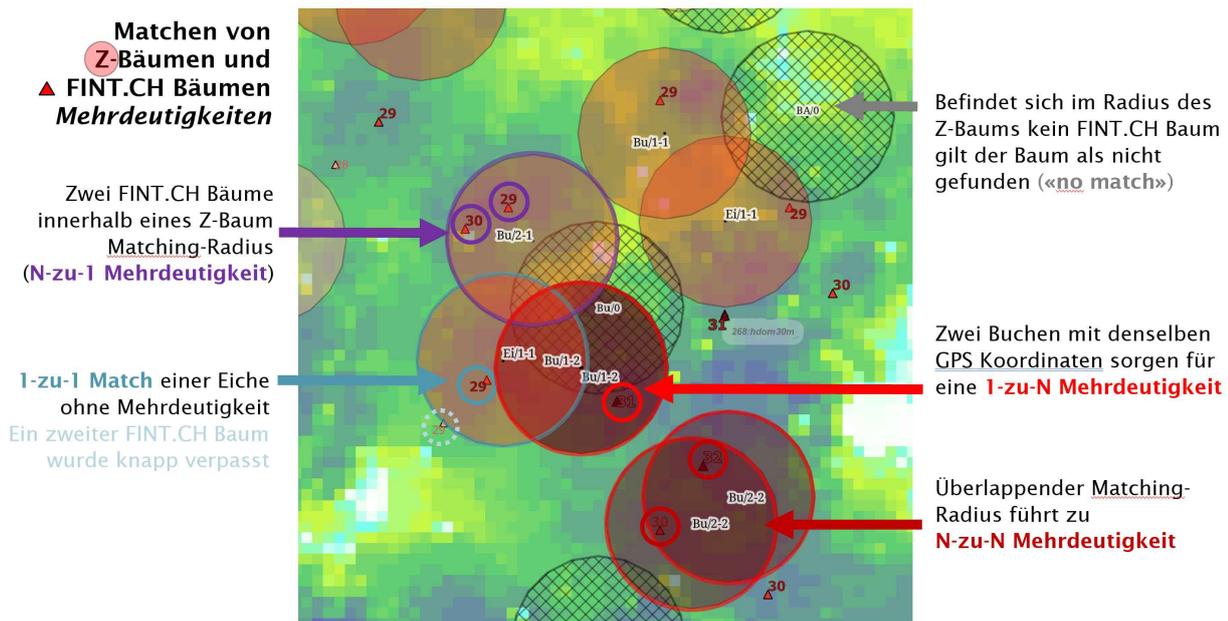


Abbildung 8.1.: Beispiele für Treffer und Mehrdeutigkeiten zwischen Z-Bäumen und FINT-CH Bäumen in einem Mischbestand aus Buche und Eiche.

Die Festlegung des Parameters  $r$  ist ein Kompromiss zwischen Eindeutigkeit ('1-zu-1') und Trefferquote. Ein grosser Toleranzradius  $r$  erhöht die Trefferquote aufgrund der höheren Wahrscheinlichkeit, dass ein FINT-CH Baum zugeordnet werden kann. Gleichermassen erhöht dies allerdings auch zweierlei Mehrdeutigkeiten (vgl. Abbildung 8.1) : Ein Z-Baum 'findet' bei grösserem  $r$  mehrere FINT-CH Bäume ('1-zu-N') oder ein FINT-CH Baum liegt in den Radien mehrerer Z-Bäume ('N-zu-1').

Für den Toleranzradius  $r$  wurde ein Wert von 4 m gewählt. Für Abweichungen zwischen Stammfuss und von FINT-CH detektierbarer Baumspitze wurden im Feld bis zu 12 m gemessen, allerdings ist eine so hohe Abweichung unüblich und ein Toleranzradius von 12 m aufgrund der Doppeldeutigkeiten nicht sinnvoll.

### Generelle Übereinstimmung

69 % der Z-Bäume konnten mit mindestens einem FINT-CH Baum im Radius von 4 m gepaart werden. Dabei traten in etwa der Hälfte der Fälle die oben erwähnten Ambiguitäten auf: Im Durchschnitt wurden 1.5 FINT-CH-Bäume pro Z-Baum gefunden, respektive für jeden zweiten Z-Baum gibt es mehr als einen FINT-CH Treffer in einem Toleranzradius von 4 Metern ('1-zu-N'). Andersherum gibt es für alle gepaarten FINT-CH Bäume im Durchschnitt 1.25 Z-Bäume, die als Paarungs-Kandidaten gelten könnten, d.h. jeder vierte FINT-CH Baum befindet sich im 4 Meter Radius von mindestens zwei Z-Bäumen ('N-zu-1'). 33% der Z-Bäume konnten eindeutig mit genau einem FINT-CH Baum gepaart werden.

### Baumhöhenranking

Die Verteilung des Baumhöhenrankings der mit Z-Bäumen gepaarten FINT-CH Bäume (siehe Abbildung 8.2 links) entspricht annähernd der Verteilung des Baumhöhenrankings aller FINT-CH Bäume in den untersuchten Beständen (prozentualer Anteil jeweils in Klammern angegeben). 13 % der zugeordneten FINT-CH Bäume sind in der 'Top 20' (vs. 11 % insgesamt), 17 % in 'Top 50' (vs. 16 %), 27 % in 'Top 100' (vs. 25 %) und 42 % in der Klasse 'Rest' (vs. 47 % insgesamt). Die Abweichungen von 2-5 % von der Gesamtverteilung sind zugunsten von höheren Bäumen, d.h. mit schwacher Tendenz werden 'dominantere' Bäume den Z-Bäumen zugeordnet. Diese Tendenz gilt als wünschenswert, da von einem Z-Baum ein hohes Dominanzkriterium (hier "Baumhöhenranking") zu erwarten ist.

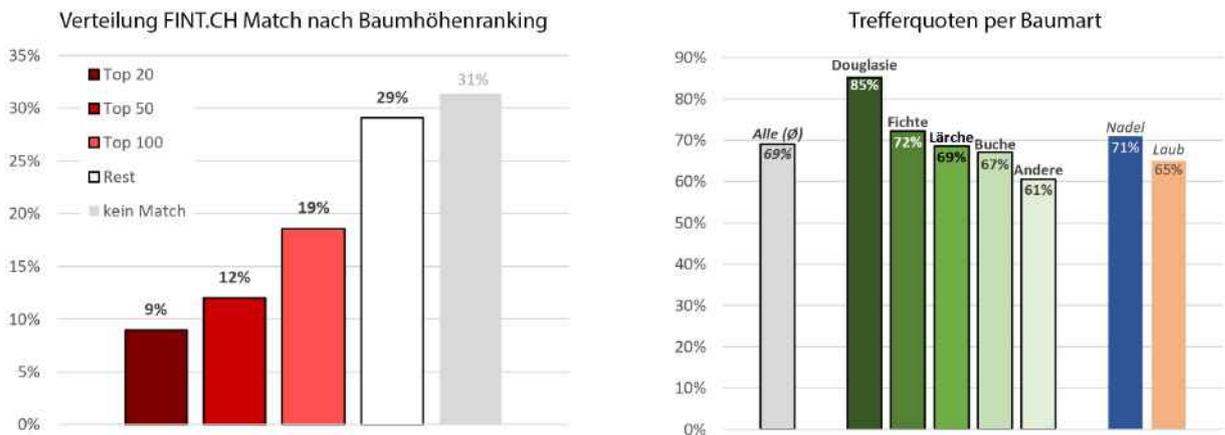


Abbildung 8.2.: Statistiken zur Verteilung der Z-Bäume auf das FINT.CH Höhenranking (links) und die Trefferquote per Baumart bzw. nach Nadel- und Laubholz differenziert (rechts)

### Baumarten

In den Beständen waren vor allem Buche und Fichte vertreten (je 38 %). Neben ihnen wurden Lärche (4 %) und Douglasie (3 %) näher untersucht. Für alle anderen Baumarten waren nur wenige Individuen vertreten, sie wurden zur Klasse 'Rest' zusammengefasst. Gegenüber der generellen Trefferquote (69 %, bzw. 33 % für eindeutige Treffer) variieren die baumartspezifischen Trefferquoten um 2-8 %. Die beste Trefferquote wurde mit Abstand für Douglasie erzielt (85%) - hier gibt es im untersuchten Bestand allerdings überwiegend alte Douglasien, die im VHM und somit für FINT-CH klar differenzierbar sind. Fichte (72 %) und Lärche (69 %) erzielten ebenfalls überdurchschnittliche Trefferquoten. Buche ist leicht unterdurchschnittlich (67 %), sowie die Klasse 'Rest' (60 %), die überwiegend aus Laubbäumen besteht. Dadurch wird der Trend deutlich, dass die Zuordnung für Nadelbäume (Trefferquote 71 %) erwartungsgemäss besser funktioniert als für Laubbäume (Trefferquote 65%), wobei der Unterschied nicht so gross ist.

### Bestandeshöhe

Die Vermutung liegt Nahe, dass Bestände mit älteren, hohen Individuen zu besseren Ergebnissen führen sollten. Betrachtet man die Trefferquote aufgeteilt nach Beständen und der Oberhöhe (der jeweiligen Höhe der dominierenden Schicht), so zeigt sich ein überraschendes Bild: In unserem Beispiel trifft die Vermutung mit kontinuierlich steigender Trefferquoten von 0 bis 25 m hdom zu. Danach (hdom > 30 m) nimmt die Trefferquote jedoch wieder ab.

Bei der Untersuchung der vorherrschenden Baumarten (Buche und Fichte) lässt sich diese Beobachtung differenzieren: Für Fichte in Mischbeständen lässt sich der Effekt nicht nachweisen, die Trefferquote bleibt für Bäume >30 m ungefähr gleich (Abbildung 8.4 rechts). Hingegen sehen wir den Effekt deutlich bei Laubbäumen, in Abbildung 8.4 repräsentiert links durch Buche in Laubwald-Beständen. Da die untersuchten Bestände zu zwei Dritteln Laubwald-Bestände (0-30 % Nadelholzanteil [NH]) und fast einem Drittel Mischwald-Bestände (30-70 % NH) sind, fällt dies schwer ins Gewicht (lediglich 7 % der Bäume sind in Nadelholzbeständen (>70 % NH)). Der Effekt ist somit vermutlich darauf zurück zu führen, dass mit wachsender Höhe die Laubbaum-Kronen grösser und ausdifferenzierter werden. Damit werden ganze Flächen anfälliger für Fehldetektionen, fehlende Detektionen und Dislokationen durch den FINT-CH Algorithmus. Die schlechteren FINT-CH Ergebnisse beeinträchtigen auch die Ergebnisse für die Nadelbaumarten in Laubwald-Beständen (z.B. Fichte, siehe Abbildung 8.4 Mitte).

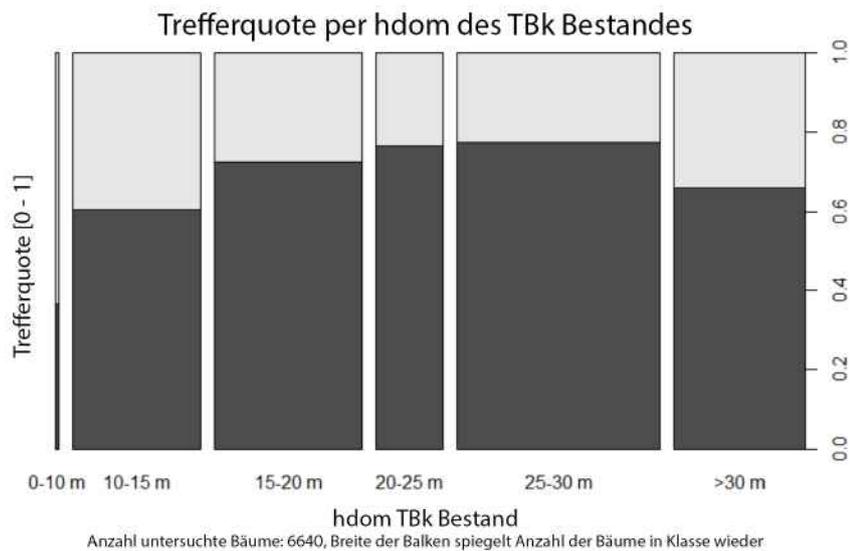


Abbildung 8.3.: Die Trefferquote aufgeschlüsselt nach hdom der TBk-Bestände. Dies zeigt nicht die Trefferquote pro Höhe der Bäume, da für Z-Bäume ohne Match keine Höhe verfügbar ist.

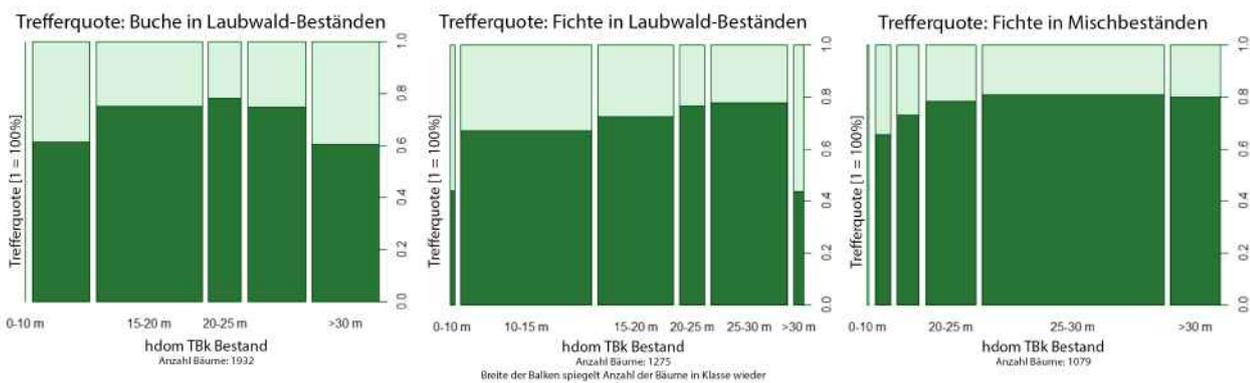


Abbildung 8.4.: Trends der Trefferquote für Buche / Fichte in Laub- und Mischbeständen.

### Gesamtergebnis und Diskussion

Einem Drittel der Z-Bäume konnten eindeutig FINT-CH Bäume zugewiesen werden, wodurch die Daten direkt um eine Höhe der Bäume ergänzt werden können. '1-zu-N'-Doppeldeutigkeiten können gelöst werden, indem die verschiedenen Matches verglichen und nach bestimmten Plausibilitätskriterien ein eindeutiger Match ausgewählt wird. 'N-zu-1'-Doppeldeutigkeiten sind schwieriger aufzulösen, aber auch hier kann ein Vergleich von BHD (Z-Baum) und Höhe (FINT-CH-Baum) eine eindeutige Zuweisung ermöglichen. Wir schätzen, dass mit einer (semi-)automatischen Auflösung von Doppeldeutigkeiten eine eindeutige Trefferquote von 50 % im Mittel erreicht werden kann. Dabei schwankt die Qualität der Ergebnisse erwartungsgemäss durch die Art der Bestände. Insbesondere spielen Gleichförmigkeit und Nadelholzanteil eine grosse Rolle.

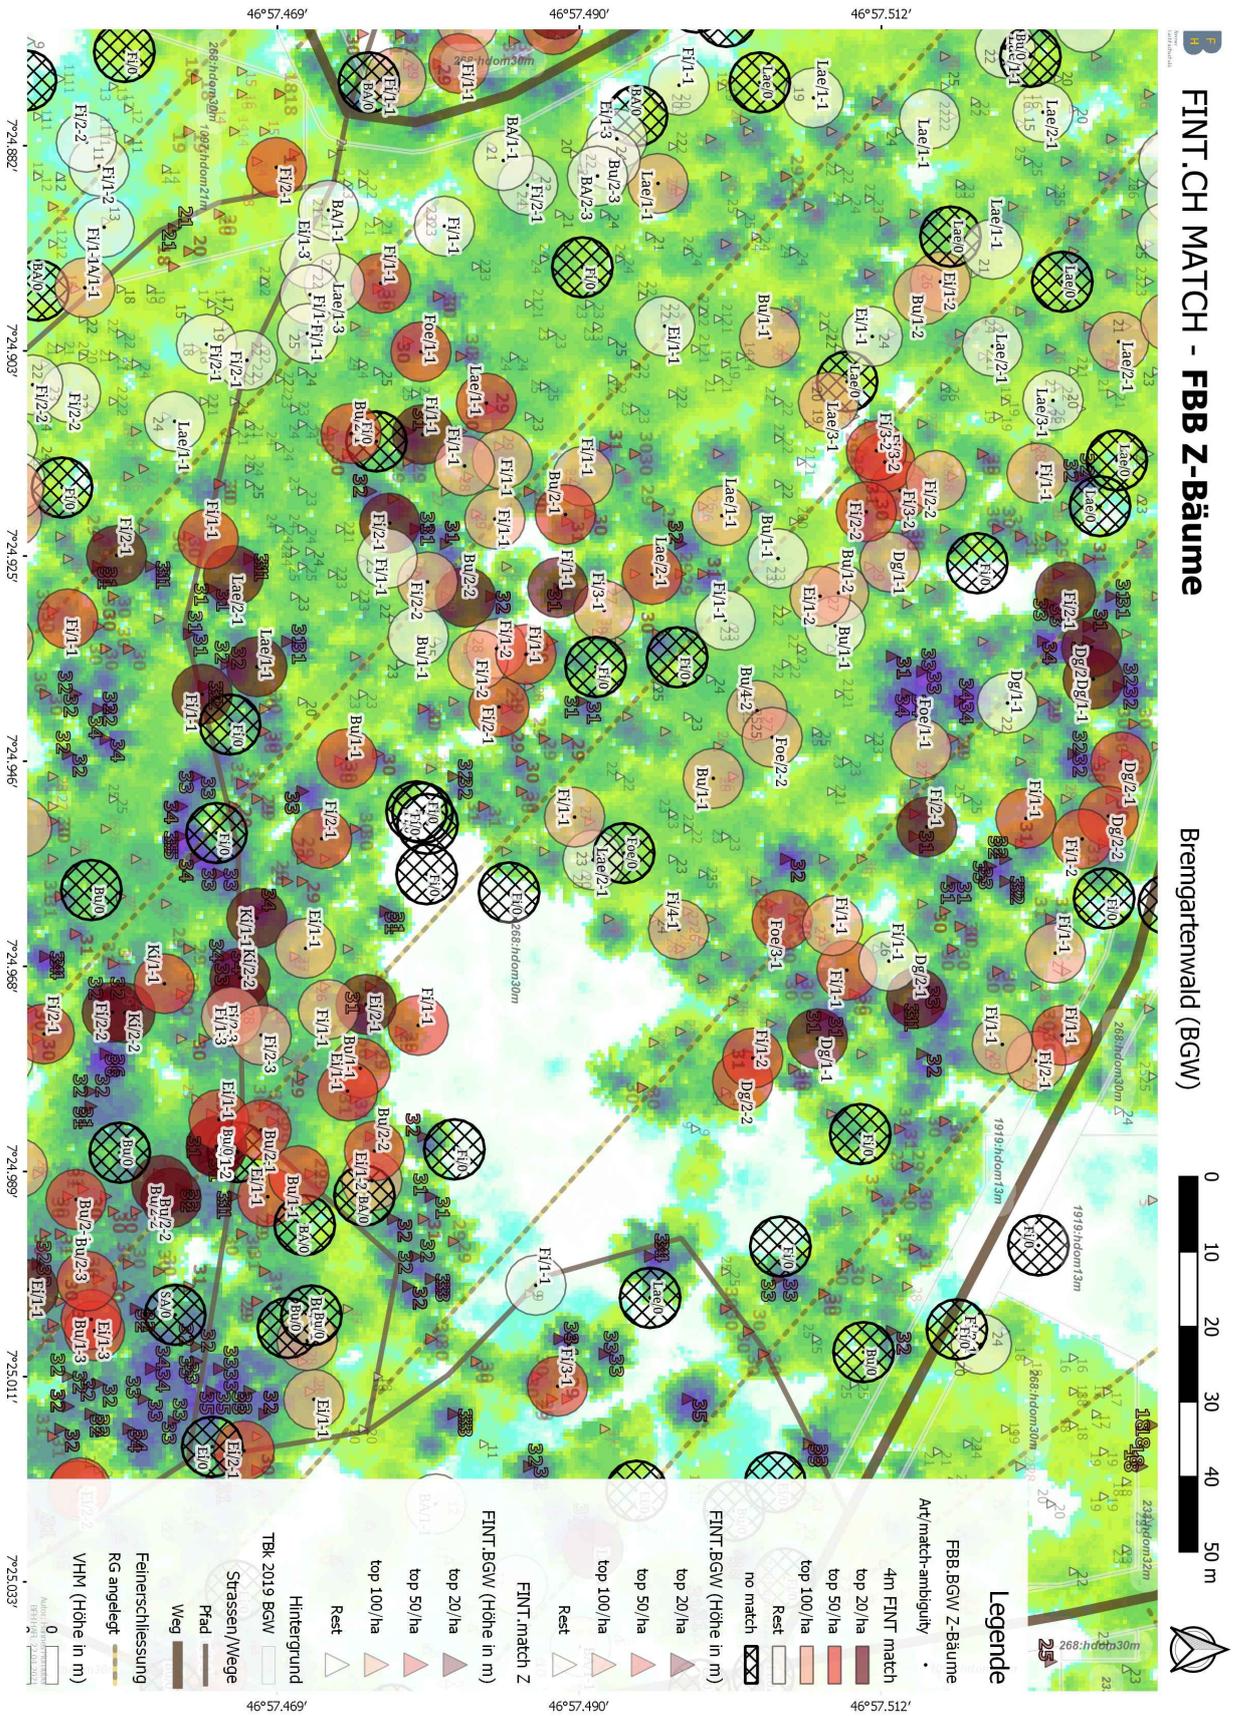


Abbildung 8.5.: Übersichtskarte Z-Bäume mit FINT-CH Matches.

### 8.1.2. Feldinventur von FINT-CH Bäumen in Beobachtungsflächen

Auch in dieser Analyse wurden die Informationen der FINT-CH Bäume wie eingangs beschrieben, anhand eines Baumhöhenrankings pro Bestandshektar eingeteilt in die Rankingklassen 'Top 20', 'Top 50' und 'Top 100'. Die stichprobenweise Überprüfung der FINT-CH Baumpositionen im Feld fand auf 12 PPSS-Flächen (*Placette Permanente de Suivi Sylvicole*; [12]) statt. Bei den PPSS-Flächen handelt es sich um dauerhafte Beobachtungsflächen, in welchen jeder Baum ab einer Kluppschwelle von 12 cm BHD mit der genauen Baumposition, BHD und Baumart erfasst wurde. Die PPSS-Flächen sind auf der Website [martelage.sylvotheque.ch](http://martelage.sylvotheque.ch) einsehbar. Die Stichprobenüberprüfung in den PPSS-Flächen ermöglichte einen Abgleich der genauen Baumposition mit der ermittelten FINT-CH Baumpositionen. Das Ziel der stichprobenweisen Überprüfung der FINT-CH Baumpositionen im Feld war es somit, erste Erfahrungen hinsichtlich der Genauigkeit der auf Fernerkundungsdaten generierten Information zur Einzelbaumposition zu sammeln und praktische Anwendungsmöglichkeiten zu ermitteln.

#### Material und Methodik

Für die Überprüfung der FINT-CH Baumpositionen im Feld wurden Karten mit den Baumpositionen nach Rankingklassen für die entsprechenden PPSS-Flächen verwendet. Als Basis der Karte diente das Vegetationshöhenmodell (VHM) der Burgergemeinde Bern aus dem Jahr 2019. Zusätzlich diente die Übersichtskarte der PPSS-Flächen (siehe Abbildung 8.6) zur Orientierung und ermöglichte den Abgleich der FINT-CH Baumpositionen mit der genauen Baumposition in der jeweiligen PPSS.

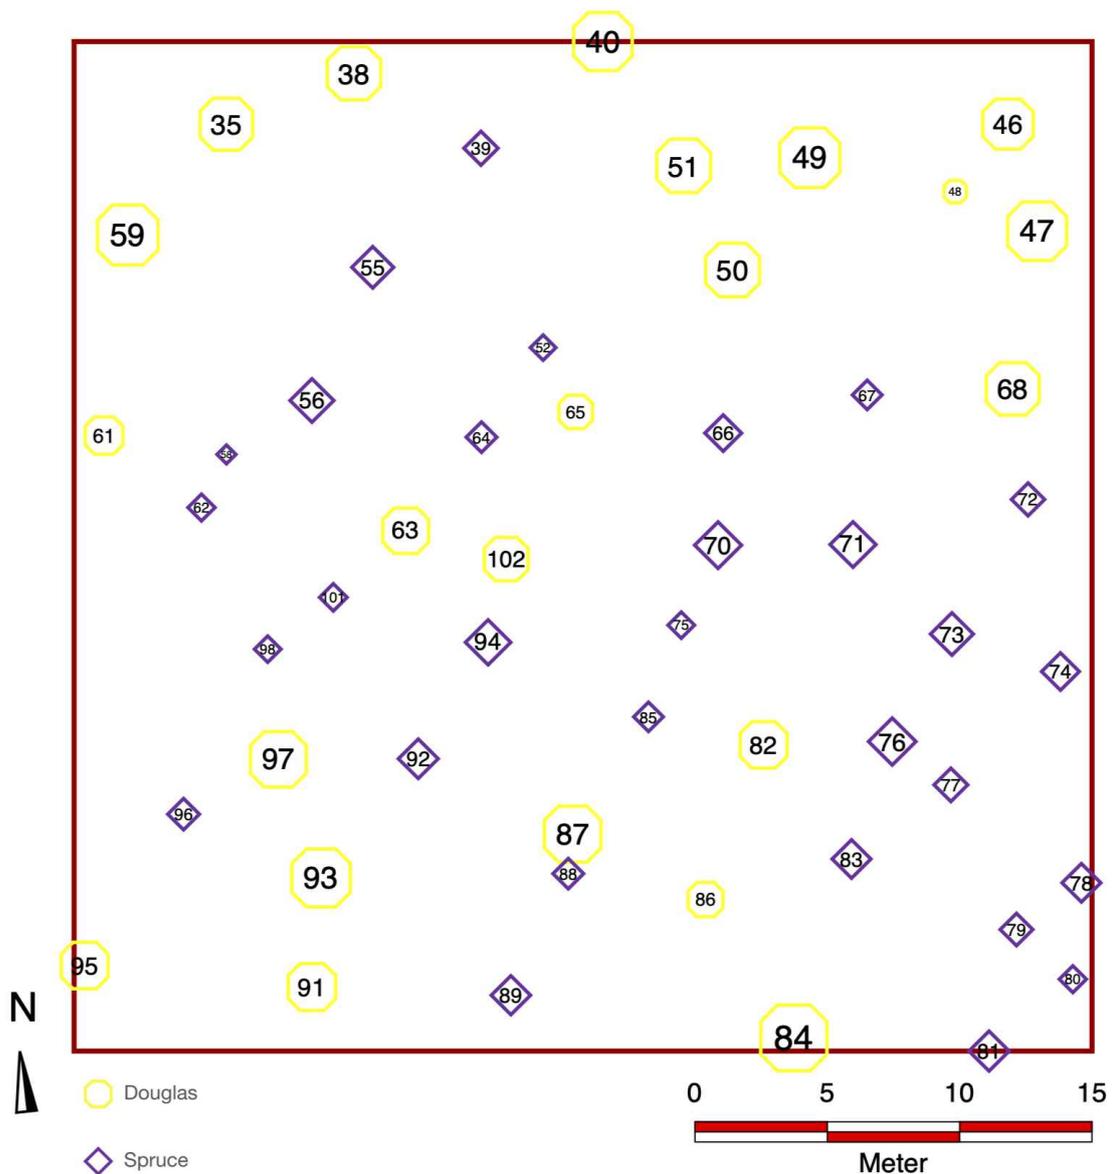


Abbildung 8.6.: Übersichtsplan einer PPSS am Beispiel der PPSS59 mit Douglasie und Fichte (Spruce).

Die dominierenden Bäume in der PPSS wurden auf der Karte 'FINT.CH Ergebnisse' (siehe Beispiel auf Abbildung 8.7) auffindig gemacht und dienten jeweils als Referenzpunkte zur Orientierung in der PPSS. Die GPS-basierten Eckpunkte der PPSS auf der Karte wurden im Gelände anschliessend überprüft und gegebenenfalls auf der Karte korrigiert. Die FINT-CH Baumpositionen der 'Top 20 Bäume' gemäss der Karte wurden mit der Position der Bäume in der PPSS abgeglichen. Gestartet wurde am nördlichsten Eckpunkt der PPSS. Durch systematisches Ablaufen der Fläche wurden die FINT-CH Baumpositionen fortlaufend mit den wirklichen Baumpositionen abgeglichen. Die der FINT-CH Baumposition entsprechende Baumnummer in der PPSS wurde direkt auf die Karte notiert. Je nach Präzisionsgrad bzw. Übereinstimmung der FINT-CH Baumposition mit der wirklichen Baumposition wurde eine Bewertung von 0, 1 oder 2 angegeben:

- 0= Keine Übereinstimmung: Die FINT-CH Baumposition kann nicht einem individuellen Baum zugeordnet werden. Mehrere Baumnummern kommen bei einem Präzisionsgrad von 3 m an der entsprechenden Position in Frage oder kein Baum ist an der entsprechenden Stelle vorhanden.

- 1=Unpräzise Übereinstimmung: Die FINT-CH Baumposition kann einem entsprechenden Baum zugeordnet werden, die Baumposition ist allerdings unpräzise (Präzisionsgrad bis 3m).
- 2=Klare Übereinstimmung des entsprechenden Baumes: Die FINT-CH Baumposition auf der Karte kann eindeutig einem Baum in der PPSS zugewiesen werden. Der Baum ist als solches auf der Karte erkennbar und die Baumposition stimmt mit der Realität überein (Präzisionsgrad bis 1m).

Die durchschnittliche Zeit zur Auffindung eines individuellen Baumes wurde am Ende der Übung notiert. Dasselbe Vorgehen wurde für die 'Top 50 Bäume' und für die 'Top 100 Bäume' durchgeführt. Auch hier wurde die durchschnittliche Zeit zur Auffindung eines individuellen Baumes notiert. Die Restbäume (Bäume ohne Rankingklasse) wurden nicht berücksichtigt. Als Illustration wurde die Karte der PPSS59 mit den bereits ergänzten Baumpositionen gemäss der PPSS auf der nachfolgenden Abbildung 8.7 aufgeführt.

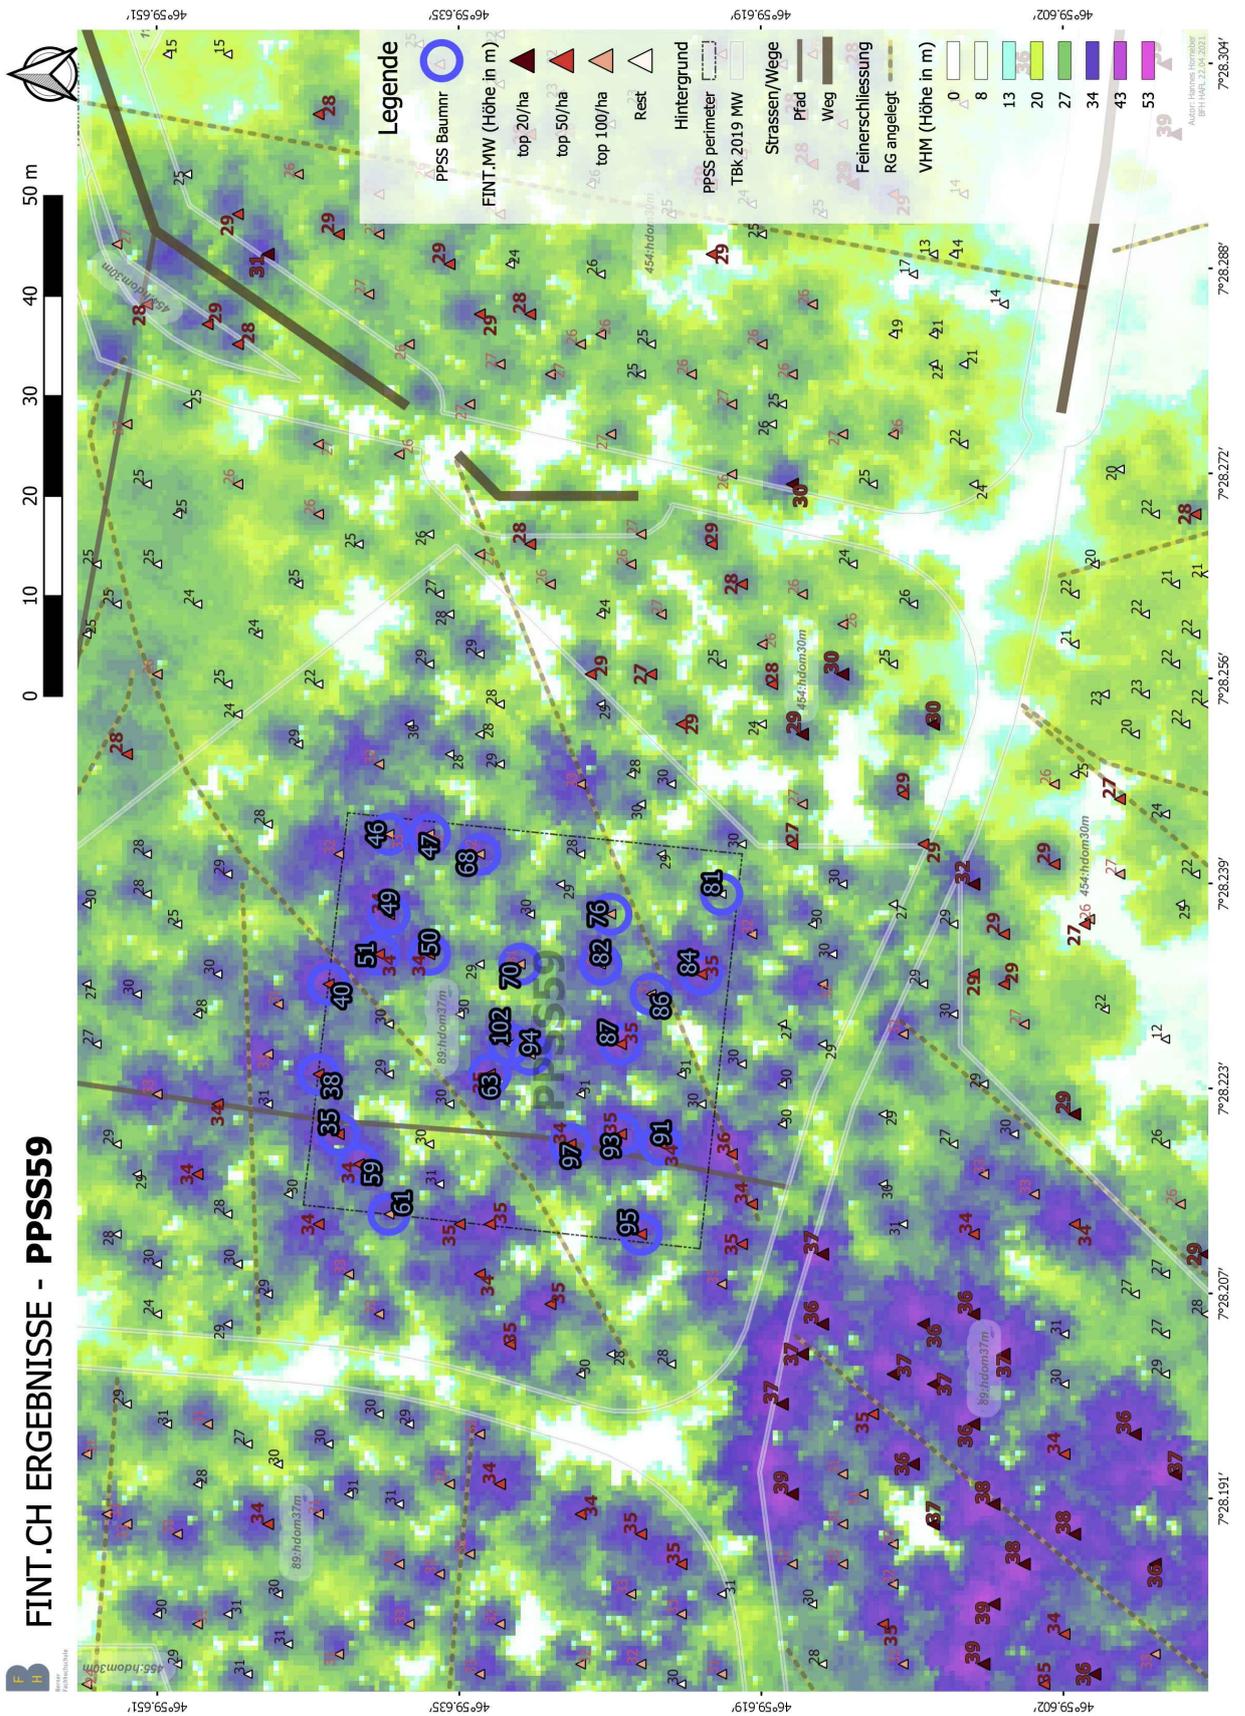


Abbildung 8.7.: Karte der PPSS59 mit den FIN-CH Baumpositionen (rot) und den entsprechenden Baumnummern in der PPSS (blau).

## Ergebnisse der Überprüfung im Feld

Im nachfolgenden Abschnitt werden die Ergebnisse der gesammelten Erfahrungen in den 12 PPSS-Flächen mit den FINT-CH Baumpositionen präsentiert. Als wichtige Elemente bei der Überprüfung im Feld wurden der Anteil der jeweils übereinstimmenden PPSS-Baumposition mit der FINT-CH Baumposition (mit Bewertung 1 und 2) pro Rankingklasse und Baumart, die dafür benötigte Zeit pro Baum sowie die Beziehung der erwähnten Faktoren zur Oberhöhe und zum Dominanzindex erachtet.

In der Abbildung 8.8 ist der Anteil der im Feld effektiv gefundenen FINT-CH Baumpositionen in Abhängigkeit der Variablen Oberhöhe, Hauptbaumart bzw. Rankingklassen pro PPSS aufgeführt. Grundsätzlich waren Nadelhölzer (Fichte, Douglasie, Föhre und Tanne) leichter identifizierbar auf Grund der ausgeprägten Baumspitze als Laubbölzer. Die Nadelhölzer waren zudem auf dem Vegetationshöhenmodell besser als Einzelbäume sichtbar. Insbesondere in gleichförmigen Mischbeständen sind die Nadelhölzer infolge des stärkeren Höhenwachstum von den umgebenen Laubbäumen besser unterscheidbar. Dies erlaubt eine eindeutigere und schnellere Identifikation der dominierenden Bäume im Feld. Die Rankingklasse und die Baumart haben somit einen Einfluss auf den Anteil der gefundenen Bäume sowie auf die benötigte Zeit (Abbildung 8.9).

Eindeutige Referenzpunkte im Bestand wie Überhalterbäume, Rückegassen oder gut sichtbare Öffnungen im Kronendach dienen zudem als Orientierungshilfen, was das Auffinden der wirklichen Baumposition weiter erleichtert. Des weiteren ist die Identifikation der Bäume bei niedriger Stammzahl und bei ausgeprägter Ausdifferenzierung einfacher, weshalb der Anteil der gefundenen Bäume mit zunehmender Oberhöhe steigt und die benötigte Zeit für das Auffinden eines Baumes sinkt (Abbildungen 8.8 und 8.9). Die Regressionsgerade verdeutlicht die lineare Beziehung zwischen den untersuchten Variablen.

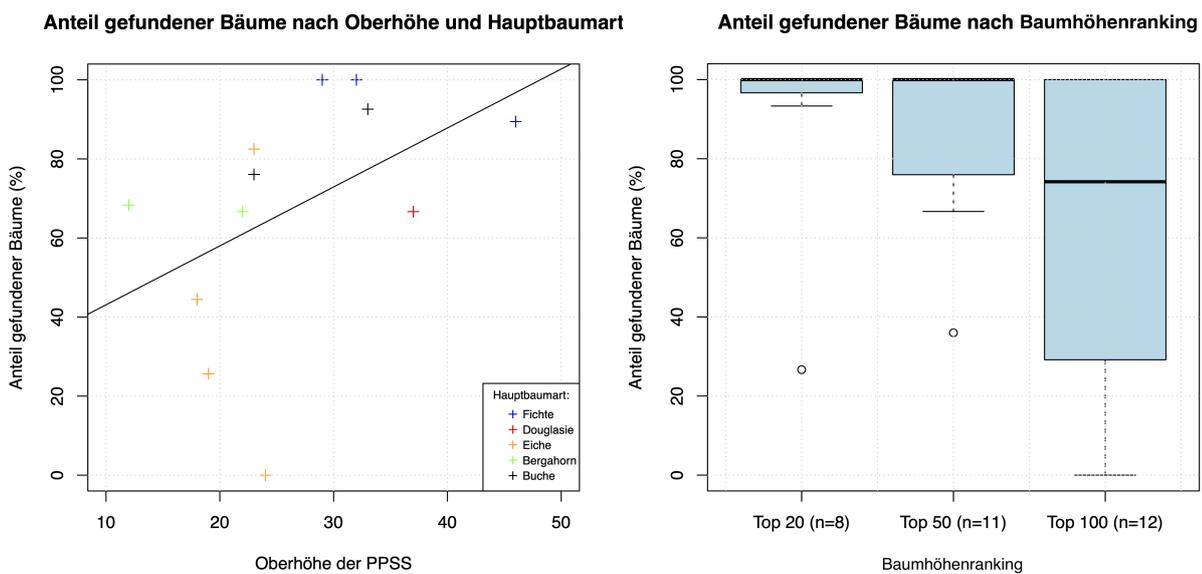


Abbildung 8.8.: Anteil in Prozent der gefundenen Bäume im Feld aller Rankingklassen abhängig von der Oberhöhe der PPSS mit der Information zur Hauptbaumart in der jeweiligen PPSS (links); Anteil in Prozent der gefundenen Bäume im Feld nach Rankingklassen pro PPSS (rechts).

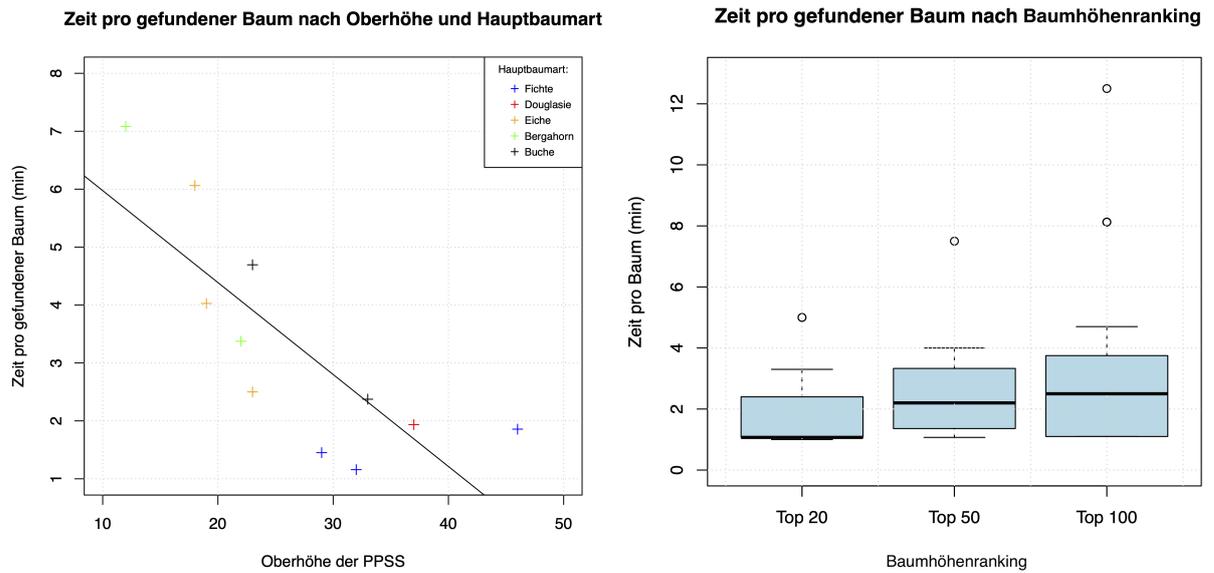


Abbildung 8.9.: Benötigte Zeit in Minuten pro gefundenen Baum abhängig von der Oberhöhe der PPSS mit der Information zur Hauptbaumart in der jeweiligen PPSS (links); Benötigte Zeit in Minuten pro gefundenen Baum nach Rankingklassen (rechts).

Wie im Abschnitt 'Material und Methodik' bereits erläutert, wurden den gefundenen Bäumen eine Bewertung von 1 oder 2 zugeteilt, welche von der Präzision des detektierten Baumes anhängig war. Die Bewertung 0 (=Einzelbaum nicht gefunden) wurde nachfolgend nicht berücksichtigt. In der Abbildung 8.10 wurde der zugewiesene Dominanzindex pro Baum in Abhängigkeit der Bewertung dargestellt. Der Dominanzindex scheint bei den untersuchten PPSS-Flächen keinen Einfluss auf die Bewertung und somit auf die eindeutige Zuweisung der FINT-CH Baumposition zu einem Einzelbaum im Feld zu haben.

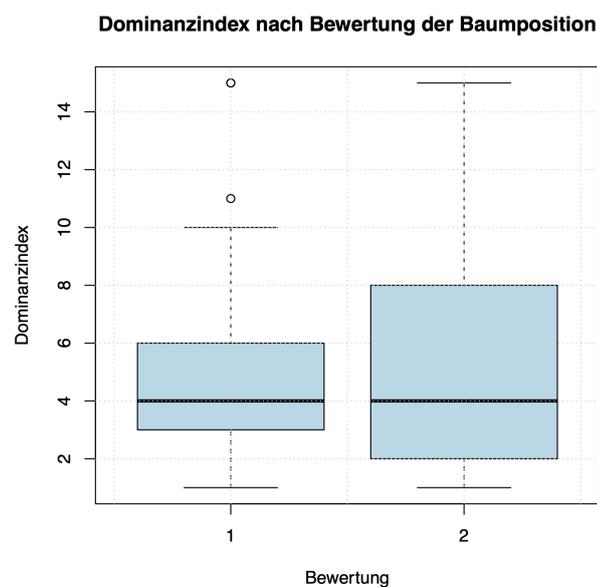


Abbildung 8.10.: Dominanzindex der gefundenen Bäume in Abhängigkeit der zugeteilten Bewertung.

## 8.2. Fallbeispiel 2: Kartierung von Lücken im Wald

Für die Kartierung der Lücken im Wald wurden zwei Methoden getestet und verglichen. Einerseits wurden Lücken auf Basis des VHM und andererseits Lücken auf Basis der detektierten Einzelbäume ausgeschieden. Der Prozess zur Bestimmung der Lücken ist in Abbildung 8.11 schematisch dargestellt. Für die Ausscheidung der Lücken basierend auf dem VHM wurden zunächst in der Originalauflösung alle Pixel mit Höhe  $\leq 3$  m als potenzielle Lücke klassiert und danach eine Aggregation mit Majority auf 10 m  $\times$  10 m Auflösung vorgenommen. Im Fall der Einzelbäume wurden die Punkte der detektierten Bäume direkt mit einer Auflösung von 10 m  $\times$  10 m rasterisiert. Bei beiden Methoden ist der verbleibende Prozess identisch. Die Lückenraster mit 10 m Auflösung werden auf die Waldmaske zugeschnitten und im Rahmen eines Vektorisierungsschritts anhand der 8er Nachbarschaft zu grösseren Lücken zusammengefasst. Für diese Lücken wird anhand der Flow Length (berechnet mit der D8 Methode) die Länge in Hangrichtung bestimmt. Lücken mit einer Flow Length von mehr als 20 m werden schlussendlich als problematische Lücken separat von den unproblematischen Lücken ausgegeben.

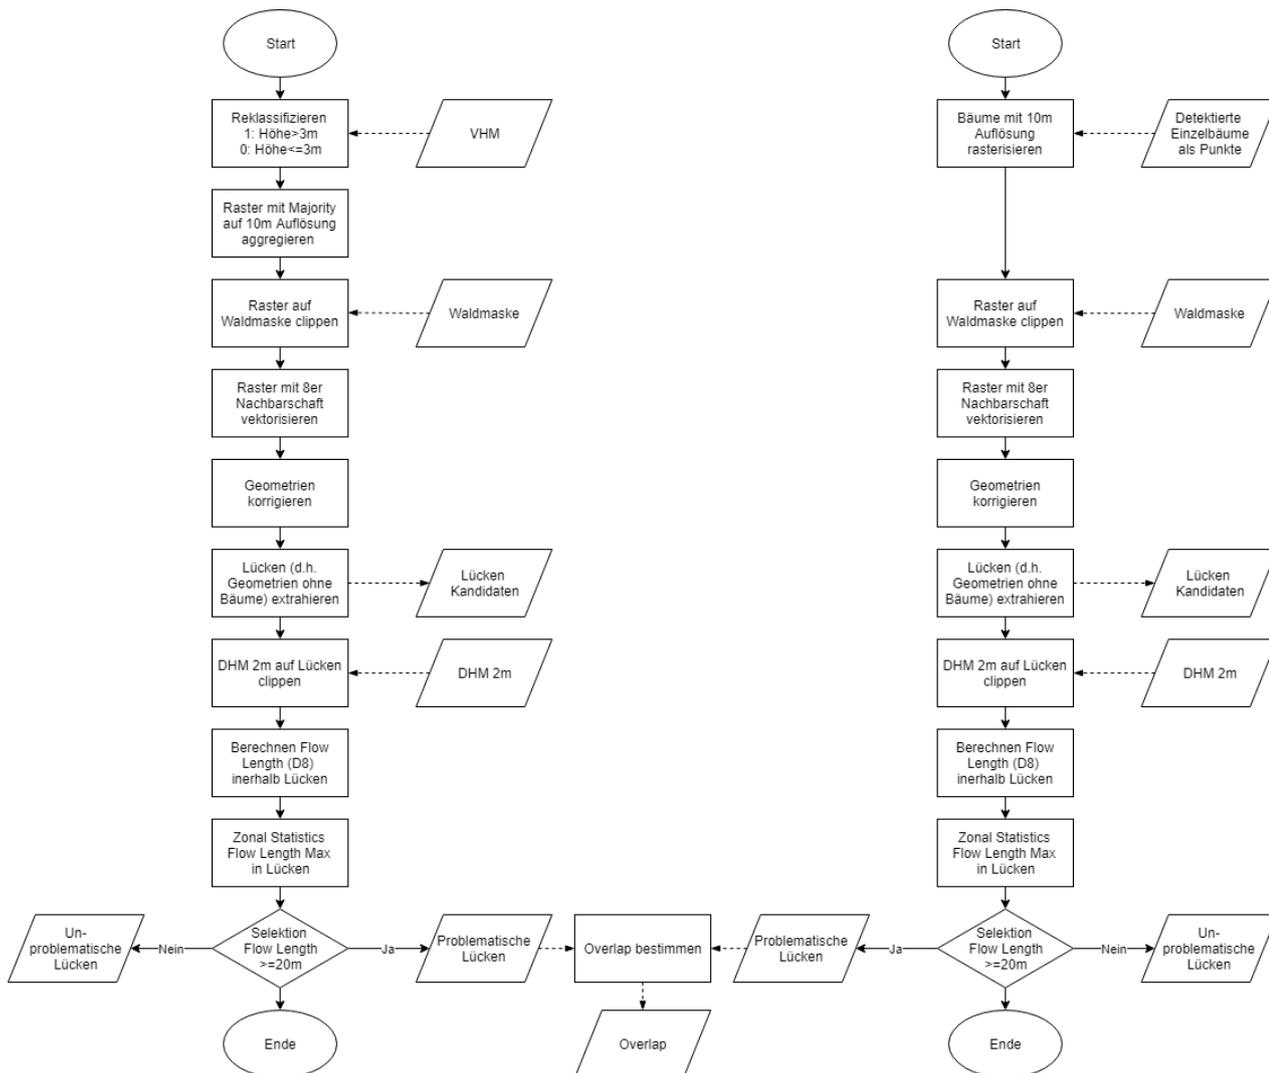
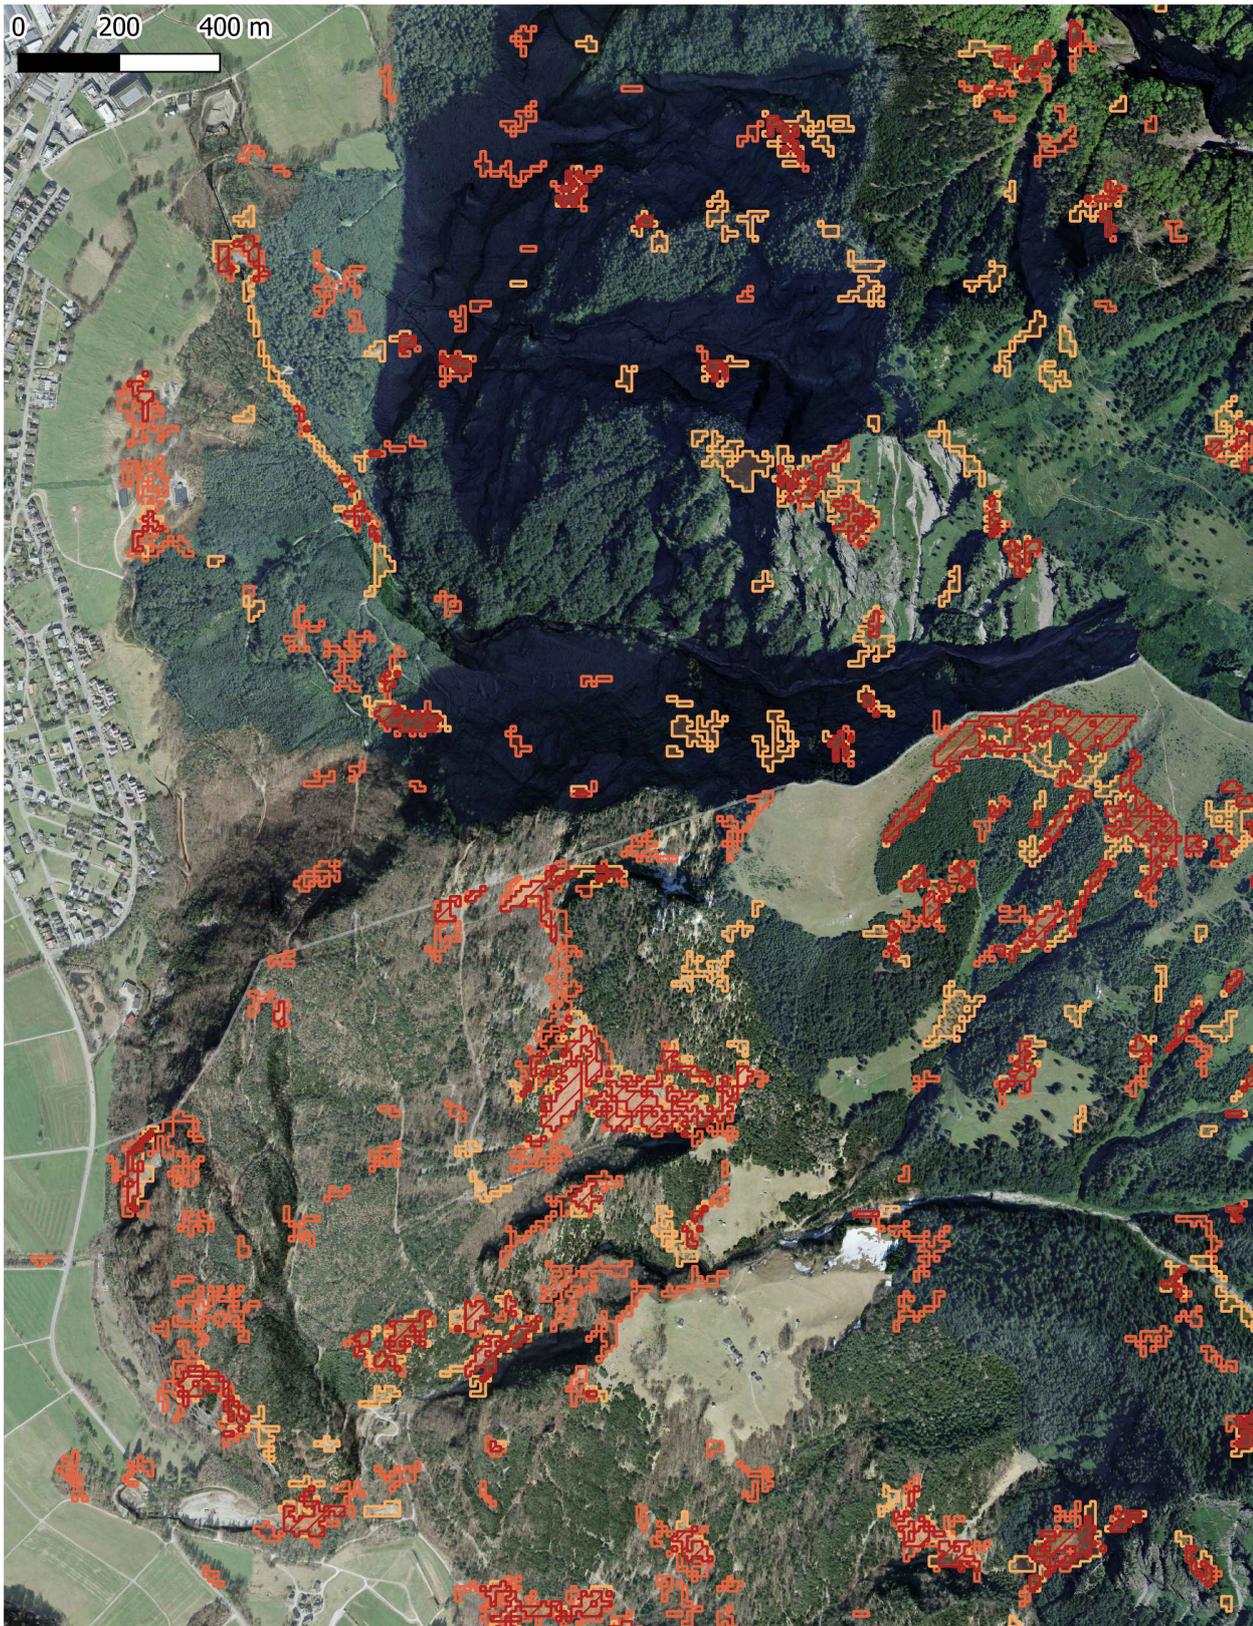


Abbildung 8.11.: Flowchart des Lücken-Detektionsprozesses.

Die beschriebene Methode wurde für den Kanton Graubünden und das Fürstentum Liechtenstein jeweils flächendeckend angewendet. Die Grundlage für die einzelbaumbasierte Variante waren in beiden Fällen die aufbereiteten Outputs aus der Detektion mit pyFINT innerhalb des FINT-CH Detektionsprozesses. Für die VHM basierte Variante wurde in Liechtenstein ein ALS basiertes VHM (Befliegung 2017) und für Graubünden das Luftbild basierte LFI VHM von 2016 verwendet. Die Verwendung des LFI VHM in Graubünden liegt darin bedingt, dass das ALS basierte VHM dort auf eine Befliegung von 2003 zurückgeht und somit als veraltet anzusehen ist. Die Abbildung 8.12 zeigt

einen Ausschnitt aus den Resultaten der Lückendetektion im Grenzgebiet zwischen Graubünden und Liechtenstein. Es werden nur die als problematisch eingestuften Lücken der beiden Methoden und deren Überlappung gezeigt. Es ist ersichtlich, dass sich mit den VHM und Einzelbaum Methoden leicht andere Resultate ergeben, es bei grösseren Lücken aber gute Überlappungen gibt. Insgesamt ist die Überlappung der einzelbaumbasierten Lücken im Vergleich zu den VHM basierten Lücken etwas grösser. Auf den Flächen im Kanton Graubünden sind an mehreren Stellen und insbesondere an Waldrändern sowie in höheren Lagen grössere Lücken zu sehen. Neben Kahlschlägen sind viele dieser Lücken auf eine weiter gefasste Definition von Wald, welche u.a. auch Gebüschwald beinhaltet, in der zugrundeliegenden Waldmaske zurückzuführen. Gerade die niedrigen Bäume im Gebüschwald oder nahe der Baumgrenze liegen teilweise unterhalb der festgelegten Limiten bei der Baumdetektion oder der Lückenausscheidung im VHM und werden deshalb als Lücken klassifiziert.



- Problematische Lücken Überlappung
- Problematische Lücken Einzelbäume
- Problematische Lücken VHM

**Quellen**

VHM ALS 2017 FL, WSL/swisstopo; VHM LFI 2016 GR, WSL; FINT-CH Bäume und Lücken, BFH  
 Hintergrund: SWISSIMAGE 2017, Swisstopo; swissALT3D multidirektionales Relief, Swisstopo; Kantonsgrenzen, Swisstopo;

Abbildung 8.12.: Visualisierung der detektierten Lücken, mit beiden Methoden, im Grenzgebiet GR und FL.

## 8.3. Fallbeispiel 3: Automatische Kartierung von potenziellen Anrissgebieten im Lawinen-Schutzwald

### 8.3.1. Generelles Vorgehen und Anforderungen

Ansätze zur besseren Quantifizierung der Schutzfunktion im Anriss-, Beschleunigungs- und Auslaufgebiet von Lawinen wurden in den letzten Jahren ständig verbessert. Neue ALS- und photogrammetrische VHM's bieten heute die Möglichkeit, wichtige Strukturmerkmale für die Abgrenzung von Lawinenanrissgebieten automatisiert zu erfassen. Im Folgenden wird anhand der gleichen Untersuchungsregionen und Datengrundlagen wie in Fallbeispiel 2 dargestellt, wie Lawinenanrissgebiete im Bereich des Schutzwaldes abgegrenzt werden können. Wie im Fallbeispiel 2 wurde für Liechtenstein mit ALS (LiDAR) basierten VHM's und für den Kanton Graubünden mit photogrammetrisch basierten VHM's gearbeitet. Die Abgrenzung von Anrissgebieten basierte dabei auf folgenden allgemeinen Grundsätzen und Anforderungen:

1. Automatisierung und Nachvollziehbarkeit: Das Verfahren wurde für den ganzen Kanton Graubünden bzw. für das ganze Fürstentum Liechtenstein einheitlich und gemäss nachvollziehbaren Kriterien durchgeführt.
2. Basierend auf bestehenden Daten und Grundlagen: Die Ausscheidung des Lawinenschutzwaldes beruht auf dem aktuellen Wissensstand und den bestmöglichen Daten über Lawinenereignisse im Waldgebiet. Auch wurden bestehende Grundlagen nach NaiS ([13]) für die Initialisierung der Modelle so weit wie möglich berücksichtigt.
3. Verifiziert und optimiert: Die Abgrenzung des wirksamen Lawinenschutzwaldes bzw. von potenziellen Anrissgebieten in uns ausserhalb vom Schutzwald wurde als Basis für grossflächige Lawinensimulationen gemäss [14] verwendet. Sowohl vor wie auch nach den Lawinensimulationen wurden die ausgeschiedenen Lawinenanrissgebiete von regionalen Naturgefahrenexperten und Wissenschaftlern überprüft und die Grenzwerte für deren automatisierte Ausscheidung (Tab. 1) feinjustiert.
4. Spezifisch für verschiedene Szenarien: Die Abgrenzung von potenziellen Lawinenanrissgebieten im Schutzwald ist stark abhängig von Schneeszenarien. Um eine möglichst gute Vergleichbarkeit mit den Gefahrenkarten zu ermöglichen, wurden Lawinen mit verschiedener Richtwiederkehrdauer, also sowohl häufige Ereignisse (10-30-jährige Ereignisse), wie auch seltene Ereignisse (100-300-jährige Ereignisse) berechnet. Von dieser Lawinen-Jährlichkeit abhängig sind die Lawinen-Anrisshöhen, welche das Anrissvolumen definieren und damit auch die für die Schutzwirkung erforderliche Baumhöhen.

### 8.3.2. Kriterien für die Abgrenzung des wirksamen Lawinenschutzwald

Das Verfahren der verwendeten Lawinenschutzwaldausscheidung wird in Abb. 1 schematisch dargestellt. Eine zentrale Grundlage für die Auswahl und Gewichtung der relevanten Parameter stellt die Datenbasis von 150 Waldlawinen in Nadel- und Laubwäldern dar, woraus nach dem Ansatz von [15] ein logistisches Regressionsmodell mit den wichtigsten Parametern "Hangneigung", "Deckungsradius" "Lückenbreiten" berechnet wurde. Basierend auf diesem Modell und dem VHM sowie dem DHM wurde dann flächig eine "Lawinen-Disposition" zwischen 0 und 100% berechnet. Um die Berechnungszeit für grössere Gebiete in einem operativen Rahmen zu halten, wurden diese Berechnungen nur innerhalb einer Waldmaske gemäss LFI ([16]) durchgeführt.

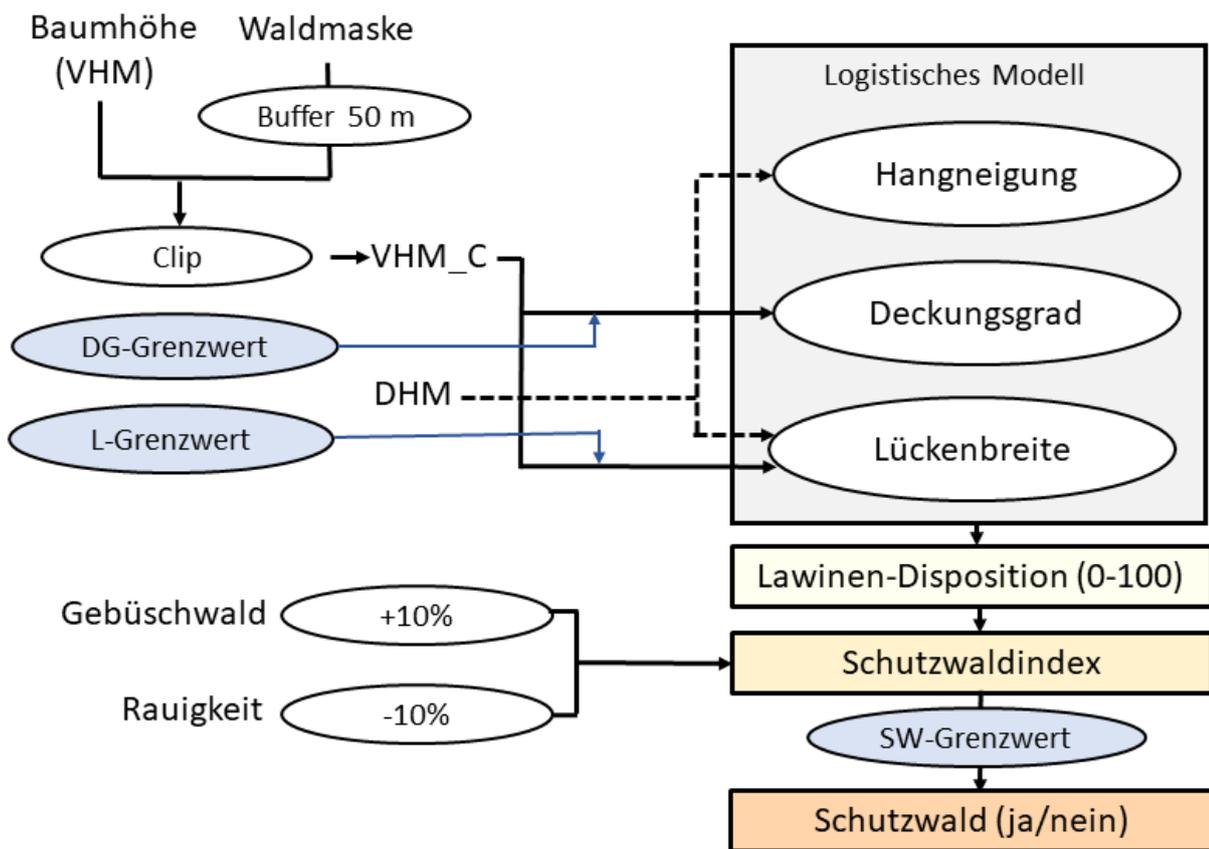


Abbildung 8.13.: Schematischer Aufbau des Modells zur Berechnung der Lawinenanriss-Wahrscheinlichkeit [17]

Schwellenwerte für die erforderlichen Baumhöhen für die Schutzwalderfüllung wurden sowohl für die Definition von Waldlücken (L-Grenzwert) wie auch für die Definition des Kronendeckungsgrad spezifisch nach verschiedenen Jährlichkeiten von Lawinenereignissen (10-j, 30-j, 100-j, 300-j) definiert (Tab. 8.1). Der resultierende „Schutzwaldindex“ bildet dann die Grundlage für die Definition des Lawinenschutzwaldcovers.

Tabelle 8.1.: Verwendete Grössen und Grenzwerte zur Abgrenzung des Lawinenschutzwaldlayers

<b>Grenzwert</b>	<b>Bedeutung und Schwellenwerte</b>
Lücken-Grenzwert	Die lokale Schneehöhe wurde gemäss [18] für ein 100-j-Ereignis gerechnet und mit dem Faktor 0.85 für häufige bzw. 1.14 für seltene Ereignisse korrigiert. Die Schneehöhen multipliziert mit dem Faktor 1.5 ergibt den jeweiligen Baumhöhengrenzwert. Um Unterschätzungen von Baumhöhen mit dem VHM auszugleichen, werden für das 100-jährige Ereignis 1.5 m für das LiDAR-VHM und 2 m für das LFI-VHM abgezogen.
DG-Grenzwert	Um den Deckungsgrad auf verschiedenen räumlichen Skalen und für verschiedene Jährlichkeiten zu berücksichtigen und die Erfassung von Bäumen vor allem in einem kritischen Bereich zwischen 3 und 5 Meter zu optimieren, wurden folgende VHM-Grenzwerte festgelegt. häufiges Ereignis: 4 m für 5 × 5 m und 3 m für 25 × 25 m Umgebung seltenes Ereignis: 5 m für 5 × 5 m und 4 m für 25 × 25 m Umgebung
Lawinen-Disposition	statistisch ermittelte Lawinendisposition (von 0-100), aus logistischem Modell aufgrund von Waldlawinendaten errechnet.
Schutzwaldindex	Aus Lawinen-Disposition und weiteren Parametern (Rauigkeit, Gebüschwald) errechneter Wert zur Beurteilung der lokalen Erfüllung der Lawinenschutzfunktion (kann Werte von -10 bis 110 annehmen).
SW-Grenzwert	Grenzwert des Schutzwaldindex, der aufgrund von Lawinendaten und Erfahrungswerten in gut dokumentierten Gebieten festgelegt wurde und eine Feinjustierung der automatisiert generierten Schutzwald-Abgrenzung erlaubt. für das LiDAR-basierte Modell (Abb. 2) wurden folgende Grenzwerte verwendet: sehr häufiges Szenario: SW-Grenzwert < 90, Häufiges Szenario: SW-Grenzwert < 80, seltenes Szenario: SW-Grenzwert < 70, Sehr seltenes Szenario: SW-Grenzwert < 60

Nach dem Vergleich der ersten Lawinensimulationen (auf der Grundlage des automatisiert generierten Schutzwaldcovers) mit Lawinenkatasterdaten und Gefahrenzonenplänen haben wir (zusätzlich zu den initialen Modellen) zwei zusätzliche Faktoren berücksichtigt, die sich aus dem ursprünglichen logistischen Modell noch nicht quantitativ ableiten liessen, aber zu einer weiteren Verbesserung der Abgrenzung von potenziellen Lawinanrissgebieten und des Schutzwaldlayers führen: (1) Ein Gebüschwald-Layers auf der Basis von [19] ermöglichte es, Flächen mit Strauchvegetation (z.B. Grünerle oder Legföhrengbüsche) bei gleicher Vegetationshöhe eine höhere Lawinendisposition zugeordnet; (2) Gebieten mit hoher Oberflächenrauigkeit wurde eine tiefere Disposition für das Anreissen von Lawinen zugeordnet. Die Rauigkeit wurde gemäss [20] auf der Basis des SwissAlti3D Geländemodells mit einer Auflösung von 2 m berechnet. Die resultierende Lawinenschutzwaldkarte (8.14 ist somit das Ergebnis eines iterativen Prozesses, der mit einem datenbasierten statistischen Modell der Lawinenauslösung in bewaldetem Gelände begann und anschliessend in mehreren Arbeits- und Validierungsschleifen verbessert wurde. Dies ermöglichte insbesondere das Abbremsverhalten kleiner Lawinen in bewaldetem Gelände adäquat zu berücksichtigen. Zusätzlich konnten Unterschiede zwischen den tatsächlichen Baumhöhen und der Bewertung dieser Baumhöhen mit den verfügbaren Vegetationshöhenmodellen berücksichtigt werden.

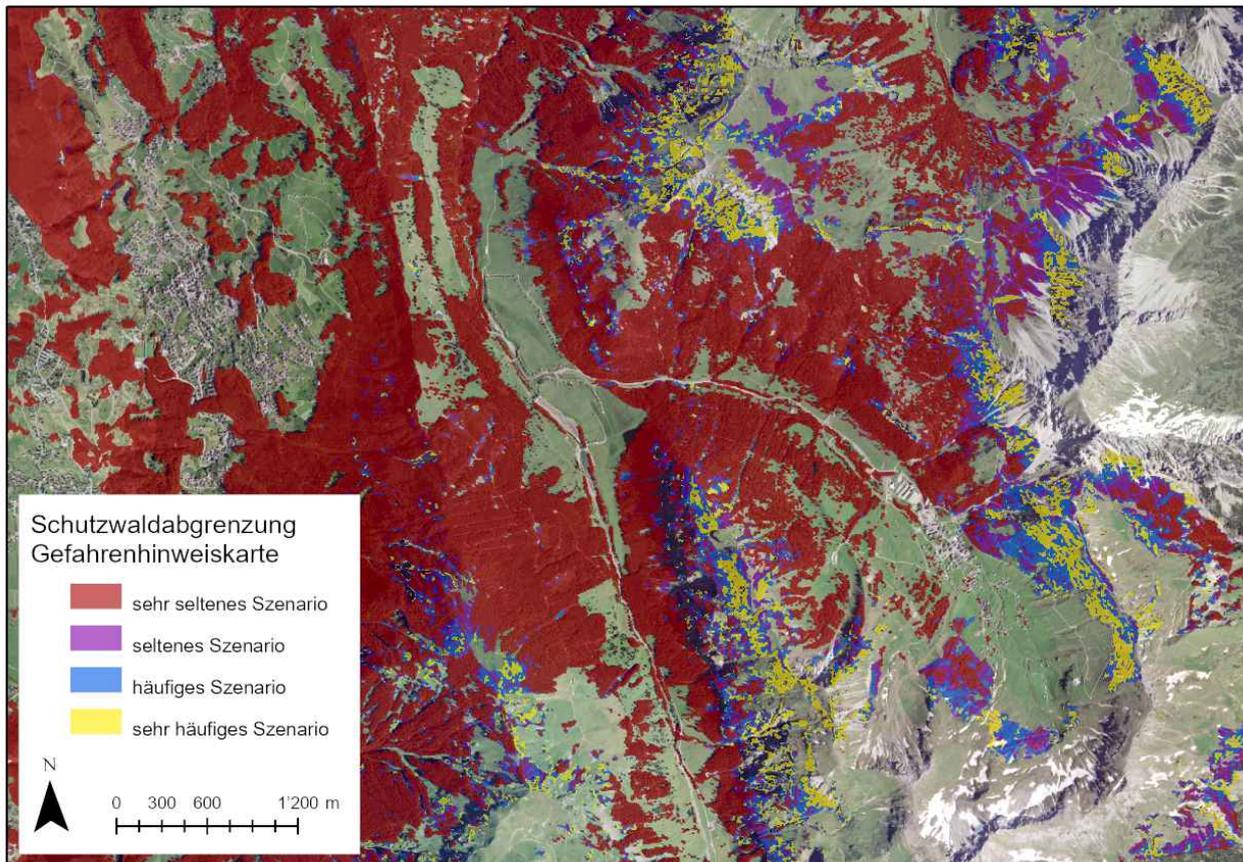


Abbildung 8.14.: Automatisiert ermittelter Lawinenschutzwaldcover zwischen Triesen und Malbun für das sehr seltene Szenario (300j, rot eingefärbte Wälder), seltene Szenario (100j, zusätzlich violett eingefärbte Wälder), das häufige Szenario (30j, zusätzlich blau eingefärbte Wälder) und das sehr häufige Szenario (10j, zusätzlich gelb eingefärbte Wälder). [21]

## 8.4. Fallbeispiel 4: Bestimmung der Waldgrenze

Die Abgrenzung von Waldflächen ist eine herausfordernde Aufgabe. Die Definition von Wald ist meist eine Kombination von Bodenbedeckung und Bodennutzung. Bei der Bodenbedeckung werden meist der Deckungsgrad, die Oberhöhe und eine bestimmte Mindestfläche oder Mindestbreite der bestockten Fläche verwendet. Dazu muss die Bodennutzung betrachtet werden. Ist die Nutzung nicht von forstlichem Charakter, dann sind diese Flächen nicht in Waldflächen inkludiert. Beispiele sind Obstgärten, Friedhöfe oder Pärke. Diese Differenzierung ist aktuell vollautomatisch nicht möglich. Wir beschränken uns daher bei diesem Fallbeispiel auf die Waldabgrenzung ohne die Berücksichtigung der Nutzung.

Für eine Kartierung der Aussengrenzen von bestockten Flächen können Rasterdaten, wie zum Beispiel ein VHM oder Punktdaten, welche Einzelbäume repräsentieren, als Eingangsdaten verwendet werden.

Für die Erstellung der Waldmaske LFI wurde ein Rasterdatensatz, das VHM LFI, verwendet. Es wurden Vegetationshöhen  $\geq 3$  m, ein Deckungsgrad  $\geq 20$  % und einer Mindestbreite von 25 m ausgeschieden. Dies entspricht der Walddefinition im LFI. Die Bodennutzung wurde manuell ergänzt.

Stehen Informationen zu Einzelbäumen zur Verfügung, so können diese Daten zur Abgrenzung von Baum- oder Waldbeständen verwendet werden. Im Folgenden wird ein Arbeitsfluss skizziert, um aus Punktdaten, welche die Lage von Einzelbäumen repräsentieren, Polygone abgeleitet werden.

Die Grundlage waren die aufbereiteten Outputs aus der Detektion mit pyFINT innerhalb des FINT-CH Detektionsprozesses (Abbildung 8.15).



Abbildung 8.15.: Visualisierung der detektierten Einzelbäume in einem Ausschnitt von Luzern.

Die Punktdaten können anhand von frei definierbaren Distanzkriterien verbunden werden. Als Werkzeug für die Erzeugung von umhüllenden Polygonen verwendeten wir LASBOUNDARY von LAsTools. In Abbildung 8.16 ist eine Abgrenzung mit einer maximalen Distanz von 25 m zwischen den Einzelbäumen dargestellt. Lücken innerhalb des Waldes werden ausgespart. Das bedeutet, dass auch temporär nicht bestockte Flächen ausgespart sind.



Abbildung 8.16.: Visualisierung der umhüllenden Polygone der detektierten Einzelbäume mit einem maximalen Abstand von 25 m in einem Ausschnitt von Luzern.

Für die Erstellung von Grenzen oder Flächen können alle Attribute der ausgegebenen detektierten Bäume gefiltert werden. Ein Beispiel ist in Abbildung 8.17 dargestellt. Es wurden nur Bäume mit einer Höhe von mehr als 30 m ausgewählt und mit einer maximalen Distanz von 20 m zusammengefasst. So können zum Beispiel Altholzinseln ausgewiesen werden.

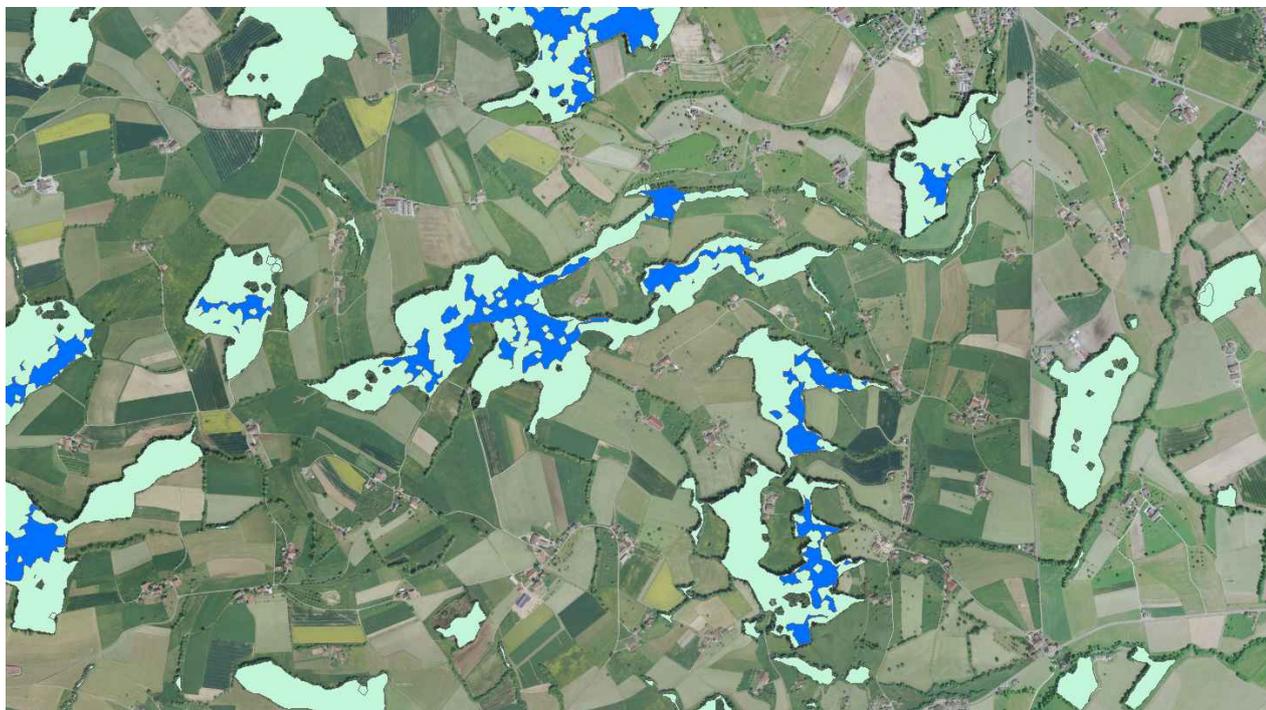


Abbildung 8.17.: Visualisierung der umhüllenden Polygone der detektierten Einzelbäume mit einem maximalen Abstand von 25 m und Flächen mit Bäumen mit einer Höhe von mindestens 30 m (blau) in einem Ausschnitt von Luzern.

## 9. Schlussfolgerungen und Ausblick

Mit diesem Bericht liegt eine transparente Beschreibung der verwendeten Methoden und der resultierenden Ergebnisse im FINT-CH Projekt vor. Folgende Schlussfolgerungen und Perspektiven können aus den verschiedenen Arbeitspakete festgehalten werden.

Der wichtigste Eingangsdatensatz für die Einzelbaumdetektion ist ein hochaufgelöstes Vegetationshöhenmodell (VHM). Im Projekt FINT-CH wurden dafür die aktuellsten kantonalen LiDAR Datensätze und Daten der ersten landesweiten Befliegung von swisstopo verwendet. Die aktuellen Daten erlauben eine zuverlässige Berechnung eines Vegetationshöhenmodells mit der Auflösung von 1 m x 1 m. Die Daten der Erstbefliegung von swisstopo weisen überwiegend keine Klassifikation der Punktdaten auf. Einzig Bodenpunkte sind bekannt. Für den Ausschluss der Gebäude wurden die Gebäudeflächen aus dem swisstopo-TLM genommen. Für das Projekt ist dies nicht entscheidend, da wir auf die Waldflächen fokussiert waren. Alle aktuellen Datensätze sind mittlerweile mit zuverlässiger Klassifikation der Punkt verfügbar und so können gezielt Bodenpunkte und Vegetationspunkte in das Vegetationshöhenmodell einfließen.

Aktuell wird von swisstopo und den Kantonen ein neuer landesweiter LiDAR-Datensatz erstellt. Die Punktdichte ist hoch ( $>25$  Punkte/m<sup>2</sup>) und der Datensatz wird im ersten Halbjahr 2024 vollständig zur Verfügung stehen. Damit ist das Potenzial zu einer Aktualisierung der Einzelbaumerkennung gegeben. Ein regelmässiger Aktualisierungszyklus wie bei den ADS Luftbildstreifen ist allerdings nicht geplant.

Der Mischungsgrad gibt die landesweite Laub- und Nadelgehölzwahrscheinlichkeit mit einer räumlichen Auflösung von 10 m mit hoher Modellgenauigkeit ( $> 95\%$ ) wieder. Bei der Generierung des Mischungsgrades wurden frei verfügbare und zeitlich hochaufgelöste Copernicus Sentinel-1/-2 Daten (2015-2018), das swissAlti3D Geländemodell sowie Machine Learning (Random Forest) verwendet. Die Kombination von Synthetic Aperture Radar (SAR) und optischen Daten ermöglichte, auch topographisch anspruchsvolle und beschattete Gebiet oft korrekt zu klassieren. Während sich der Datensatz auf Bestandesebene oder pro Flächeneinheit, z.B. 1/4 Hektare gut eignet, ist bei der Interpretation der Resultate auf Pixel-Basis Vorsicht geboten. Da der Datensatz auf frei verfügbarer Software basiert (R statistics) und zu einem hohen Grad automatisiert wurde, kann er bei Bedarf mit relativ wenig Aufwand aktualisiert werden.

Der verwendete Algorithmus zur automatisierten Bestandesabgrenzung mittels TBk war schon vor der Laufzeit des FINT-CH Projektes vorhanden. Im Rahmen des Projektes wurde daraus jedoch ein optimiertes Tool mit standardisierten Prozessen entwickelt, wodurch eine deutlich breitere Anwendung möglich wurde. Die Gelegenheit, die Ergebnisse mit einigen Auftraggebern im Wald zu besprechen, lieferte zudem einen wertvollen Austausch hinsichtlich möglicher Weiterentwicklungen, welche teilweise schon im Projekt umgesetzt werden konnten. Die Kombination von FINT und TBk hat im Hinblick auf das Waldmanagement grosses Potenzial bewiesen und von der Bestandesabgrenzung bis hin zu den dominierenden Bäumen können nun auch grossflächige Waldgebiete im Detail erfasst werden. Zusätzliche Attribute wie die Höhe und die räumliche Verteilung der dominierenden Bäume liefern dabei eine wertvolle Grundlage, zum Beispiel für die Anzeichnung. Vielversprechend ist weiterhin die Möglichkeit, vergleichbare Berechnungen zu unterschiedlichen Zeitpunkten durchzuführen. Dies ermöglicht eine temporale Analyse, wodurch ein besseres Verständnis der Bestandesdynamik erlangt wird.

Die Ergebnisse der Einzelbaumdetektion zeigen insgesamt eine Verbesserung durch den Einbezug der Waldstrukturtypen (WST) im Detektionsprozess. Limitierender Faktor bei der Differenzierung der WST und der Detektionsmethoden war vor allem die Verfügbarkeit von genügend Referenzdaten pro WST. Durch Einbezug weiterer Referenzdaten mit Einzelbäumen wäre eine Verfeinerung der Methodenwahl denkbar. Bei den Referenzdaten wäre eine einheitliche Datenbasis und -qualität wünschenswert. Insbesondere die konsequente Verfügbarkeit von BHD und Höhe könnte noch einige Verbesserungen bringen. Auf Grund der bereits spärlichen Datenlage bei einigen WST wurde im Projekt auf eine Limitierung aufgrund des zeitlichen Abstandes zwischen der Erfassung der Referenzdaten und der ALS Daten verzichtet. Eine Beachtung dieses Abstandes könnte aber ebenfalls noch Verbesserungen bei der Kalibrierung der Detektion und der Statistikmodelle bringen. Bei der Erstellung der Modelle könnte durch Beachtung weiterer Variablen wie feineren BHD Klassen oder Wald- und Bestandesgrenzen eine weitere Verbesserung

erzielt werden. Diese höhere Genauigkeit würde aber mit einer höheren Komplexität und schwereren Übertragung in die Praxis erkaufen. Wie die Modellierung des Vorrats gezeigt hat, könnten aber auch die Anwendung von weiteren Methoden aus der Statistik und der Einsatz von Machine Learning Methoden weitere Verbesserungen bringen. Bei der technischen Umsetzung hat sich die Verwendung von Python für die Umsetzung der Geoprocessing Abläufe bewährt und soll in Zukunft vermehrt für Aufgaben dieser Art eingesetzt werden.

Zusätzlich können wir festhalten, dass die TBk-Daten ergänzt durch die Daten zu den detektierten Einzelbäumen, eine gute Schätzung des Vorrats auf Bestandsebene ermöglichen. Das verwendete Schätzungsmodell ermöglicht somit die Erstellung flächendeckender Karten mit Informationen zum Vorrat zur Ergänzung der Ergebnisse terrestrischer Inventuren und zur Unterstützung bei der Dateninterpolation. In gewissem Umfang können diese Karten sogar für die Waldplanung auf Forstbetriebsebene verwendet werden.

Das Fallbeispiel 1 - Lokalisieren dominanter FINT-CH Bäume - hat aufgezeigt, dass es grundsätzlich gut möglich ist, die auf Fernerkundungsdaten ermittelten FINT-CH Baumpositionen im Feld wieder aufzufinden. Dies gilt jedoch hauptsächlich für die Rankingklassen 'Top 20' und 'Top 50'. Dabei hat sich wie erwartet herausgestellt, dass Nadelhölzer um einiges deutlicher erkannt werden können als Laubhölzer. Die eindeutige Zuordnung steigt dabei mit zunehmender Oberhöhe. Bei der vorliegenden Stichprobenüberprüfung fehlen allerdings noch Beispiele für Laubholz in den Entwicklungsstufen Baumholz 2 und 3, weshalb keine Aussagen über diese Entwicklungsstufen gemacht werden können. Schwierigkeiten bei der Ermittlung der realen Baumposition gab es in den PPSS08, 16 und 25, welche sich alle in der Entwicklungsstufe Stangenholz 2 befinden und zu 100 % aus Laubholz bestehen. Ohne eindeutige Referenzpunkte im Feld sowie klare Höhenunterschiede zwischen einem dominanten Baum und seinen Nachbarn konnten die FINT-CH Baumpositionen der dominanten Bäume nur über den ersichtlich stärkeren BHD der entsprechenden Bäume im Feld erahnt werden. In derartigen Situationen ist eine zuverlässige Überwachung der dominanten Bäume bzw. Z-Bäumen im Sinne eines Controllings nur begrenzt möglich.

Als zusätzliche Herausforderung bei der Überprüfung im Feld war die Aktualität der Datengrundlagen, die zur Berechnung der FINT-CH Baumposition verwendet wurden. Die teilweise auffällige Differenz zwischen den FINT-CH Baumpositionen und der Vegetationshöhe in den Karten ist darauf zurückzuführen, dass die Baumpositionen mit einem älteren VHM berechnet wurden. Die Abweichungen mit der Realität erschwerten die Identifikation der Einzelbäume zusätzlich. Dies verdeutlicht, dass die Aktualität der Kartengrundlagen einen bedeutenden Einfluss auf die Einsatzmöglichkeiten der FINT-CH Daten haben kann.

Beim Fallbeispiel 2 - Kartierung von Lücken im Wald - haben sowohl die Methode zur Ableitung der Lücken anhand der detektierten Einzelbäume als auch anhand des VHM gute Resultate und eine hohe Überlappung erbracht. Die Unterschiede ergeben sich aus den leicht unterschiedlichen Ansätzen und der Untergrenze bei der Baumhöhe, welche bei der Detektion eingestellt wurde. Beide Ansätze sind mit relativ einfachen Mitteln effizient umzusetzen. Der einzelbaumbasierte Ansatz hat den Vorteil, dass die Position grosser, in der Detektion erkannter Bäume in der Nähe des eigentlichen Standorts berücksichtigt wird und ausladende Kronen nicht zu kleineren Lücken führen. Deshalb wurde diesem Ansatz schlussendlich der Vorzug gegeben. Für künftige Entwicklungen ist die Flexibilisierung der Lückengrösse und der kritischen Länge eine Option, um abhängig von den jeweiligen Anforderungen Lücken zu kartieren.

Für Fallbeispiel 3 - Automatische Kartierung von potenziellen Anrissgebieten im Lawenschutzwald - war keine Einzelbaumdetektionen erforderlich. Hier wurde die aktuelle Abgrenzung von Lawinnenrissgebieten im Schutzwald aufgrund der verfügbaren Daten und der aktuellen Prozesskenntnisse und Modelle optimiert. Zusätzliche Optimierungen sind (zusätzlich zu weiteren regionalen Verifizierungen) in den nächsten Jahren aber insbesondere in folgenden Bereichen möglich:

- Da möglichst korrekte Baumhöhen im Vergleich zu den regional zu erwarteten Schneehöhen für die automatisierte Abgrenzung der potenziellen Lawinnenrissgebiete im Wald wichtig sind, können hochaufgelöste LiDAR-Daten die Qualität dieser Abgrenzung deutlich verbessern.
- Zurzeit läuft an der WSL eine Dissertation zur Verwendung von Copernicus Sentinel Daten zur Erfassung von Baumarten in der Schweiz (Koch et al., in Bearbeitung). Wir erwarten, dass wir basierend auf diesem Projekt die für die Lawinenschutz Wirkung wichtige Baumartenzusammensetzung ermitteln können.
- Die Oberflächenrauigkeit wurde im aktuellen Schutzwalddatensatz berücksichtigt, indem rauen Waldgebieten gemäss [20] ein erniedrigter Schutzwaldindex zugeordnet wurde. Dank aktuellen Untersuchungen zur Oberflächenrauigkeit auf Störungsflächen sind in Zukunft differenziertere Unterscheidungen möglich.

Fallbeispiel 4 - Bestimmung der Waldgrenze - hat gezeigt, dass einen Datensatz mit Informationen zu einzelnen Bäumen, auch wenn er nicht vollständig ist, das Potenzial hat, anhand von Distanzkriterien Waldflächen (und damit auch Waldgrenzen) zu bilden. Neben den äusseren Waldrändern können auch Gruppierungen von Bäumen anhand von Höhenkriterien zusammen gefasst werden. Dies könnte ein wertvoller Input zum Beispiel für Elemente der ökologischen Infrastruktur sein.

Insgesamt hat das FINT-CH Projekt eine Reihe von Methoden und Produkten hervorgebracht, welche für das tägliche Waldmanagement in der Schweiz von Nutzen sind. Eine schweizweite Anwendung dieser Methoden ab 2024, dessen Weiterentwicklung in den kommenden Jahren natürlich mit inbegriffen, wäre unserer Ansicht nach für die schweizerische Waldwirtschaft vorteilhaft.



# Literaturverzeichnis

- [1] J. N. Heinzel, H. Weinacker, and B. Koch, "Prior-knowledge-based single-tree extraction," *International journal of remote sensing*, vol. 32, no. 17, pp. 4999–5020, 2011.
- [2] J. Hyypä, "Detecting and estimating attributes for single trees using laser scanner," *Photogramm J Finland*, vol. 16, pp. 27–42, 1999.
- [3] Z. Zhen, L. J. Quackenbush, and L. Zhang, "Trends in automatic individual tree crown detection and delineation—evolution of lidar data," *Remote Sensing*, vol. 8, no. 4, p. 333, 2016.
- [4] L. Eysn, M. Hollaus, E. Lindberg, F. Berger, J.-M. Monnet, M. Dalponte, M. Kobal, M. Pellegrini, E. Lingua, D. Mongus, *et al.*, "A benchmark of lidar-based single tree detection methods using heterogeneous forest data from the alpine space," *Forests*, vol. 6, no. 5, pp. 1721–1747, 2015.
- [5] J. Menk, L. Dorren, J. Heinzel, M. Marty, and M. Huber, "Evaluation automatischer Einzelbaumerkennung aus luftgestützten Laserscanning-Daten," *Schweizerische Zeitschrift für Forstwesen*, vol. 168, no. 3, pp. 151–159, 2017.
- [6] A. Erbach and C. Rosset, "TBk set d'outils pour la création de cartes de peuplements d'après des données de télédétection,"
- [7] G. Kraft, *Beiträge zur Lehre von den Durchforstungen, Schlagstellungen und Lichtungshieben*. Klindworth, 1884.
- [8] L. T. Waser, C. Ginzler, and N. Rehus, "Wall-to-wall tree type mapping from countrywide airborne remote sensing surveys," *Remote Sensing*, vol. 9, no. 8, p. 766, 2017.
- [9] L. Breiman, "Random forests," *Machine learning*, vol. 45, no. 1, pp. 5–32, 2001.
- [10] L. Dorren, F. Berger, and B. Maier, "Mapping the structure of forestal vegetation with an airborne light detection and ranging (lidar) system in mountainous terrain," *Revue Francaise de Photogrammetrie et de Télédétection (186)*, pp. 54–59, 2007.
- [11] D. Yin and L. Wang, "How to assess the accuracy of the individual tree-based forest inventory derived from remotely sensed data: A review," *International Journal of Remote Sensing*, vol. 37, no. 19, pp. 4521–4553, 2016.
- [12] C. Rosset, G. Dumollard, C. Gollut, D. Weber, V. Sala, V. Martin, J. Endtner, F. Wyss, and J. Schütz, *SiWaWa 2.0 et placettes permanentes de suivi sylvicole*. Rapport technique OFEV, 2018.
- [13] M. Frehner, B. Wasser, and R. Schwitter, "Nachhaltigkeit und Erfolgskontrolle im Schutzwald," *Wegleitung für Pflegemassnahmen in Wäldern mit Schutzfunktion*. Bundesamt für Umwelt, Wald und Landschaft, Bern, vol. 564, 2005.
- [14] Y. Bühler, D. v. Rickenbach, A. Stoffel, S. Margreth, L. Stoffel, and M. Christen, "Automated snow avalanche release area delineation—validation of existing algorithms and proposition of a new object-based approach for large-scale hazard indication mapping," *Natural Hazards and Earth System Sciences*, vol. 18, no. 12, pp. 3235–3251, 2018.
- [15] P. Bebi, F. Kienast, and W. Schönenberger, "Assessing structures in mountain forests as a basis for investigating the forests' dynamics and protective function," *Forest Ecology and Management*, vol. 145, no. 1-2, pp. 3–14, 2001.
- [16] C. Ginzler and M. L. Hobi, "Das aktuelle Vegetationshöhenmodell der Schweiz: spezifische Anwendungen im Waldbereich," *Schweizerische Zeitschrift für Forstwesen*, vol. 167, no. 3, pp. 128–135, 2016.
- [17] Y. Bühler, M. Christen, S. Margreth, L. Stoffel, A. Stoffel, M. C., S. G., and D. von Rickenbach, "Gefahrenhinweiskarten lawinen kanton graubünden," p. 35, 2020a.

- [18] S. Margreth, R. Baumann, S. O. fédéral de l'environnement, la neige et le paysage (Birmensdorf) Institut fédéral de recherches sur la forêt, and I. pour l'étude de la neige et des avalanches (Davos-Weissfluhjoch), *Lawinenverbau im Anbruchgebiet: technische Richtlinie als Vollzugshilfe*. Bundesamt für Umwelt, 2007.
- [19] D. Weber, M. Rüetschi, D. Small, and C. Ginzler, "Grossflächige Klassifikation von Gebüschwald mit Fernerkundungsdaten," *Schweizerische Zeitschrift für Forstwesen*, vol. 171, no. 2, pp. 51–59, 2020.
- [20] J. M. Sappington, K. M. Longshore, and D. B. Thompson, "Quantifying landscape ruggedness for animal habitat analysis: a case study using bighorn sheep in the mojave desert," *The Journal of wildlife management*, vol. 71, no. 5, pp. 1419–1426, 2007.
- [21] Y. Bühler, P. Bebi, M. Christien, S. Margreth, L. Stoffel, A. Stoffel, C. Marty, G. Schmucki, and D. von Rickenbach, "Gefahrenhinweiskarten lawinen liechtenstein," p. 41, 2020b.



# A. Anhang - Boxplots mit Detektionsraten

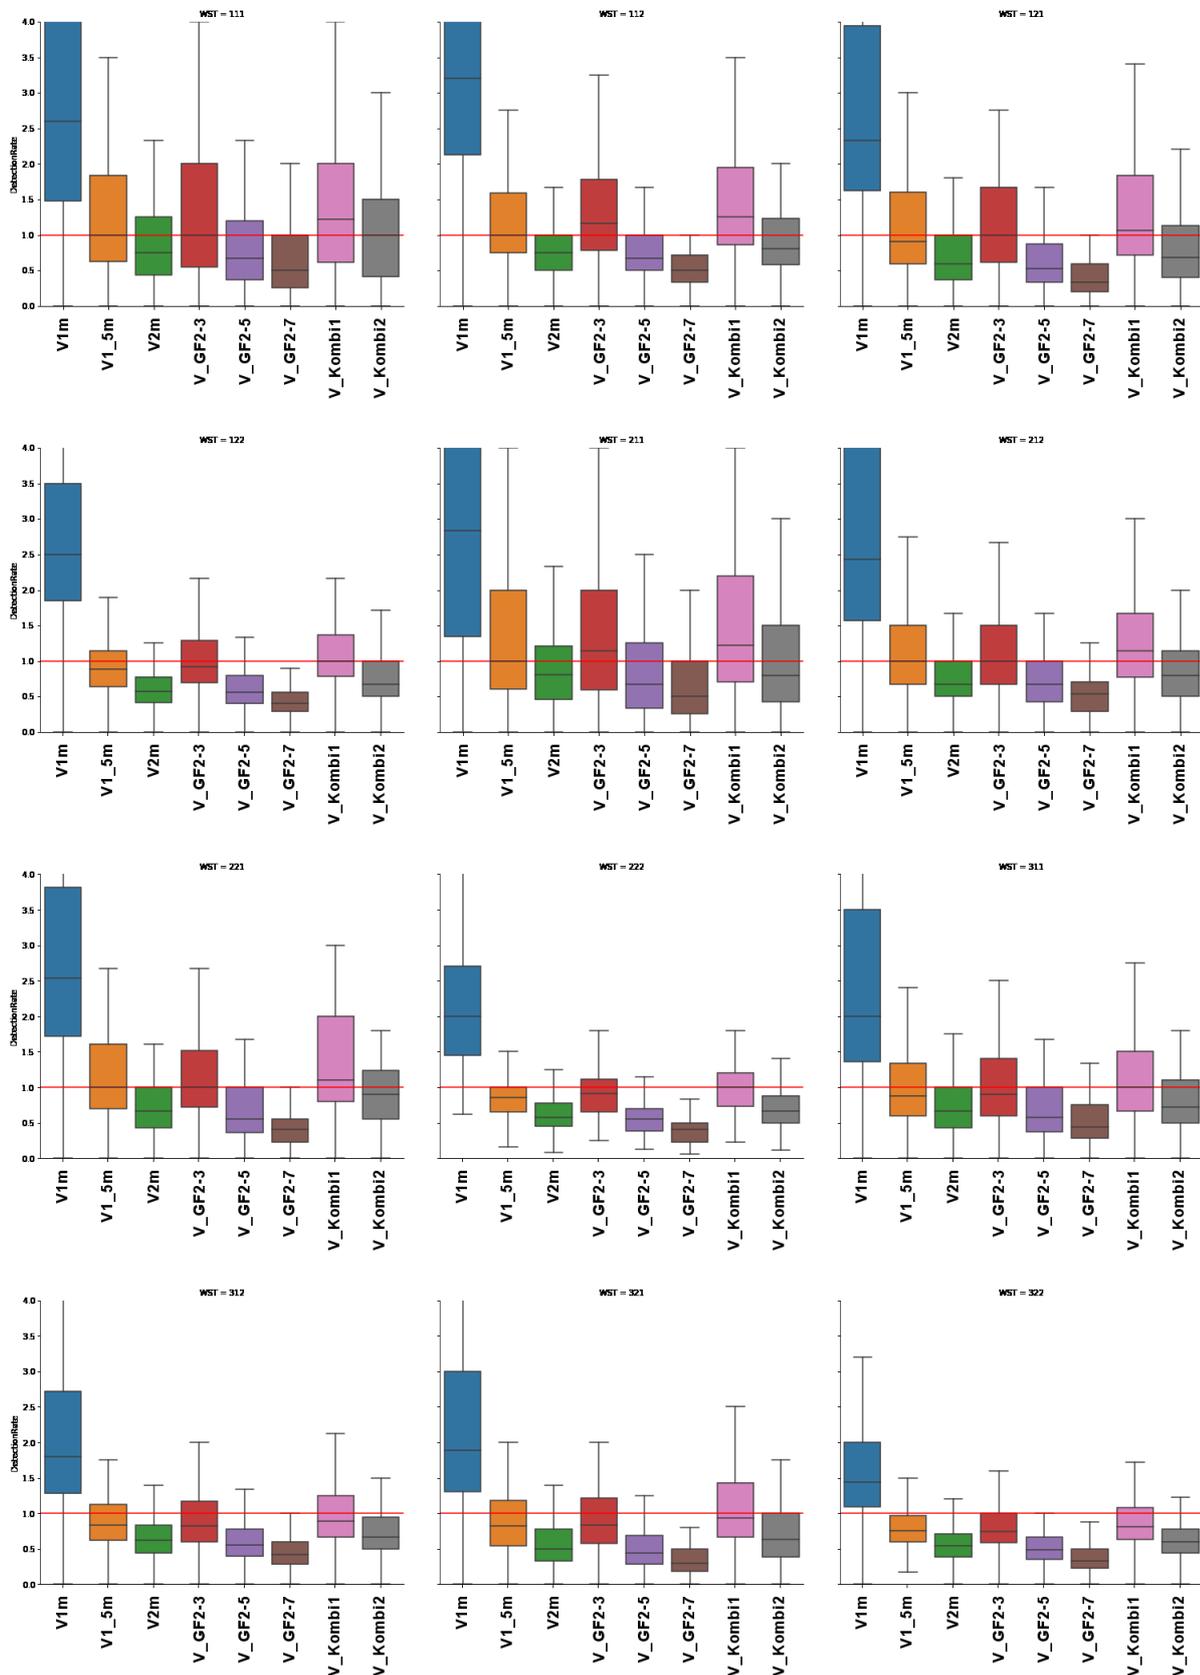


Abbildung A.1.: Boxplots der Detektionsraten der getesteten Detektionsvarianten für alle WST. Die Detektionsrate wird wie folgt berechnet:  $N_{detektiert}/N_{LFI}$  ( $N$  = Stammzahl per ha).



## B. Anhang - QQ-Plots der EBD

