



Master Thesis

im Rahmen des
Universitätslehrganges „Geographical Information Science & Systems“
(UNIGIS MSc) am Interfakultären Fachbereich für GeoInformatik (Z_GIS)
der Paris Lodron-Universität Salzburg

zum Thema

„Quantifizierung klimatisch bedingter Veränderungen der Baumartenzusammensetzung mithilfe passiver Fernerkundungs-Systeme“

vorgelegt von

Mario Werlen BSc
104850, UNIGIS MSc Jahrgang 2018

Betreuer/in:
Assoc. Prof. Dr. Gudrun Wallentin

Zur Erlangung des Grades
„Master of Science – MSc“

Brig, 31.08.2023

Danksagung

An dieser Stelle möchte ich mich bei allen herzlich bedanken, die mich während dem Studium unterstützt haben.

Zuerst gebührt mein Dank Frau Assoc. Prof. Dr. Gudrun Wallentin für die Betreuung und Begutachtung meiner Master-Thesis und dem gesamten UNIGIS-Team für die Begleitung durch das Studium.

Ein besonderer Dank gilt Dr. Lars Waser von der Eidgenössischen Forschungsanstalt für Wald, Schnee und Landschaft für die Beantwortung der Fragestellungen bezüglich der Bildanalysen.

Ebenfalls möchte ich mich bei Mathias Hutter von der Dienststelle für Wald, Natur und Landschaft, Robert Jenni vom Bundesamt für Umwelt und Anna Theler vom Naturpark Pfyn-Finges für die Betreuung und zur Verfügungstellung der Grundlagedaten aus forstlicher Sicht bedanken.

Zusammenfassung

Der Klimawandel wird sich in Zukunft auf den Wald und darin noch standortgerechten Baumarten auswirken. Die Diskrepanz zwischen der aktuellen Lage und der anzustrebenden Baumartenzusammensetzung eines Bestandes ist dabei entscheidend. Daher sind Informationen über den aktuellen Zustand der Baumartenmischung für Forstfachleute von zentraler Bedeutung. In der vorliegenden Arbeit wurde in einem Gebirgswald im Kanton Wallis untersucht, ob die Bestimmung der Baumarten mit einer objektbasierten Bildanalyse mit Luftbildern oder mit einer pixelbasierten Bildanalyse mit Satellitenbildern besser geeignet ist, um daraus Handlungsempfehlungen herzuleiten. Das Ziel ist eine Klassifikation mit einer genügend hohen Genauigkeit von 85 % zu erhalten. Mit den besser geeigneten Ergebnissen wurden Handlungsempfehlungen für den Waldbau hergeleitet. Als Grundlage für die objektbasierte Bildanalyse wurden multispektrale swissimage RS-Luftbilder mit einer räumlichen Auflösung von 0.25 m verwendet. Die Baumkronen sind mit dem *Mean Shift Segmentation* Algorithmus abgegrenzt worden. Die Klassifizierung wurde mit Trainingsdaten aus einer Felderhebung und dem *Support Vector Machine* Algorithmus mit insgesamt 10 Variablen durchgeführt. Das Modell ist am effektivsten mit der Variable über die Vegetationshöhe und den Nadelholzanteil verbessert worden. Es konnte eine Gesamtgenauigkeit von 83 % erzielt werden. Als Grundlage für die pixelbasierte Bildanalyse wurden Sentinel-2A-Bilder von drei verschiedenen Aufnahmezeitpunkten verwendet. Die Trainingsdaten aus der Felderhebung wurden mit Daten aus einer Fotointerpretation erweitert. Die Klassifizierung ist mit 44 Variablen und dem *Random Forest* Algorithmus durchgeführt worden. Das Ergebnis konnte neben der Variable über den Nadelholzanteil mit einer Farbmodellkonvertierung entscheidend verbessert werden. Es wurde eine Gesamtgenauigkeit von 84 % erreicht. Zwischen den Baumarten gibt es unterschiedliche Ergebnisse. Bei beiden Bildanalysen sehen die Tendenzen ähnlich aus. Die Lärche wurde am schlechtesten detektiert. Die Flaumeiche und die Waldföhre weisen hohe Genauigkeiten auf. Obwohl mit beiden Bildanalysen ähnliche Gesamtgenauigkeiten erreicht wurden, ist die räumliche Verteilung der Baumarten unterschiedlich. Im Vergleich mit externen Inventurdaten konnte festgestellt werden, dass die objektbasierten Ergebnisse besser übereinstimmen als die pixelbasierten Ergebnisse. Für die Herleitung der Handlungsempfehlung sind aufgrund der höheren Gesamtgenauigkeit die pixelbasierten Ergebnisse für die Bestimmung des Ist-Zustandes herangezogen worden. Mit der gutachterlichen Analyse wurden 62 % Fichten-, 21 % Föhren- und 17 % Arvenwälder ausgeschieden. Durch die Differenz vom Ist-Zustand mit Modelldaten über die künftige Baumartenzusammensetzung konnte berechnet werden, dass bei einem mässigen Klimawandel 34 % und bei einem starken Klimawandel 85 % der Waldfläche umgebaut werden müssten.

Abstract

In the future, climate change will have an impact on the forest and on the tree species that are still suitable for their location. The discrepancy between the current situation and the desired tree species composition of a stand is crucial. Therefore, information about the current state of the tree species mix is of central importance for forest professionals. In the present work it was investigated in a mountain forest in the canton of Valais whether the determination of tree species with an object-based image analysis with aerial photographs or with a pixel-based image analysis with satellite images is better suited to use this as a basis for recommendations for action. The goal is to obtain a classification with a sufficiently high accuracy of 85 %. With the more suitable results, recommendations for action in silviculture were derived. Multispectral swissimage RS aerial images with a spatial resolution of 0.25 m were used as the basis for the object-based image analysis. Tree canopies have been delineated using the Mean Shift Segmentation algorithm. Classification was performed using training data from a field survey and the Support Vector Machine algorithm with a total of 10 variables. The model was most effectively improved with the variable on vegetation height and proportion of coniferous wood. An overall accuracy of 83% was achieved. Sentinel-2A images from three different acquisition times were used as the basis for the pixel-based image analysis. The training data from the field survey were extended with data from a photo interpretation. The classification has been performed with 44 variables and the Random Forest algorithm. The result could be decisively improved with the variable over the proportion of coniferous wood and with a color model conversion. An overall accuracy of 84% was achieved. There are different results between the tree species. In both image analyses, the trends look similar. The larch was detected the worst. Downy oak and Scots pine have high accuracies. Although similar overall accuracies were achieved with both image analyses, the spatial distribution of tree species is different. In comparison with external inventory data, it was found that the object-based results matched better than the pixel-based results. For the derivation of the recommended action, the pixel-based results were used for the determination of the actual condition due to the higher overall accuracy. With the expert analysis, 62% spruce, 21% pine, and 17% stone pine forests were eliminated. By differing the current state with model data on future tree species composition, it was possible to calculate that 34% of the forest area would need to be converted under moderate climate change and 85% under severe climate change.

Inhaltsverzeichnis

1	Einleitung	1
1.1	Forschungsfrage	3
2	Material	4
2.1	Studiengebiet.....	4
2.2	Fernerkundungsdaten	5
2.2.1	Luftgestützte Daten	5
2.2.2	Satellitengestützte Daten	6
2.3	Forstliche Grundlagedaten	7
2.3.1	Vegetationshöhenmodell LFI	7
2.3.2	Toolkit Bestandeskarten TBk	7
2.3.3	NaiS - Nachhaltigkeit und Erfolgskontrolle im Schutzwald.....	7
2.3.4	Grundlagedaten Kanton Wallis	8
3	Methoden.....	9
3.1	Objektbasierte Bildanalyse (O1)	9
3.1.1	Datenvorverarbeitung	9
3.1.2	Segmentation	10
3.1.3	Trainingsdaten	12
3.1.4	Bildklassifizierung	15
3.1.5	Genauigkeitsanalyse	17
3.2	Pixelbasierte Bildanalyse (O2)	18
3.2.1	Trainingsdaten	18
3.2.2	Bildklassifizierung	21
3.2.3	Genauigkeitsanalyse	22
3.3	Vergleich und Validation der Ergebnisse (O3)	23
3.4	Handlungsempfehlung (O4).....	23
4	Ergebnisse.....	26
4.1	Objektbasierte Bildanalyse (O1)	26
4.1.1	Räumliche Verteilung der Baumarten	26
4.1.2	Genauigkeit der Klassifizierung	30
4.2	Pixelbasierte Bildanalyse (O2)	34
4.2.1	Räumliche Verteilung der Baumarten	34
4.2.2	Genauigkeit der Klassifizierung	38
4.3	Vergleich und Validation der Ergebnisse (O3)	39
4.3.1	Verteilung der Baumarten	39
4.3.2	Genauigkeit der Klassifizierungen	40
4.4	Handlungsempfehlung (O4).....	42
5	Diskussion	46
5.1	Segmentation.....	46
5.2	Trainingsdaten.....	47
5.3	Bildklassifizierung.....	49
5.3.1	Variablen und Klassifikator	49

5.3.2	Objektbasierte Bildanalyse (O1)	55
5.3.3	Pixelbasierte Bildanalyse (O2)	57
5.4	Vergleich und Validation der Ergebnisse (O3)	58
5.4.1	Vergleich beider Bildanalysen	58
5.4.2	Vergleich Genauigkeiten mit anderen Publikationen	60
5.4.3	Vergleich räumliche Verteilung mit anderen Publikationen	61
5.5	Handlungsempfehlung (O4).....	66
6	Schlussfolgerungen	67
7	Literaturverzeichnis	70

Anhang

- A Baumartenkartierung
- B Objekt- und pixelbasierte Baumartenklassifikation
 - B.1 Testgebiet 1
 - B.2 Testgebiet 2
 - B.3 Testgebiet 3
 - B.4 Testgebiet 4
- C Ist-Zustand und Handlungsempfehlung
 - C.1 Testgebiet 1
 - C.2 Testgebiet 2
 - C.3 Testgebiet 3
 - C.4 Testgebiet 4
- D Mögliche Standortstypen und Empfehlung der künftigen Baumartenzusammensetzung
- E Validation mit ausgeführten Holzschlägen

1 Einleitung

In Zukunft wird der Klimawandel noch weitere Auswirkungen auf den Wald haben. Laut der Studie von Frehner et al. (2018) werden sich die Vegetationshöhenstufen in der Schweiz voraussichtlich bis Ende des Jahrhunderts um etwa 500 bis 700 m nach oben verschieben und so erhebliche Auswirkungen auf die heute noch standortgerechten Baumarten haben. In der Studie wurde erarbeitet, wie sich die Waldstandorte (Standortstypen) in Zukunft verändern werden und welche Baumarten sich langfristig besser für bestimmte Standorte eignen. In der *Tree App* wurden diese Erkenntnisse digital umgesetzt und den Praktikern zur Verfügung gestellt (www.tree-app.ch). Gemäss der Studie ist dabei die Diskrepanz zwischen der aktuellen Lage und der anzustrebenden Baumartenzusammensetzung eines Bestandes entscheidend. Laut den Autoren werden deshalb waldbauliche Massnahmen nötig sein, um den Wald langfristig an den Klimawandel anzupassen. Für die zuständigen Forstfachleute sind deshalb für die Herleitung der Handlungsempfehlungen Informationen über die momentane und künftige Entwicklung der Baumartenzusammensetzung von zentraler Bedeutung.

Die Baumartenzusammensetzung von Waldbeständen kann mithilfe der Fernerkundung anhand verschiedenen Grundlagedaten ermittelt werden. Einerseits werden Daten von aktiven Sensorsystemen wie *Light Detection and Ranging* (LiDAR) eingesetzt (Guo et al., 2022; Liu et al., 2022; Qian et al., 2023). Die Identifizierung der Baumarten erfolgt dabei über die dreidimensionale Form der Baumkronen (Qian et al., 2023) oder über die spektrale Information der Messpunkte (*Multispectral Airborne Laser Scanning*) (Axelsson et al., 2018). Neben aktiven werden auch Daten von passiven Sensorsystemen wie Satelliten- oder Luftbilder für die Bildklassifizierung verwendet, wobei die Baumarten über die spektralen Informationen bestimmt werden (Shojanoori et al., 2018; Waser et al., 2011; Wessel et al., 2018). Durch die Kombination von aktiven und passiven Fernerkundungsdaten ist es möglich den Informationsgehalt weiter zu erhöhen (Jamal et al., 2022; Li et al., 2021). Die erwähnten Grundlagedaten können von terrestrischen Aufnahmesystemen (Choi et al., 2022; Liu et al., 2022), von luftgestützten Systemen wie Drohnen (Miyoshi et al., 2020; Schiefer et al., 2020) oder Flugzeugen (Waser et al., 2011; Yu et al., 2017) sowie von Satelliten (Wessel et al., 2018) stammen.

Es ist möglich die Baumarten über eine pixelbasierte oder objektbasierte Bildklassifizierung zu bestimmen. Laut Blaschke (2010) hängt die Wahl der Methode von der räumlichen Auflösung der Daten ab. Gemäss der Studie kann bei einer niedrigen räumlichen Auflösung eine pixel- sowie objektbasierte Bildanalyse angewendet werden, wobei bei einer hohen räumlichen Auflösung die objektbasierte Bildanalyse der pixelbasierten überlegen ist. Die objektbasierte Bildanalyse setzt eine Bildsegmentierung voraus, wobei einzelne Pixel themenbasiert in Vektor-Objekte gruppiert werden. Bäume bzw. Baumkronen können mit verschiedenen Methoden segmentiert werden. Unter anderem werden dazu Algorithmen wie die *Multiresolution Segmentation* (Jamal et al., 2022) oder die *Mean Shift*

Segmentation (Maschler et al., 2018) eingesetzt. Es ist auch möglich mittels Deep Learning Algorithmen Baumkronen abzugrenzen (Freudenberg et al., 2022).

Bei einer überwachten Klassifizierung (pixel- sowie objektbasiert) werden Trainingsdaten benötigt, welche aus lokalen Inventuren stammen können. Zusammen mit diesen Daten ist es möglich, die Baumarten mithilfe diverser Algorithmen zu klassifizieren. Verbreitet ist die Anwendung von nichtparametrischen Machine Learning Algorithmen wie *Random Forest* (Immitzer et al., 2012; Ma et al., 2021; Qin et al., 2022) oder *Support Vector Machine* (Nguyen et al., 2019; Wessel et al., 2018). Es wird auch Deep Learning für die Klassifizierung eingesetzt (Li et al., 2021). Die Leistung dieser Algorithmen hängt wesentlich von der Qualität der Trainingsdaten und der gewählten Untersuchungsgebiete ab (Wessel et al., 2018). Die Genauigkeit der Ergebnisse kann erhöht werden, wenn neben den spektralen Informationen der Bilddaten weitere Variablen oder Indizes genutzt werden (Maschler et al., 2018; Waser et al., 2011).

Die Wahl der Grundlagedaten hängt von den zur Verfügung stehenden Ressourcen und nicht von der resultierenden Präzision der Ergebnisse ab. Die Genauigkeit der Klassifizierung von Landnutzungs- und Landbedeckungskategorien sollte gemäss dem *United States Geological Survey* mindestens 85 % ergeben, damit das Ergebnis zufriedenstellend ist (United States Geological Survey, 1976). Es können mit LiDAR-, Luftbild- oder Satellitendaten gute Ergebnisse mit Genauigkeiten über 85 % erzielt werden (Maschler et al., 2018; Qian et al., 2023; Shojanoori et al., 2018). Sogar mit Satellitenbilder mit einer Auflösung von 10 m können gleich gute Genauigkeiten erreicht werden (Wessel et al., 2018). Dadurch ist mit Sentinel-2 ein grosses Potenzial für die Forstwirtschaft gegeben. Dies nicht nur wegen den Ergebnissen, sondern auch aufgrund der freien Verfügbarkeit der Daten. Durch die Wiederholungszeit von 5 Tagen in den mittleren Breiten (European Space Agency, 2015) sind ausserdem Zeitreihenanalysen möglich. Hinsichtlich der Klassifizierungsmethoden können mit traditionellen Machine Learning Algorithmen wie *Random Forest* und *Support Vector Machine* sowie mit Deep Learning Algorithmen ebenfalls Ergebnisse mit einer Genauigkeit über 85 % generiert werden (Li et al., 2021; Qin et al., 2022; Wessel et al., 2018). Die Wahl des Klassifikators ist deshalb von geringer Bedeutung, sofern die Grundlagedaten auf die Anforderungen des Klassifikators vorverarbeitet wurden (Fassnacht et al., 2016). Im direkten Vergleich ist die Klassifizierung mittels Deep Learning jedoch am genauesten, gefolgt von *Support Vector Machine* und *Random Forest* (Li et al., 2021; Raczko & Zagajewski, 2017).

1.1 Forschungsfrage

Ziel dieser Arbeit ist es zu evaluieren, ob die Bestimmung von Baumarten in einem Gebirgswald im Kanton Wallis mit einer objektbasierten Bildanalyse mit Luftbildern oder mit einer pixelbasierten Bildanalyse mit Satellitenbildern besser geeignet ist, um dies als Grundlage von Handlungsempfehlungen hinsichtlich der klimatisch bedingten Veränderungen nutzen zu können.

Das erste operative Teilziel (O1) beinhaltet die Bestimmung der Baumartenzusammensetzung in der Hauptschicht auf Stufe Baum mit einer objektbasierten Bildanalyse. Anhand orthorektifizierten multispektralen Luftbildstreifen aus dem Jahr 2020 und mit einer räumlichen Auflösung von 25 cm soll eine genügend hohen Genauigkeit von 85 % erreicht werden. Die Analyse soll in einem repräsentativen Gebirgswald im Kanton Wallis durchgeführt werden, welcher verschiedene Expositionen und Höhenstufen abdeckt.

Mit dem zweiten operativen Teilziel (O2) sollen im selben Gebirgswald die Baumarten in der Hauptschicht auf Stufe Bestand mit einer pixelbasierten Bildanalyse bestimmt werden. Mittels freiverfügbaren Sentinel-Satellitenbildern in einer Auflösung von 10 m soll eine genügend hohen Genauigkeit von 85 % erzielt werden.

Das dritte operative Teilziel (O3) beinhaltet den Vergleich der Ergebnisse beider Bildanalysen miteinander und die Validation anhand der Gesamtgenauigkeit.

Im vierten operativen Teilziel (O4) soll mit den Ergebnissen mit der höheren Gesamtgenauigkeit der Ist-Zustand beschrieben werden. Im Vergleich mit Modelldaten über die künftige Baumartenzusammensetzung sollen mittels der Differenz Handlungsempfehlungen hinsichtlich einem Waldumbau hergeleitet werden.

2 Material

2.1 Studiengebiet

Das Studiengebiet (Abb. 1) umfasst rund 50 km² und liegt im Forstrevier «Forst Region Leuk» im Süden der Schweiz (2'617'000 / 1'128'000 EPSG:2056). Aufgrund der Lage, der Höhenunterschiede und der damit verbunden unterschiedlichen Wälder, ist das Forstrevier repräsentativ für den ganzen Kanton und somit gut geeignet für die vorliegende Studie. Das Studiengebiet ist in folgende Testgebiete unterteilt: Testgebiet 1 [3.5 km²], Testgebiet 2 [23.5 km²], Testgebiet 3 [20.0 km²] und Testgebiet 4 [3.0 km²]. Bei der Abgrenzung der Testgebiete sind die verschiedenen klimatischen Bedingungen hinsichtlich Exposition und Topografie berücksichtigt worden.

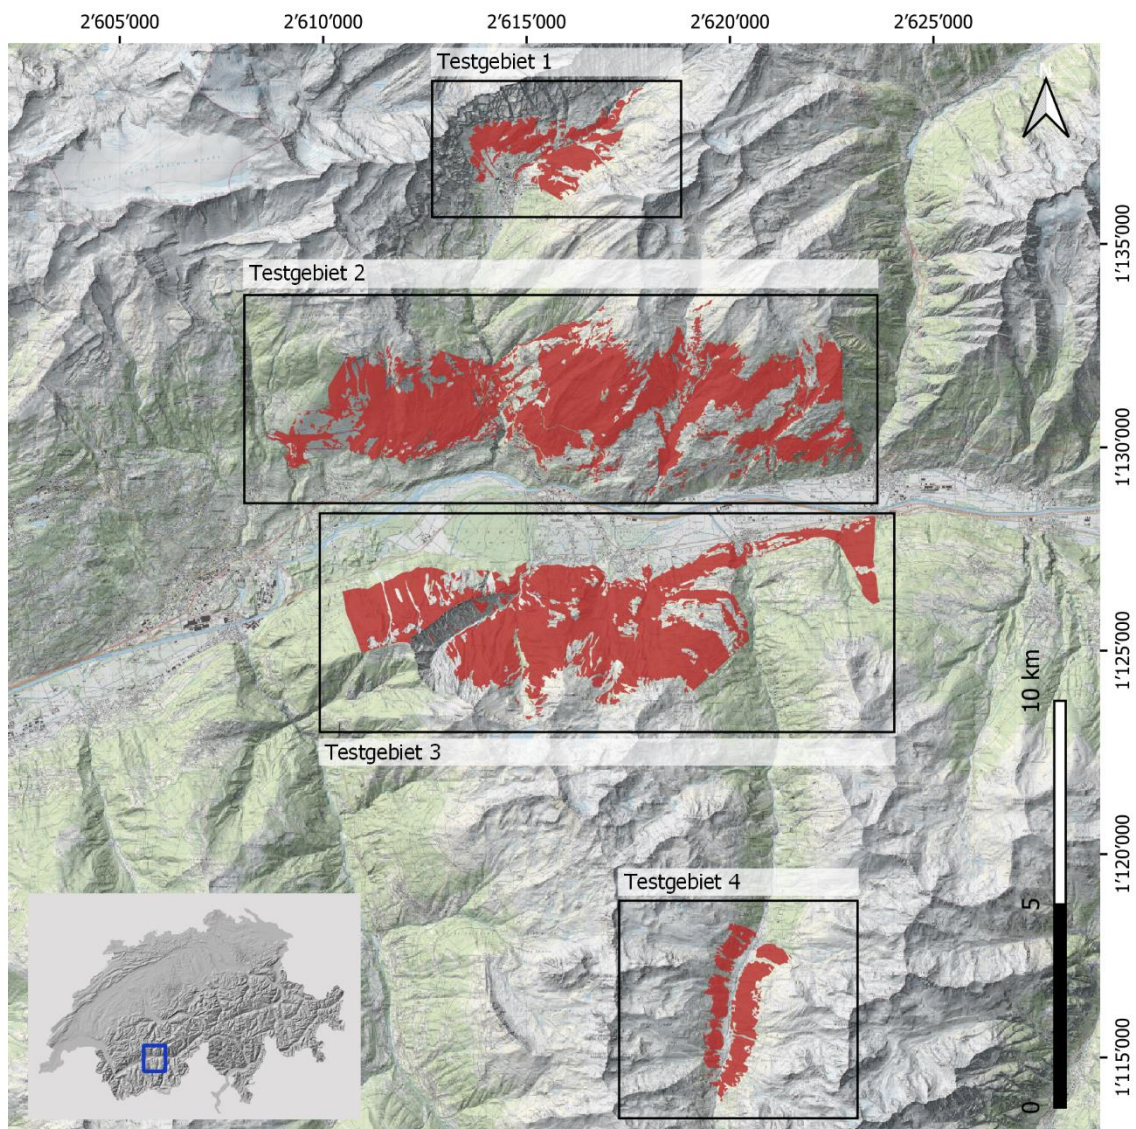


Abb. 1: Übersicht Studiengebiet und 4 Testgebiete in rot

Die Perimeter wurden auf Grundlagen der Geodaten «Forstreviere» und «Bestockte Fläche» abgegrenzt (siehe Kap 2.3.4). Das Testgebiet 1 liegt im nördlichen Seitental des Rhonetals bei Leukerbad. Das Gebiet ist zwischen 1'400 und 2'000 m ü. M. gelegen. Das Testgebiet 2 liegt an der nördlichen Flanke des Rhonetals und erstreckt sich von Salgesch nach Gampel. Die Wälder im Perimeter reichen von 800 bis auf 2'300 m ü. M. an die obere Baumgrenze. Das Testgebiet 3 liegt an der südlichen Flanke des Rhonetals. Die Wälder sind im Perimeter zwischen 600 und 2'300 m ü. M. gelegen. Das Testgebiet 4 liegt südlich vom Rhonetal im Turtmantal. Die Wälder kommen zwischen 1'800 und 2'200 m ü. M. vor.

2.2 Fernerkundungsdaten

2.2.1 Luftgestützte Daten

Für die objektbasierte Bildanalyse wurden multispektrale swissimage RS Lufbilder verwendet, welche vom Bundesamt für Landestopografie (swisstopo) aufgenommen wurden. Die Daten liegen im Schweizerischen Bezugssystem LV95 (EPSG:2056) vor. Die Bilddaten setzen sich aus Teilstücken von orthorektifizierten Bildstreifen zusammen und enthalten folgende spektrale Informationen: NIR [808 - 882 nm], Rot [619 - 651 nm], Grün [525 – 585 nm] und Blau [435 – 495 nm] (Produktseite von swisstopo). Die Bilder stehen in einer Bodenauflösung von 0.1 m (Flachland) und 0.25 m (Berggebiet) zur Verfügung. Für die vier Testgebiete wurden deshalb Luftbilder in einer Auflösung von 0.25 m verwendet. Es sind Lufbilder aus dem Jahr 2020 analysiert worden, welche in einem Zeitfenster von drei Tagen aufgenommen wurden: Testgebiet 1 [2020-08-08], Testgebiet 2 [2020-08-07], Testgebiet 3 [2020-08-06] und Testgebiet 4 [2020-08-06 und 2020-08-07]. Das Zeitfenster wurde so kurz wie möglich gehalten, um Probleme bei der Baumartendifferenzierung aufgrund jahreszeitlicher Entwicklungen zu eliminieren. Für die vier Testgebiete sind folgende Bildstreifen verwendet worden (Tab. 1):

Tab. 1: swissimage RS Bildstreifen für objektbasierte Bildanalyse

Testgebiet	Bildstreifen	Testgebiet	Bildstreifen
Testgebiet 1	20200808_0853_12504_0_23	Testgebiet 3	20200806_1123_12504_0_21
	20200808_0853_12504_0_24		20200806_1123_12504_0_22
Testgebiet 2	20200807_1013_12504_0_21		20200806_1123_12504_0_23
	20200807_1013_12504_0_22		20200806_1123_12504_0_24
	20200807_1013_12504_0_23	20200806_1235_12504_0_25	
	20200807_1013_12504_0_24	20200806_1235_12504_0_26	
	20200807_1013_12504_0_25	Testgebiet 4	20200806_0948_12504_0_25
	20200807_1013_12504_0_26		20200806_0948_12504_0_26
	20200807_1033_12504_0_24		20200807_1136_12504_0_8
	20200807_1033_12504_0_25		20200807_1136_12504_0_9
	20200807_1033_12504_0_26		
	20200807_1033_12504_0_27		
	20200807_1033_12504_0_28		
20200807_1033_12504_0_29			

2.2.2 Satellitengestützte Daten

Für die pixelbasierte Bildanalyse sind hyperspektrale Satellitenbilder aus der Copernicus Sentinel-2 Mission verwendet worden (atmosphärisch korrigierten Level-2A-Daten). Die Daten liegen im Referenzsystem WGS84 (EPSG:4326) vor. Die 13 Bänder sind in drei verschiedenen räumlichen Auflösungen verfügbar (10 m, 20 m und 60 m) . Über die Webapplikation «sentinelhub Playground» können Bildszenen gesucht und mit dem «Copernicus Open Access Hub» heruntergeladen werden. Die wesentlichen Wahlkriterien sind dabei der Bewölkungsgrad und der Aufnahmezeitpunkt. Für die Klassifikation wurden Aufnahmen aus dem gleichen Jahr wie die swissimage RS Bildstreifen verwendet (Tab. 2).

Tab. 2: Sentinel-Satellitenbilder für pixelbasierte Bildanalyse

Produkt Level	Aufnahmedatum	Aufnahmezeit	Wolkenabdeckung
Level-2A	2020-05-29	13:54:55	16.8 %
Level-2A	2020-06-23	14:28:51	0.3 %
Level-2A	2020-08-07	13:20:26	0.3 %

2.3 Forstliche Grundlagedaten

2.3.1 Vegetationshöhenmodell LFI

Die Eidg. Forschungsanstalt für Wald, Schnee und Landschaft (WSL) hat im Rahmen des Schweizerischen Landesforstinventars (LFI) ein Vegetationshöhenmodell für die ganze Schweiz berechnet (Ginzler, 2018). Das Modell basiert auf ADS80-Luftbilder und wird regelmässig aktualisiert. Aus den Stereoluftbildern wurde ein digitales Oberflächenmodell (DSM) in hoher Auflösung (1 x 1m) und mit einem digitalen Geländemodell (DTM) normalisiert. Das Vegetationshöhenmodell (VHM) steht in einer Auflösung von 1 m zur Verfügung. Für die vorliegende Arbeit diente als Grundlage das Modell von 2019.

2.3.2 Toolkit Bestandeskarten TBk

Die Hochschule für Agrar-, Forst- und Lebensmittelwissenschaften (HAFL) erarbeiteten zusammen mit der Eidg. Forschungsanstalt für Wald, Schnee und Landschaft (WSL) im Rahmen des Projekts FINT-CH (Find individual trees in CH) eine Bestandeskarte (TBk) aus (Dorren et al., 2021). In der Bestandeskarte ist eine Schätzung des Nadelholzanteils basierend auf Sentinel-Satellitenbilder enthalten, welche für die Analyse verwendet wurde.

2.3.3 NaiS - Nachhaltigkeit und Erfolgskontrolle im Schutzwald

Das Bundesamt für Umwelt (BAFU ehemals BUWAL) hat 2005 die Wegleitung «NaiS - Nachhaltigkeit und Erfolgskontrolle im Schutzwald» herausgegeben (Frehner et al., 2005). Sie hat zum Ziel, Handlungsempfehlungen für die Waldbewirtschaftung zu geben, damit mit einem minimalen Aufwand die nachhaltige Erfüllung der Schutzfunktion gewährleistet ist. Der Kanton Wallis hat die Wegleitung weiter vereinfacht und in einer kürzeren Fassung ausgegeben (Sàrl, 2011). Darin sind die wichtigsten Standortstypen für den Kanton ersichtlich. Die wichtigsten Grundlagen für die Herleitung der Baumartenempfehlung sind die Standortsregionen, Standortstypen und Ökogramme der Wegleitung. Die Standortsregionen konnten von der Webseite map.geo.admin.ch kostenfrei bezogen werden (Layer: Waldstandortsregionen).

Auf Grundlage der Wegleitung vom Bundesamt wurde die Tree App entwickelt. Die Tree App ist eine von verschiedenen Fachleuten entwickelte Applikation, welche in einer Webkarte an einem Ort in der Schweiz Empfehlungen für zukunftsfähige Baumarten zur Verfügung stellt. Sie gibt dabei Empfehlungen für die folgenden drei Klimaszenarien wieder: Klima heute, mässiger Klimawandel und starker Klimawandel. Weitere Informationen können von der Webapplikation (tree-app.ch) entnommen werden. Für die vorliegende Arbeit konnten die Höhenstufen kostenfrei von der Webseite map.geo.admin.ch heruntergeladen werden. Die Daten entsprechenden Klimaszenarien von Tree App wie folgt (Tab. 3):

Tab. 3: Vegetationshöhenstufen vom Bundesamt für Umwelt im Zusammenhang mit Klimaszenarien Tree App

Geodaten map.geo.admin	Beschreibung	Klimaszenario Tree App
Höhenstufen 1975	Vegetationshöhenstufen modelliert für 1975	Klima heute (1961-1990)
Höhenstufen 2085 mässig trocken	Vegetationshöhenstufen modelliert für 2085 mit weniger trockener Klimazukunft	mässiger Klimawandel (2070-2099)
Höhenstufen 2085 trocken	Vegetationshöhenstufen modelliert für 2085 mit trockener Klimazukunft	starker Klimawandel (2070-2099)

2.3.4 Grundlagedaten Kanton Wallis

Für die Abgrenzung der Testgebiete und die Vorbereitung der Feldaufnahmen wurden diverse Geodaten vom Kanton Wallis zur Verfügung gestellt. Die verwendeten Daten sind in der folgenden Tabelle zusammengestellt (Tab. 4).

Tab. 4: Grundlagedaten Kanton Wallis

Datensatz	Datenbank	Beschreibung	Letzte Aktualisierung
Triages_forestiers.shp	Geodaten Inventar Kanton	Forstreviere	2017-03-07
Surface_boisee.shp	Geodaten Inventar Kanton	Bestockte Fläche	-
ASSOCIATIONS_FORES	ASSOCIATIONS_FORESTIERE	Waldgesellschaften	2017-12-06
TIERES_WERLEN_1997	S_WERLEN_1997.gdb	Werlen 1997	

3 Methoden


3.1 Objektbasierte Bildanalyse (O1)

Sämtliche Arbeitsschritte der objektbasierten Bildanalyse erfolgte im Schweizerischen Bezugssystem LV95 (EPSG:2056). Die Datenverarbeitung in ArcGIS Pro wurde mit der Softwareversion 3.0.3 durchgeführt.


3.1.1 Datenvorverarbeitung

Die swissimage RS-Bildstreifen sind mit ArcGIS Pro in Raster-Datasets zusammengeführt und auf die Perimeter der Testgebiete zugeschnitten worden. Um den Datensatz für die Segmentierung noch weiter einzugrenzen, sind die Daten vorverarbeitet worden. Laut Ke & Quackenbush (2011) hat die Datenvorverarbeitung das Ziel, die Unterscheidung zwischen den zu erkennenden Objekten mit dem Hintergrund zu verbessern. Wie in der Studie beschrieben kann dies durch die Eliminierung irrelevanter Bereiche wie Schatten oder vegetationslosen Flächen erfolgen. Für die Analyse wurden deshalb schattige Bereiche und Flächen mit geringer Vegetationsproduktivität ausgeschlossen. Zudem ist auch Vegetation kleiner als 3 m nicht berücksichtigt worden.


Schattige Bereiche können mit dem spektralen Bereich des nahen Infrarots (NIR; swissimage RS-Band 1) ermittelt werden. Der Schwellenwert für die Abgrenzung des Schattens liegt bei einem Zellenwert von 1400, wobei tiefere Werte schattige Bereiche aufzeigen (Abb. 2; a). Die Vegetationsproduktivität kann mit dem Normalized Difference Vegetation Index (NDVI) berechnet werden. Rasterzellen mit einem Index kleiner 130 zeigen dabei eine geringe Vegetationsproduktivität auf (Abb. 2; b). Die Baumhöhe entspricht der Höhe aus dem Vegetationshöhenmodell LFI. Es sind Rasterzellen mit Werten grösser 3 m berücksichtigt worden. Aufgrund der geringen Auflösung von einem Meter, wurde um den Bestand eine Pufferzone von 2 m berechnet (Abb. 2; c). Die Schnittmenge der drei Zwischenergebnisse entspricht der neuen Beurteilungsgrenze (Abb. 2; d). Es wurden Polygone kleiner als 2 m² entfernt (ausserhalb und innerhalb anderer Polygone), damit ein lückenloser Datensatz entstand. Die Grenzlinie der neuen Beurteilungszone wurde in einem letzten Schritt geglättet.



(a) Eliminierung Schatten mit NIR < 1400



(b) Eliminierung geringe Vegetationsproduktivität mit NDVI < 130



(c) Vegetation kleiner 3 m mit Pufferzone von 2 m



(d) Neue Beurteilungsgrenze

Abb. 2: Schritte der Vorverarbeitung der swissimage RS-Bildstreifen

3.1.2 Segmentation

Die Baumkronen sind mit dem *Mean Shift Segmentation* Algorithmus in ArcGIS Pro abgegrenzt worden. Mittels Trial-and-Error sind folgende Parameter bestimmt worden: *Spectral Detail* [16]; *Spatial Detail* [15]; *Minimum Segment Size* [70]. Die Bildsegmentierung wurde mit der spektralen Auflösung NIR, Rot, Grün und Blau der Orthofotos durchgeführt. Aufgrund der tiefen Auflösung von einem Meter sind die Höhendaten vom Vegetationshöhenmodell LFI für die Segmentation nicht geeignet. Für die Abgrenzung von Bäumen werden Features benötigt, welche getrennt klassifiziert, aber ähnliche spektrale Eigenschaften aufweisen. Sie müssen eher klein und zusammengefasst sein. Das bedeutet, dass eine zu starke Glättung der Ausgabe nicht optimal wäre. Für die Steuerung der Segmentation wurde deshalb ein eher höherer Wert für das *Spectral* und *Spatial Detail* angestrebt.

Alternativ wurden die Baumkronen mit dem *Multiresolution Segmentation* Algorithmus in eCognition Developer (Version 10.2) segmentiert. Neben der spektralen Auflösung sind auch die Höheninformationen vom Vegetationshöhenmodell LFI berücksichtigt worden. Mittels Trial-and-Error wurden folgende Parameter ermittelt: *Image Layer Weights* [NIR 3, Rot 2, Grün 2, Blau 2, VHM 1]; *Scale Parameter* [60]; *Shape* [0.9]; *Compactness* [0.9]. Die Segmentierung mit einer Parametereinstellung zugunsten ähnlicher Spektralfarben und einer geringen Glättung (ähnliche Einstellungen wie mit dem *Mean Shift Segmentation* Algorithmus) generierte zu kleinflächige Features. Deshalb ist in der Parametrisierung versucht worden die Baumkronen anhand ihrer Form und einer Glättung der Spektralfarben abzugrenzen. Mit der *Multiresolution Segmentation* wurden im Vergleich zur *Mean Shift Segmentation* mit einem ähnlichen Zeitaufwand eher schlechtere Ergebnisse erzielt (Abb. 3). Deshalb ist für die Bildklassifizierung das Ergebnis der *Mean Shift Segmentation* weiterverwendet worden. Bildsegmentierungen können unter anderem auch in QGIS mithilfe der Orfeo Toolbox (OTB) oder mit Deep Learning generiert werden. Aus zeitlichen Gründen wurde in der vorliegenden Arbeit auf diese Ansätze nicht eingegangen.

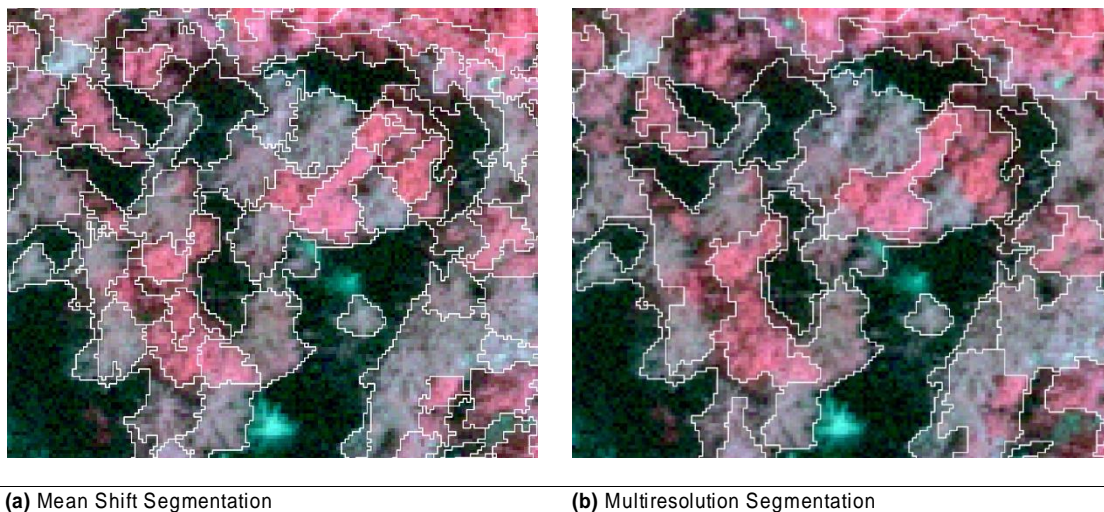


Abb. 3: Vergleich der Ergebnisse von den zwei Bildsegmentierungs-Algorithmien

3.1.3 Trainingsdaten

Für die Klassifikation wurde ein Trainingsdatensatz im Wald innerhalb der Testgebiete aufgenommen. Die relevanten Baumarten und Bestände sind mithilfe Geodaten über die Hauptbaumarten «Waldgesellschaften Werlen 1997» festgelegt worden. Aufgrund der dominierenden Baumarten im Studiengebiet, wurden für die Klassifikation folgende Hauptbaumarten berücksichtigt: Fichte (*Picea abies*), europäische Lärche (*Larix decidua*), Waldföhre (*Pinus sylvestris*), Weisstanne (*Abies alba*), Arve (*Pinus cembra*), Flaumeiche (*Quercus pubescens*) und übriges Laubholz (Gruppe aus den restlichen Laubholzarten). Weil die übrigen Laubholzarten in den Beständen nur gemischt vorkommen, wäre eine weitere Unterteilung mit viel Aufwand bei der Felderhebung verbunden gewesen. Laut Fasnacht et al. (2016) sollten die Standorte der Trainingsdaten repräsentativ für das Studiengebiet sein. Gemäss den Autoren beinhaltet dies unter anderem, dass unterschiedliche Baumalter und Expositionen berücksichtigt werden. Die 7 Trainingsgebiete decken die zu untersuchenden Hauptbaumarten in verschiedenen Expositionen ab und liegen im Studiengebiet verteilt vor (Abb. 4). Ausserdem wurden verschieden altrige Bäume ab einer Baumhöhe von 3 m aufgenommen.





Abb. 4: Übersicht der Trainingsgebiete (T1-T7) in blau

Abb. 5: Baumartkartierung mithilfe der QField-App

Die Kartierung erfolgte manuell auf einem Tablet mithilfe der QField-Applikation (Version 2.3.4) (Abb. 5). Die Baumarten sind auf Grundlage der swissimage RS Bildstreifen erfasst worden. In anderen Studien wurde für die Kartierung unter anderem RTK GNSS-Empfänger eingesetzt (Qin et al., 2022; Waser et al., 2011). Aufgrund der steilen Topografie im Studiengebiet und der Abschirmung der Bäume sind ungenaue Messergebnisse nicht auszuschliessen. Deshalb wurde die vorliegende Methode angewendet. Die Kartierung fand während September - Oktober 2022 statt. Die aufgenommene Waldfläche weist eine Fläche von rund 19.2 ha auf: Trainingsgebiet 1 [1.5 ha], Trainingsgebiet 2 [2.4

ha], Trainingsgebiet 3 [2.7 ha], Trainingsgebiet 4 [1.1 ha], Trainingsgebiet 5 [1.3 ha], Trainingsgebiet 6 [6.5 ha] und Trainingsgebiet 7 [3.7 ha]. Die aufgenommenen Bestände sind hinsichtlich der Baumarten mehrheitlich gemischt und charakterisieren sich durch eine horizontale und vertikale Strukturierung. Die detaillierte Beschreibung der Baumartenkartierung ist im Anhang A ersichtlich. Die Baumartengruppe «übriges Laubholz» beinhaltet mehrheitlich folgende Baumarten: Esche (*Fraxinus excelsior*), Zitterpappel (*Populus tremula*), Berg-Ahorn (*Acer pseudoplatanus*), Salweide (*Salix caprea*), echter Mehlbeerbaum (*Sorbus aria*), Grau-Erle (*Alnus incana*) und Kirsche (*Prunus avium*).

Laut Fassnacht et al. (2016) hängt die Anzahl Trainingsdaten von der Fragestellung und dem Lernalgorithmus ab. Ausserdem sollten gemäss der Studie Klassen mit zu wenig Stichproben von der Klassifizierung ausgeschlossen werden. In verschiedenen Studien liegt die Anzahl der Trainingsdaten in einem Bereich zwischen 20 und 250 Stichproben pro Baumart (Immitzer et al., 2012; Maschler et al., 2018; Qin et al., 2022). Deshalb wurde eine Mindestanzahl von 300 Exemplaren pro Baumart angestrebt. Gesamthaft sind 2'854 Bäume kartiert worden. Aufgeschlüsselt nach Baumart sieht die Kartierung wie folgt aus (Tab. 5).

Tab. 5: Baumartenkartierung aufgeschlüsselt nach Baumart

Deutscher Name / Gruppe	Wissenschaftlicher Name	Typ	Anzahl Objekte	Anteil [%]
Arve	<i>Pinus cembra</i>	Nadelholz	334	11.7
Fichte	<i>Picea abies</i>	Nadelholz	387	13.6
Flaumeiche	<i>Quercus pubescens</i>	Laubholz	405	14.2
Lärche	<i>Larix decidua</i>	Nadelholz	424	14.9
übriges Laubholz	-	Laubholz	374	13.1
Waldföhre	<i>Pinus sylvestris</i>	Nadelholz	575	20.1
Weisstanne	<i>Abies alba</i>	Nadelholz	355	12.4
			2'854	100.0

Die Baumartenkartierung wurde mit der Segmentierung verglichen und situativ minimal in der Lage korrigiert (Abb. 6; A). Die Segmentierung ist im Bereich der Kartierung ebenfalls visuell anhand von Luftbilder korrigiert worden (Abb. 6; B). Mit der räumlichen Verbindung der Kartierung mit der Segmentierung ist der Trainingsdatensatz entstanden (Abb. 6; C).




Abb. 6: Räumliche Verbindung der Baumartenkartierung mit der Baumkronen-Segmentation

Der prozentuale Anteil der verschiedenen Baumarten liegt in der Kartierung zwischen 12 und 20 % (Tab. 5). Dieses Ungleichgewicht zwischen den Klassen kann den Lernprozess eines Klassifizierungsmodells beeinträchtigen und so die Leistung des Klassifikators verschlechtern (Javaheri et al., 2014; Tarekegn et al., 2021). Laut Tarekegn et al. (2021) sind *Resampling* Ansätze die am meisten angewendeten Techniken zur Behebung dieses Problems. Gemäss der Studie kann dies durch ein *Undersampling* auf die am wenigsten vertretene oder ein *Oversampling* auf die am meisten vertretene Klasse erfolgen, wobei ein ausgeglichener Datensatz angestrebt wird. Für die vorliegende Klassifikation ist deshalb der Trainingsdatensatz mit der *Undersampling* Methode mit einer zufälligen Auswahl in QGIS (Version 3.28.4) auf 334 Exemplare pro Baumart reduziert worden.

Wie in Fassnacht et al. (2016) beschrieben ist, kann der Trainingsdatensatz in Trainings- und Referenzdaten aufgeteilt werden um ein *Overfitting* vom Klassifikationsmodell zu vermeiden. Laut der Studie ist der gängigste Ansatz die Aufteilung in 70 % Trainings- und 30 % Referenzdaten. Ausserdem wird empfohlen einen Teil des Datensatzes als unabhängigen Testdatensatz (Blinddaten) für die Validierung der Baumartenklassifizierung (*Ground Truth*) beiseite zu legen. Von den 334 Stichproben sind deshalb 10% Blinddaten [33] entnommen worden. Die restlichen 90% wurden in 70% Trainings-[211] und 30% Referenzdaten [90] aufgeteilt. In der Tabelle 6 ist der Trainingsdatensatz für die objektbasierte Baumartenklassifikation ersichtlich.

Tab. 6: Trainingsdaten für objektbasierte Baumartenklassifikation

Deutscher Name / Gruppe	Wissenschaftlicher Name	Anzahl Objekte
Arve	<i>Pinus cembra</i>	334
Fichte	<i>Picea abies</i>	334
Flaumeiche	<i>Quercus pubescens</i>	334
Lärche	<i>Larix decidua</i>	334
übriges Laubholz	-	334
Waldföhre	<i>Pinus sylvestris</i>	334
Weisstanne	<i>Abies alba</i>	334
		2'338

3.1.4 Bildklassifizierung

Die vier Testgebiete mussten aufgrund der grossen Datenmengen einzeln klassifiziert werden. Damit alle Baumarten aus den Trainingsdaten in der Analyse berücksichtigt werden sind die sieben Trainingsgebiete mit einer *Bounding Box* abgegrenzt und den Testgebieten hinzugefügt worden. Bildklassifizierungen können in verschiedenen Softwareapplikationen durchgeführt werden (eCognition Developer, ERDAS Imagine, etc.). Aufgrund der zur Verfügung stehenden Mittel ist die Klassifikation der Baumarten in ArcGIS Pro mit dem *Classification Wizard*-Steuerelement durchgeführt worden. Ein Variantenstudium im Testgebiet 4 mit verschiedenen Klassifikatoren und Variablen diente dazu, die bestmögliche Genauigkeit aus den Daten zu erhalten. Aufgrund der Erkenntnisse der Studie, wurde für die Klassifizierung der *Support Vector Machine* Algorithmus ausgewählt. Es sind folgende Segmentattribute verwendet worden: konvergierender Farbwert, durchschnittlicher Digitalnummernwert, Standardabweichung. Die Pixelanzahl und Kompaktheit wurden nicht berücksichtigt, weil in der Kartierung Bäume aus allen Altersklassen mit verschiedenen Kronenformen aufgenommen wurden. Neben der Segmentation und den Trainings- / Referenzdaten wird für die Klassifikation ein *Classification Schema* benötigt. Das *Schema* konnte im *Trainings Samples Manager* erstellt werden. Am Ende der Klassifikation ist keine Reklassifizierung durchgeführt worden. Um den Informationsgehalt bzw. die Genauigkeit weiter zu erhöhen sind neben den spektralen Informationen (NIR, Rot, Grün, Blau) noch weitere Variablen in den Rasterdatensatz integriert worden. Folgend ist die Zusammenstellung der Bänder ersichtlich (Tab. 7).

Tab. 7: Verwendete Variablen (Raster Komposit) in der objektbasierten Baumartenklassifikation

Band	Variable	Beschreibung	Grundlage
1 - 4	NIR RGB	Band 1: Nahinfrarot, Band 2: Rot, Band 3: Grün, Band 4: Blau	swissimage RS
5	NDVI	Normalized Difference Vegetation Index: [NIR-Rot]/[NIR+Rot]	swissimage RS
6	VHM	Vegetationshöhenmodell	Vegetationshöhenmodell LFI
7 - 9	HSV	Farbmodellkonvertierung RGB zu HSV: Band 7: Hue, Band 8: Saturation, Band 9: Value	swissimage RS
10	NH	Nadelholzanteil	Toolkit Bestandeskarten TBk

Neben der Verwendung von Hyperspektraldaten für die Klassifizierung von Baumarten (Fassnacht et al., 2016), kann mit dem Einbezug von Vegetationsindizes die Ergebnisse verbessert werden (Ma et al., 2021; Maschler et al., 2018). Für die Klassifizierung relativ offener Laubbäume ist dies unter anderem hilfreich, weil dadurch Hintergrundeffekte korrigiert werden (Maschler et al., 2018). Der Vegetationsindex NDVI konnte in ArcGIS Pro über die *Raster Functions* berechnet werden. Die Kombination von Höhen- und Hyperspektraldaten können die Ergebnisse prinzipiell nicht wesentlich verbessern, weil die Baumhöhe nicht von der Baumart, sondern vom Alter, den Standortbedingungen und der Konkurrenz abhängig ist (Fassnacht et al., 2016). Im Variantenstudium hat es sich aber gezeigt, dass mit der Integration der Baumhöhe im Studiengebiet wesentlich bessere Ergebnisse erzielt werden konnten. Die Baumhöhe basiert auf dem Vegetationshöhenmodell LFI. In der Studie von Waser et al. (2011) wurde aufgezeigt, dass spektrale Variablen für die Klassifikation von Baumarten nützlich sein können. Für die vorliegende Klassifizierung wurde in ArcGIS Pro über die *Raster Functions* der Farbraum RGB mit der Funktion «Color Model Conversion» in den Farbraum HSV (Farbton [H], Sättigung [S] und Helligkeitswert [V]) konvertiert. Im Variantenstudium ist ausserdem als zusätzliche Variable die Konvertierung von einem *Color Infrared Luftbild* (CIR) in den Farbraum HSV getestet worden. Weil durch diese Farbtransformation die Ergebnisse nicht verbessert werden konnten, wurde dieser Ansatz nicht weiterverfolgt. Im Variantenstudium ging ausserdem hervor, dass das Modell mit der Information über den Nadelholzanteil verbessert werden kann. Deshalb ist der Vektordatensatz von der Bestandeskarte TBk in den zu analysierenden Datensatz integriert worden.

Hinsichtlich dem Klassifikator wurde im Variantenstudium neben *Support Vector Machine* auch der *Random Forest* Algorithmus getestet. Die Anwendung dieser beiden Algorithmen ist für die Klassifikation von Baumarten weit verbreitet (Fassnacht et al., 2016). Mit dem *Support Vector Machine* Algorithmus sind jedoch bessere Ergebnisse erzielt worden. Aus Zeitgründen wurde auf eine Klassifizierung mit anderen Machine Learning oder Deep Learning Algorithmen verzichtet. Es wurde auch getestet, ob mit dem Einbezug von allen Trainingsdaten bessere Ergebnisse erzielt werden können. Aufgrund des Ungleichgewichts in den Daten waren die Ergebnisse für das Studiengebiet schlechter.

3.1.5 Genauigkeitsanalyse

Die Genauigkeit vom Modell wurde im *Classification Wizard*-Steuerelement ermittelt. Die Ergebnisse der Klassifizierung werden dabei mit den Referenzdaten verglichen und in einer Konfusionsmatrix ausgegeben. Die Analyse basierte auf einem Referenzpunktschema mit einer abgeglichenen stratifizierten Zufallsstichprobe mit 500 zufälligen Punkten.


Neben den Genauigkeiten aus der Konfusionsmatrix konnte die Genauigkeit der Vorhersage mittels den Blinddaten manuell berechnet werden (*Ground Truth*). Die Segmentierung der Baumkronen für die Bildklassifizierung ist nicht deckungsgleich mit der Segmentierung der Referenzdaten. Deshalb kann es vorkommen, dass innerhalb einer einzelnen Referenzfläche mehrere Baumarten vorhergesagt werden. Aus diesem Grund erfolgte die Ermittlung der Genauigkeit über den Verschnitt der Blinddaten mit der Baumartenklassifizierung. Der Flächenanteil einer spezifischen Baumart an der Gesamtfläche entspricht dabei der Genauigkeit der Vorhersage.

3.2 Pixelbasierte Bildanalyse (O2)

Sämtliche Arbeitsschritte der pixelbasierten Bildanalyse erfolgten im Referenzsystem WGS84 (EPSG:4326). Grundlagedaten im Schweizerischen Bezugssystem LV95 sind mit einer geografischen Transformation umprojiziert worden. Die Datenverarbeitung in ArcGIS Pro wurde mit der Softwareversion 3.0.3 durchgeführt.

3.2.1 Trainingsdaten

Der erste Teil der Trainingsdaten basiert auf den Daten aus der Baumartenkartierung (Kap. 3.1.3). Dazu wurde mittels den Sentinel Level-2A-Daten in ArcGIS Pro ein Vektordatensatz generiert. Die Polygonflächen entsprechen dabei der Rasterauflösung der Sentinelbilder. In den Trainingsgebieten wurde innerhalb dieser Rasterflächen geschaut, welche Baumarten vorkommen. Aufgrund der tiefen Auflösung von 10 m können mehrere Bäume in einem Pixel vorhanden sein. Auch der Durchmischungsgrad kann für die Bestimmung einer Baumart in einem Pixel problematisch sein (Fassnacht et al., 2016). Mit der Festlegung eines bestimmten Anteils der Zielbaumart an der Gesamtfläche, kann das Problem umgangen werden (Adelabu et al., 2013). Es wurden deshalb Rasterflächen als Trainingsdaten ausgewählt, welche von der Zielbaumart ungefähr mehr als Zweidrittel abgedeckt sind. Dies kann durch eine einzelne grosse oder mehrere kleinere Baumkronen sichergestellt sein (Abb. 7).



(a) abgedeckt durch einen Baum

(b) abgedeckt durch mehrere Bäume

(c) in Konkurrenz mit anderen Baumarten

Abb. 7: Auswahl Trainingsdaten für die pixelbasierte Baumartenklassifikation am Beispiel der Weisstanne (in blau)


Stichproben aus Felderhebungen können zusätzlich mit Stichproben aus der Fotointerpretation von Luftbildern kombiniert werden (Immitzer et al., 2012). Der Trainingsdatensatz konnte dadurch mehr als verdoppelt werden (Tab. 8). Es wurde mit der gleichen Abdeckung der Zielbaumart innerhalb einer Rasterfläche ausgegangen. Die Fotointerpretation erfolgte auf Grundlage der swissimage RS Bildstreifen anhand verschiedenen Bandkombinationen (*Natural Color*, *Color Infrared*). Es wurde mit einer pessimistischen Angehensweise vorgegangen, um Fehlinterpretationen zu vermeiden. Die Trainingsdaten sind angrenzend an den Trainingsgebieten digitalisiert worden.

Tab. 8: Trainingsdaten für pixelbasierte Baumartenklassifikation


Deutscher Name / Gruppe	Wissenschaftlicher Name	Felderhebung	Fotointerpretation	Trainingsdaten gesamt
Arve	<i>Pinus cembra</i>	114	139	253
Fichte	<i>Picea abies</i>	114	139	253
Flaumeiche	<i>Quercus pubescens</i>	114	139	253
Lärche	<i>Larix decidua</i>	114	139	253
übriges Laubholz	-	114	139	253
Waldföhre	<i>Pinus sylvestris</i>	114	139	253
Weisstanne	<i>Abies alba</i>	114	139	253
		798	973	1'771

Arven und Lärchen wurden neben dem Trainingsgebiet T7 erfasst. Die Unterscheidung ist mit der natürlichen Farbkombination RGB möglich. Die eher dunkleren Arven weisen oft helle Äste in den Kronen auf (Abb. 8; a). Weisstannen und Fichten sind neben dem Trainingsgebiet T6 digitalisiert worden. Die Digitalisierung erfolgte anhand der Bandkombination aus Nahinfrarot, Grün und Blau. Die Fichte besitzt oft eine dunkle sternförmige Baumkrone. Die Baumkrone der Lärche hat eine ähnliche Farbe, ist jedoch buschiger. Die Weisstanne weist hingegen rote und graue Farben auf (Abb. 8; b). Waldföhren und Flaumeichen sind um das Trainingsgebiet T3 aufgenommen worden. Aufgrund Erkenntnisse aus Gegenhanganalysen wurde darauf geachtet, dass die Stichproben auf derselben Höhenstufe erfasst werden, wie die Trainingsdaten aus der Felderhebung. Die Unterscheidung erfolgte ebenfalls auf Grundlage der Bandkombination aus Nahinfrarot, Grün und Blau. Die Baumgruppen aus Waldföhren und Flaumeichen lassen sich farblich unterscheiden (Abb. 8; c). Das übrige Laubholz wurde in der Nähe vom Trainingsgebiet T4 mit der gleichen Bandkombination digitalisiert. Auf Basis von Beobachtungen sind Bestände angrenzend an landwirtschaftlichen Flächen aufgenommen worden (Abb. 8; d).


Die Stichproben [253 pro Baumart] sind gleich wie bei der objektbasierten Bildanalyse in 10% Blinddaten [25] und die restlichen 90% in 70% Trainings- [160] und 30% Referenzdaten [68] aufgeteilt worden. Wie in der Studie von Wessel et al. (2018) könnten als Trainingsdaten auch forstliche Inventuraufnahmen verwendet werden, wobei Informationen über die Baumartenzusammensetzung in einer spezifischen Kreisfläche vorliegen. Für das Studiengebiet stehen nur Daten vom Schweizerischen Landesforstinventar LFI zur Verfügung. Das Stichprobennetz liegt in einem Abstand von 1.4 km vor, und ist deshalb für die vorliegende Analyse ungeeignet.




(a) Bestand mit Arve (rot) und Lärche (gelb)



(b) Bestand mit Fichte (grün), Weisstanne (blau) und Lärche (gelb)



(c) Bestand mit Flaumeiche (violett) und Waldföhre (braun)



(d) Bestand mit gemischten Laubholzarten (türkis)

Abb. 8: Beispiele aus der Fotointerpretation der Trainingsdaten für die pixelbasierte Baumartenklassifikation

3.2.2 Bildklassifizierung

Die pixelbasierte Bildklassifizierung konnte aufgrund der geringeren Datenmenge für alle vier Testgebiete zusammenhängend durchgeführt werden. Die verwendeten Grundlagedaten wurden vorgängig auf den Perimeter der Testgebiete zugeschnitten. Es fand keine weitere Datenvorverarbeitung statt. Die Klassifikation der Baumarten ist in ArcGIS Pro mit dem *Classification Wizard*-Steuerelement durchgeführt worden. Durch ein Variantenstudium konnten die Variablen und der Klassifikator bestimmt werden. Aufgrund der Ergebnisse der Analyse ist für die Klassifizierung der *Random Forest* Algorithmus verwendet worden. Folgende Einstellungen wurden dabei berücksichtigt: max. Anzahl von Strukturen [1'000]; max. Strukturtiefe [100]; Segmentattribute [konvergierender Farbwert], [durchschnittlicher Digitalnummernwert], [Standardabweichung]. Das *Classification Schema* ist im *Trainings Samples Manager* erstellt worden. Am Ende der Klassifikation wurde keine Reklassifizierung durchgeführt. Analog zur objektbasierten Klassifikation sind weitere Variablen in den Rasterdatensatz integriert worden. Folgend ist die Zusammenstellung der Bänder aufgeführt (Tab. 9).

Tab. 9: Verwendete Variablen (Raster Komposit) in der pixelbasierten Baumartenklassifikation

Band	Variable	Beschreibung	Grundlage
1	VHM	Vegetationshöhenmodell	Vegetationshöhenmodell LFI
2	NH	Nadelholzanteil	Toolkit Bestandeskarten TBk
3 - 12	Spektral- bänder	Blue [B2]; Green [B3]; Red [B4]; Vegetation Red Edge [B5, B6, B7]; NIR [B8]; Vegetation Red Edge [B8A]; SWIR [B11, B12]	Sentinel-2A 2020-05-29
13	NDVI	Normalized Difference Vegetation Index: [NIR-Rot]/[NIR+Rot]	Sentinel-2A 2020-05-29
14 - 16	HSV	Farbmodellkonvertierung RGB zu HSV: Hue, Saturation, Value	Sentinel-2A 2020-05-29
17 - 26	Spektral- bänder	Blue [B2]; Green [B3]; Red [B4]; Vegetation Red Edge [B5, B6, B7]; NIR [B8]; Vegetation Red Edge [B8A]; SWIR [B11, B12]	Sentinel-2A 2020-06-23
27	NDVI	Normalized Difference Vegetation Index: [NIR-Rot]/[NIR+Rot]	Sentinel-2A 2020-06-23
28 - 30	HSV	Farbmodellkonvertierung RGB zu HSV: Hue, Saturation, Value	Sentinel-2A 2020-06-23
31 - 40	Spektral- bänder	Blue [B2]; Green [B3]; Red [B4]; Vegetation Red Edge [B5, B6, B7]; NIR [B8]; Vegetation Red Edge [B8A]; SWIR [B11, B12]	Sentinel-2A 2020-08-07
41	NDVI	Normalized Difference Vegetation Index: [NIR-Rot]/[NIR+Rot]	Sentinel-2A 2020-08-07
42 - 44	HSV	Farbmodellkonvertierung RGB zu HSV: Hue, Saturation, Value	Sentinel-2A 2020-08-07

Durch die Verwendung von mehreren Bildszenen, können verschiedene Phasen der Vegetationsperiode abgedeckt und damit die Ergebnisse der Klassifikation verbessert werden (Immitzer et al., 2019; Ma et al., 2021; Wessel et al., 2018). Dabei sind Bildszenen von April bis August am besten geeignet (Immitzer et al., 2019). Für die vorliegende Analyse sind deshalb drei verschiedene Bildszenen zwischen Mai und August in die Klassifikation integriert worden. In Immitzer et al. (2016) und Wessel et

al. (2018) wurde über die spektrale Signatur von verschiedenen Baumarten aufgezeigt, dass ab einem Wellenlängen-Bereichs von 750 nm Baumarten unterschieden werden können. Insbesondere die Red Edge-, NIR- und SWIR-Bänder von Sentinel-2 sind dafür gut geeignet (Fassnacht et al., 2016; Ma et al., 2021). Die Sentinel-Bänder in einer Auflösung von 60 m (B1, B9 und B10) sind für die Detektierung von Baumarten nicht interessant (Immitzer et al., 2019). Aus diesen Gründen wurden die vorliegenden Sentinel-Bänder für die Analyse ausgewählt (Tab. 10).

Tab. 10: Sentinel-2A Spektralbänder für die pixelbasierte Baumartenklassifikation (European Space Agency, 2015)

Spektralbänder	Mittlere Wellenlänge	Räumliche Auflösung
B2: Blue	490 nm	10 m
B3: Green	560 nm	10 m
B4: Red	665 nm	10 m
B5: Vegetation Red Edge	705 nm	20 m
B6: Vegetation Red Edge	740 nm	20 m
B7: Vegetation Red Edge	783 nm	20 m
B8: NIR	842 nm	10 m
B8A: Vegetation Red Edge	865 nm	20 m
B11: SWIR	1'610 nm	20 m
B12: SWIR	2'190 nm	20 m

Im Variantenstudium sind weitere Kombinationen getestet worden. Einerseits wurde der *Support Vector Machine* Algorithmus oder nur die aus der Felderhebung generierten Trainingsdaten eingesetzt. Andererseits sind weitere Variablen wie Bildszenen von 2020-07-08 oder der Waldmischungsgrad-Layer der Eidg. Forschungsanstalt für Wald, Schnee und Landschaft (WSL) (Waser et al., 2017) geprüft worden. Die Ergebnisse konnten dadurch jedoch nicht verbessert werden.

3.2.3 Genauigkeitsanalyse

Analog zur objektbasierten Klassifikation wurde die Genauigkeit vom Modell über das *Classification Wizard*-Steuerelement in Form einer Konfusionsmatrix ausgegeben. Die Analyse basierte ebenfalls auf einem Referenzpunktschema mit einer abgeglichenen stratifizierten Zufallsstichprobe mit 500 zufälligen Punkten. Die Genauigkeit der Klassifikation konnte zusätzlich manuell über die Blinddaten ermittelt werden. Die Pixel der Referenzdaten stimmen mit der Bildklassifizierung überein. Deshalb konnte die Genauigkeit über die Anzahl richtig vorhergesagten Pixel einer Klasse im Vergleich zur Anzahl der dazugehörigen Referenzdaten berechnet werden.

3.3 Vergleich und Validation der Ergebnisse (O3)

Die Ergebnisse beider Bildanalysen werden hinsichtlich der Baumartenverteilung und den Genauigkeiten gegenübergestellt. Der Vergleich der Gesamtgenauigkeit aus der Konfusionsmatrix soll als Validation dienen.

3.4 Handlungsempfehlung (O4)

Damit herausgefunden werden kann ob ein Wald in Zukunft umgebaut werden muss, sind Informationen über den Ausgangszustand und die künftige Gegebenheiten von entscheidender Bedeutung. Die Methodik zur Herleitung der Handlungsempfehlung kann wie folgt zusammengefasst werden (Abb. 9).

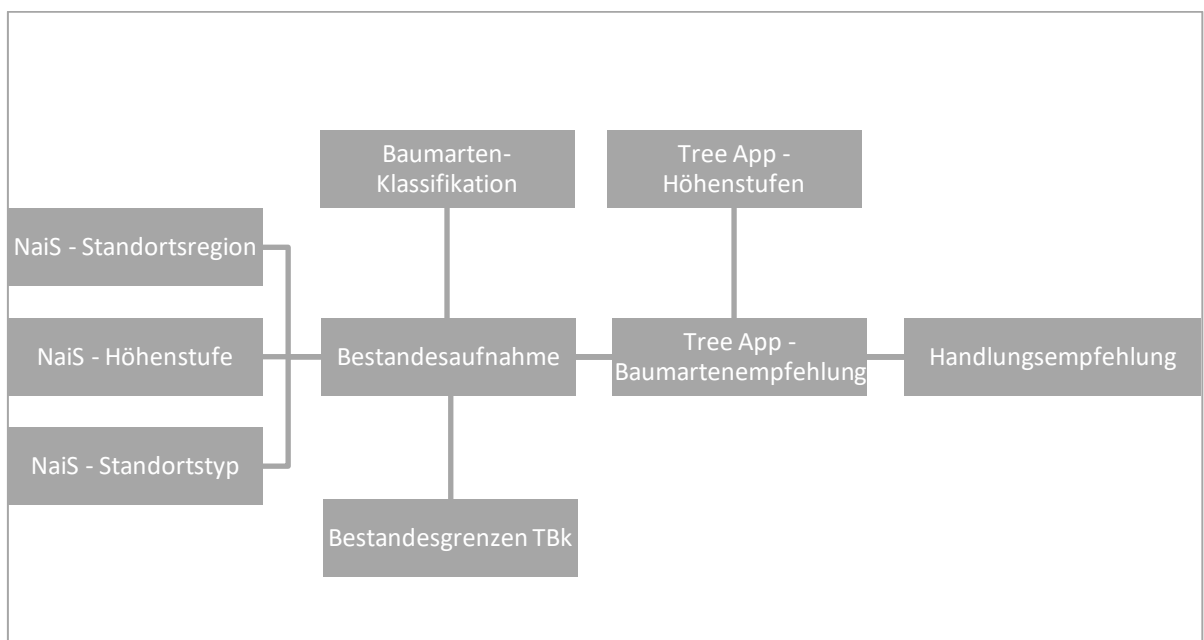
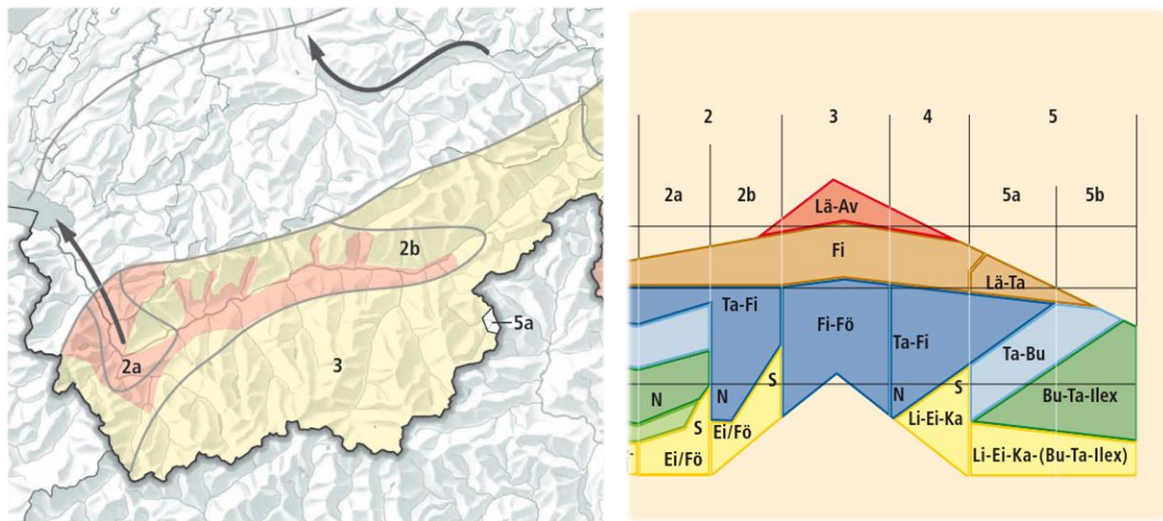


Abb. 9: Methodik zur Herleitung der Handlungsempfehlung

Mit den besser geeigneten Ergebnissen der Bildanalysen (hinsichtlich der Gesamtgenauigkeit aus der Konfusionsmatrix) können zusammen mit der Wegleitung «NaiS - Nachhaltigkeit und Erfolgskontrolle im Schutzwald» (Frehner et al., 2005) die im jetzigen Zeitpunkt vorliegenden Wald-Standortstypen hergeleitet werden. Das Vorgehen ist angelehnt an das Verfahren in der Wegleitung NaiS (siehe dazu Anhang 2A: Kap. 3 und 4 der Wegleitung). Dabei werden zuerst anhand der geografischen Lage der zu untersuchenden Wälder die dazugehörigen Standortsregionen bestimmt (Abb. 10; a). Zusammen mit den Höheninformationen können anschliessend die vorkommenden Höhenstufen und darin möglichen Hauptbaumarten bestimmt werden (Abb. 10; b)



(a) Standortregionen vom Kanton Wallis; Nördliche Zwischenalpen mit Buche (2a) und ohne Buche (2b); Kontinentale Hochalpen (3); Südliche Randalpen mit Fichte (5a)

(b) Mögliche Höhenstufen der jeweiligen Standortregionen mit Hauptbaumarten; obersubalpin (rot); subalpin (braun); hochmontan (dunkelblau); obermontan (hellblau); untermontan (dunkelgrün);

Abb. 10: Auszug von der Wegleitung NaiS (Frehner et al., 2005); (a) Standortregionen und (b) Höhenstufen

In der überarbeiteten kantonalen Wegleitung (Sàrl, 2011) sind für die jeweiligen Hauptbaumarten die wichtigsten Wald-Standortstypen des Kantons ersichtlich. Die Baumarten der Klassifizierung können diesen Standortstypen zugeordnet und in generelle Standortstyp-Gruppen zusammengefasst werden (bspw. Fichtenwälder). Die Bestände sind gutachterlich anhand der vorkommenden Höhenstufen und der Baumartenmischung analysiert worden. Als Bestandesgrenze dienten die Daten der Bestandeskarte TBk. Der daraus resultierende Datensatz wurde mit den Höhenstufen «Klima heute», «mässiger Klimawandel» und «starker Klimawandel» überschritten. Dies macht es möglich für jeden einzelnen Bestand für verschiedene Szenarien (Kombinationen verschiedener Höhenstufen in den Klimamodellen) die künftige Entwicklung aufzuzeigen. Die Entwicklung bzw. die Verschiebung der Höhenstufen in den drei Klimamodellen sieht für das Studiengebiet wie folgt aus (Abb. 11):

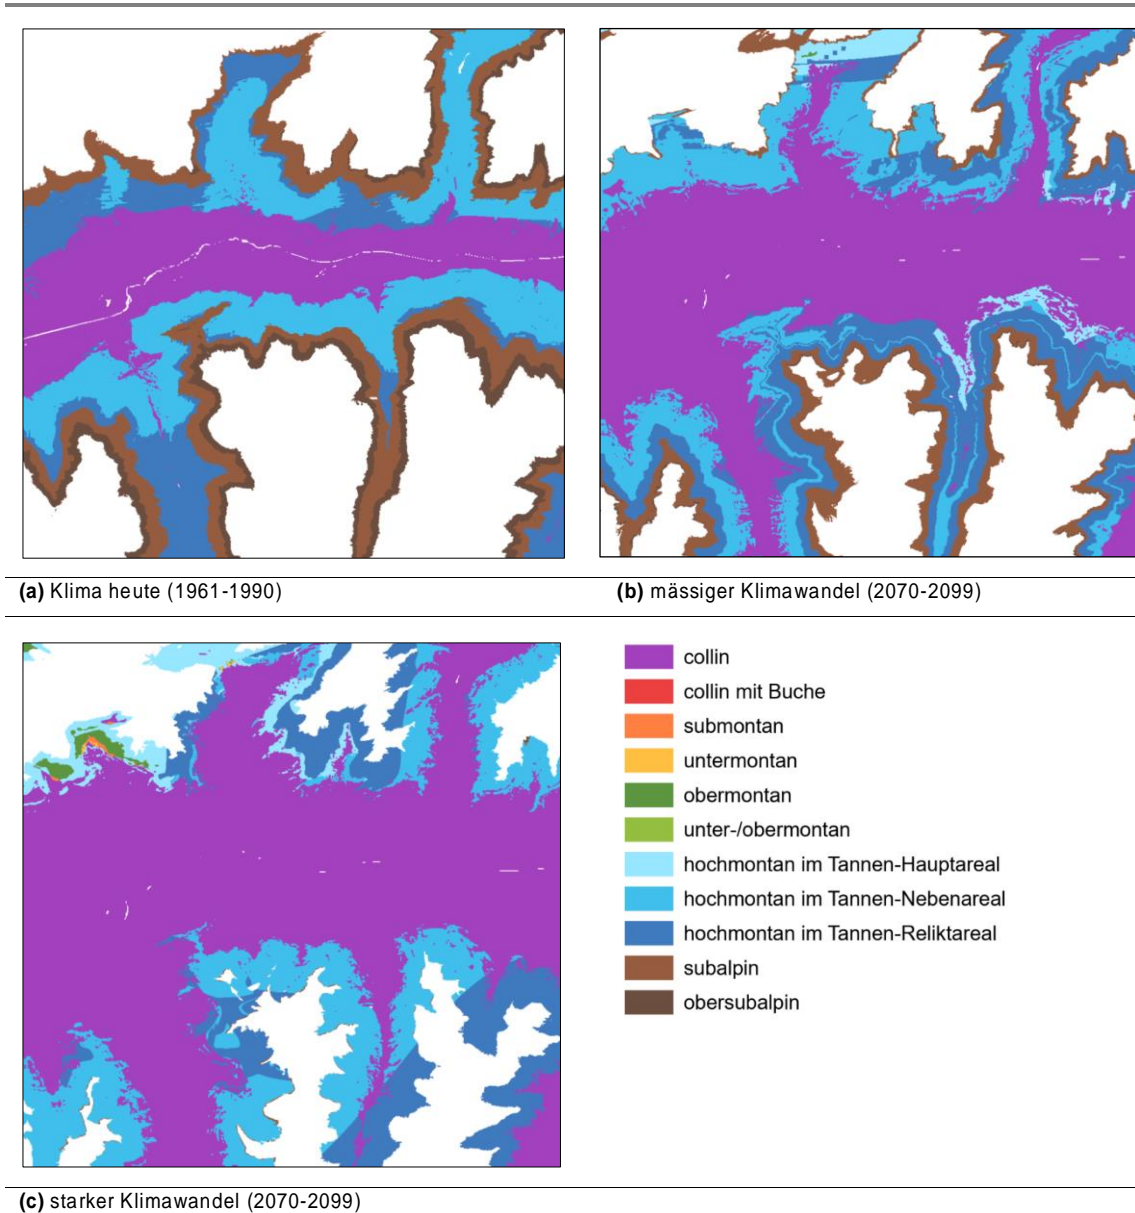


Abb. 11: Entwicklung bzw. Verschiebung der Vegetationshöhenstufen gemäss Klimamodelle Tree App (map.geo.admin.ch)

In der Tree App wurde manuell mithilfe der Standortsregionen, den Höhenlagen (Verschiebung der Höhenstufen) und der Wald-Standortstypen die Empfehlung der Baumartenmischung abgeleitet. Für die Analyse ist in der Tree App die Aussage über die dominante Naturwaldbaumart entscheidend, ob eine Hauptbaumart künftig auf einem Standort überleben kann oder nicht. Auf Standorten, bei denen keine Information über die dominante Naturwaldbaumart verfügbar ist, wurden die wichtigen beigemischten Naturwaldbaumarten berücksichtigt. Pro Szenario (Kombinationen verschiedener Höhenstufen in den Klimamodellen) resultierten so mehrere Empfehlungen über zukunftsfähige Baumarten. Deshalb sind alle möglichen Baumarten für die Analyse pro Szenario zusammengefasst verwendet worden. Mit dieser Information wurde die Empfehlung für einen mässigen und starken Klimawandel hergeleitet.

4 Ergebnisse

4.1 Objektbasierte Bildanalyse (O1)

4.1.1 Räumliche Verteilung der Baumarten

Die räumliche Verteilung der Baumarten ist im Anhang B detailliert ersichtlich. In der Abbildung 12 ist ein Überblick der Ergebnisse im Testgebiet 1 aufgeführt. Die Klassifizierung macht gesamthaft eine Fläche von 138 ha aus. Die Lärche (78 ha; 56 %) ist die dominierende Baumart. Sie kommt verteilt auf allen Höhenstufen und Expositionen vor. Die Flaumeiche (24 ha; 18 %) wird mehrheitlich an den ostexponierten Hängen oberhalb Leukerbad vorhergesagt. Das übrige Laubholz (13 ha; 9 %) kommt ebenfalls am meisten westlich von Leukerbad vor. Die Klasse wird ausserdem an den Bestandesrändern vorhergesagt. Die Arven (10 ha; 8 %) sind in den Lärchen-Beständen beigemischt. Die Weisstannen (7 ha; 5 %) und Fichten (4 ha; 3 %) kommen in Gruppen im Perimeter vor. Die Waldföhre (2 ha; 1 %) weist einen geringen Flächenanteil auf. In westexponierten Hängen wurden weniger Bäume segmentiert und klassifiziert als im übrigen Testgebiet.

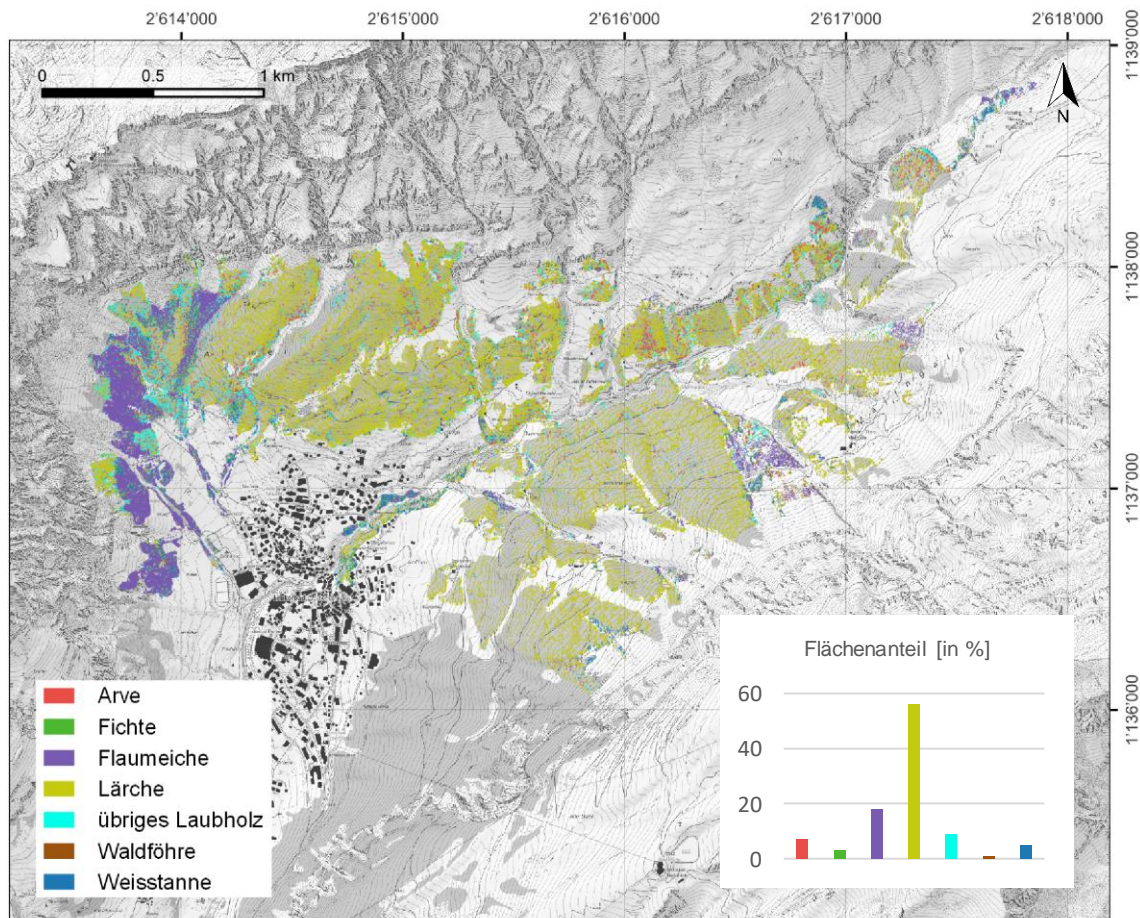


Abb. 12: Testgebiet 1 - Räumliche Verteilung der Baumarten der objektbasierten Bildanalyse

In der Abbildung 13 ist ein Überblick der Ergebnisse vom Testgebiet 2 ersichtlich. Die Klassifizierung macht gesamthaft eine Fläche von 1'439 ha aus. Die dominierende Baumart ist die Waldföhre (510 ha; 35 %). Sie wird v.a. oberhalb den Dörfern Varen, Leuk und Gampel vorhergesagt. Ebenfalls weit verbreitet ist die Fichte (347 ha; 24 %). Sie kommt eher in höheren Lagen vor und ist mit der Waldföhre und Lärche gemischt. Das übrige Laubholz (195 ha; 14 %) wird mehrheitlich in Gerinnehängen oder an Bestandesrändern detektiert. Die grössten zusammenhängenden Bestände sind unterhalb Albinen. Die Lärche (176 ha; 12 %) kommt in den oberen Höhenstufen vor. Sie ist mehrheitlich mit der Fichte beigemischt. Auffällig ist die Grenze innerhalb der Klassifizierung im östlichen Bereich auf rund 2'000 m Höhe, wobei oberhalb v.a. Lärchen und unterhalb eher die Fichte oder Waldföhre vorhergesagt wird. Die Flaumeiche (139 ha; 10 %) wird v.a. an den Hängen oberhalb Jeizinen und im ehemaligen Waldbrand oberhalb Leuk detektiert. Die Weisstanne (39 ha; 3 %) und die Arve (33 ha; 2 %) machen nur einen kleinen Teil der Klassifikation aus. Im Bereich des Waldbrandes wurden vergleichsweise weniger Bäume segmentiert und klassifiziert.

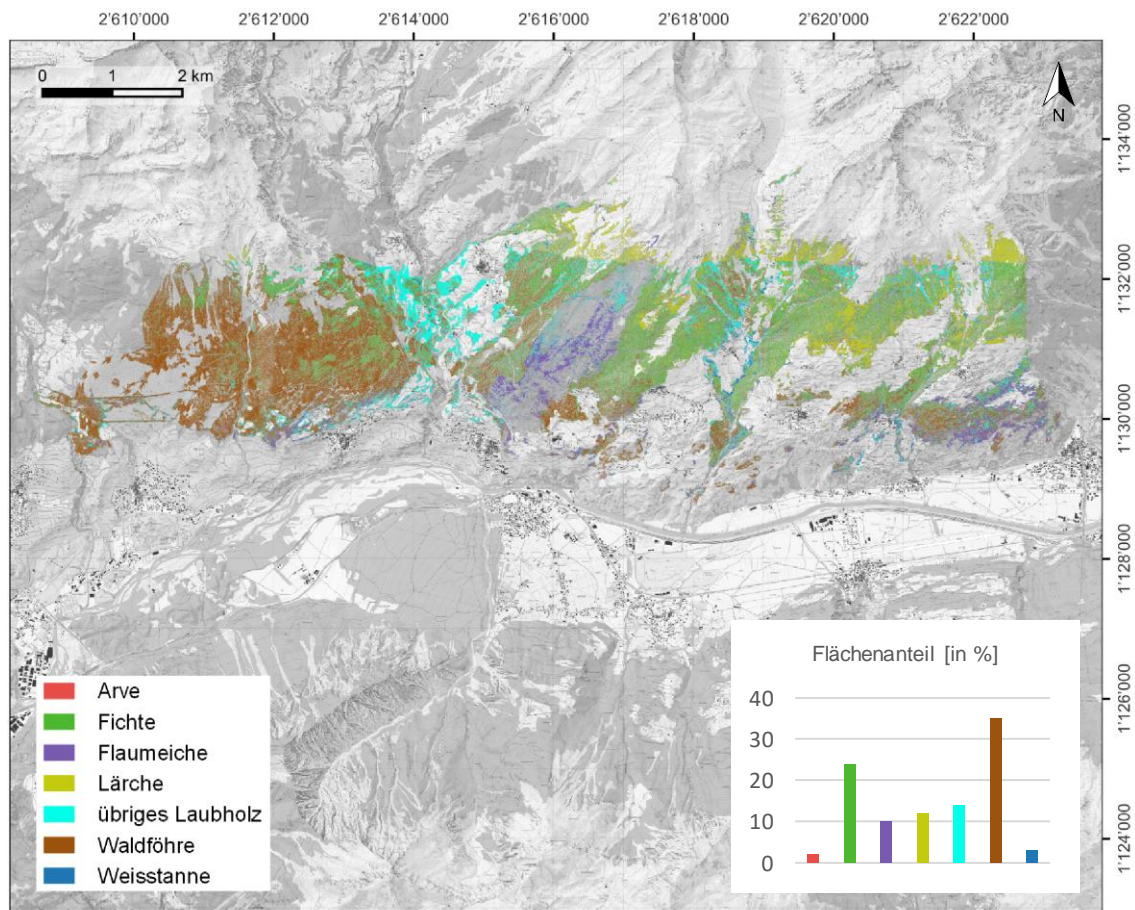


Abb. 13: Testgebiet 2 - Räumliche Verteilung der Baumarten der objektbasierten Bildanalyse

In der Abbildung 14 ist ein Überblick der Ergebnisse vom Testgebiet 3 ersichtlich. Auf einer gesamten Fläche von 1'102 ha ist die Fichte (333 ha; 30 %) die dominierende Baumart. Sie kommt verteilt im gesamten Testgebiet vor. Das übrige Laubholz (280 ha; 25%) wird mehrheitlich in tieferen Höhenlagen angrenzend an landwirtschaftlichen Flächen oder in Gerinneabhängungen vorhergesagt. Die Lärche (218 ha; 20 %) wird eher in den oberen Höhenstufen detektiert. Die Waldföhre (151 ha; 14 %) kommt mehrheitlich oberhalb Agarn und in der ehemaligen Waldbrandfläche Pfyberg vor. Die Weisstanne (81 ha; 7 %) wird im Perimeter verteilt vorhergesagt. Sie kommt dabei in Gruppen vor. Die Flaumeiche (23 ha; 2 %) und die Arve (16 ha; 2 %) weisen jeweils einen kleinen Flächenanteil an der Klassifikation auf. Die Flaumeiche wird überwiegend in höheren Lagen in Gerinnen festgestellt.

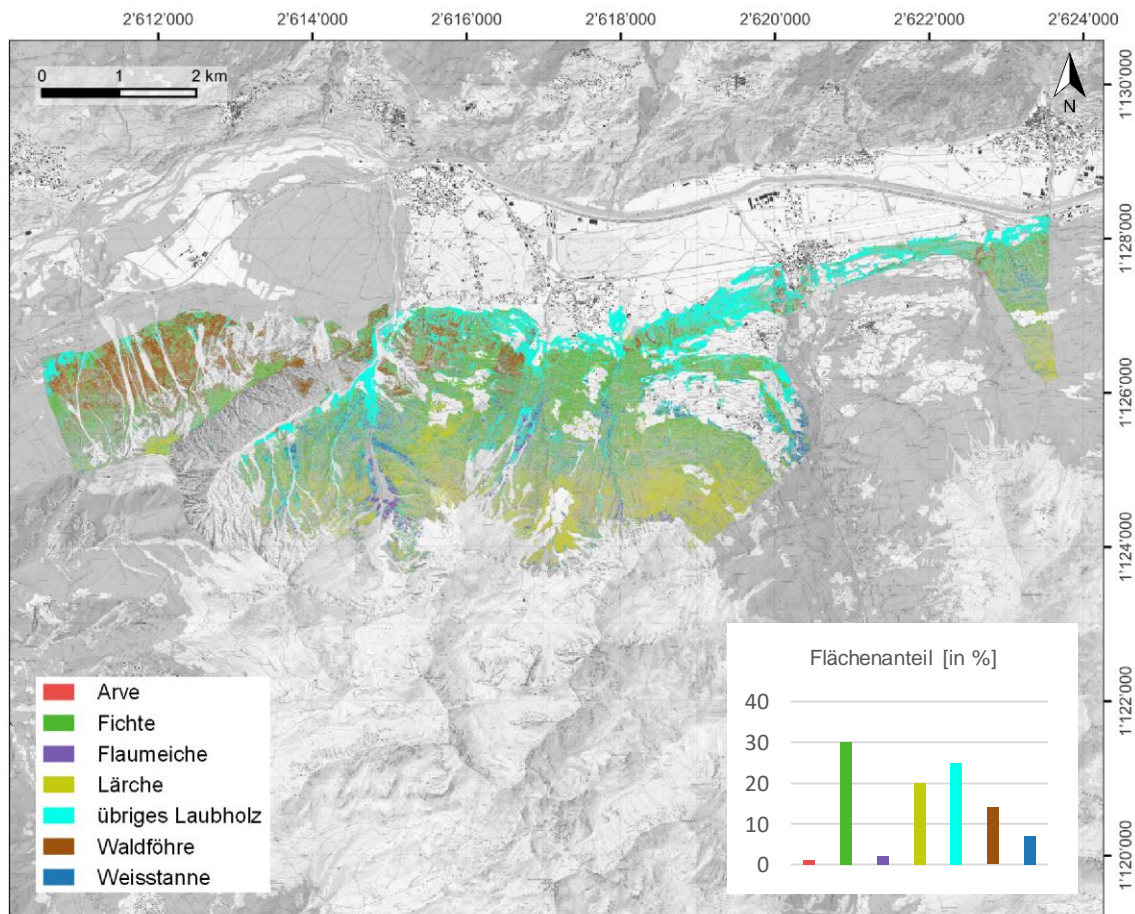


Abb. 14: Testgebiet 3 - Räumliche Verteilung der Baumarten der objektbasierten Bildanalyse

In der Abbildung 15 ist ein Überblick der Ergebnisse vom Testgebiet 4 ersichtlich. Die Klassifizierung macht gesamthaft eine Fläche von 169 ha aus. Die Lärche (103 ha; 61 %) ist deutlich die dominierende Baumart. Daneben sind die Arve (30 ha; 18%) und die Flaumeiche (19 ha; 11 %) die wichtigsten Baumarten. Die Lärche und die Arve kommen beide verteilt im Testgebiet vor. Die Flaumeiche ist mehrheitlich in Gerinnehängen oder an Bestandesrändern zu finden. Die Fichte (9 ha; 5 %) kommt mehrheitlich in Gerinnehängen oder an Bestandesrändern vor. Das übrige Laubholz (4 ha; 2 %), die Weisstanne (3 ha; 2 %) und die Waldföhre (1 ha; 1%) weisen den geringsten Flächenanteil der Klassifikation auf.

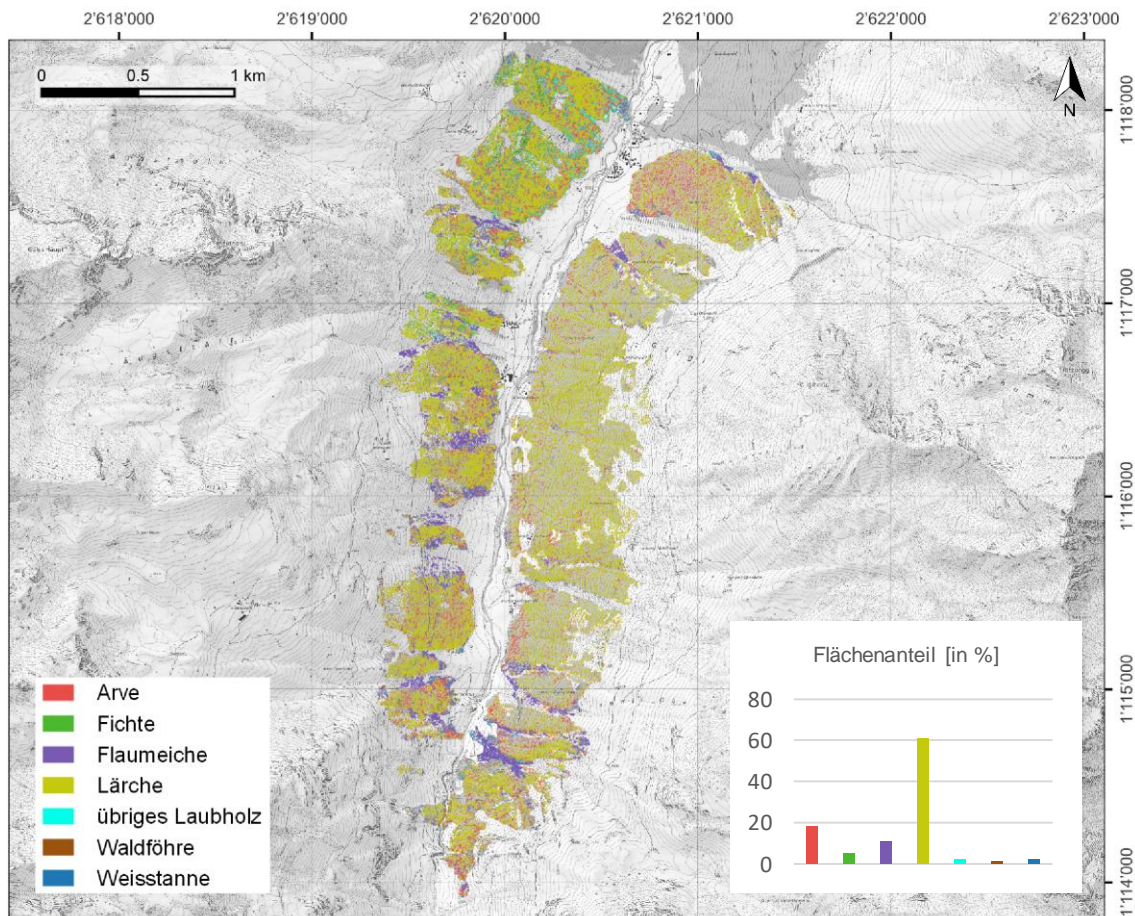


Abb. 15: Testgebiet 4 - Räumliche Verteilung der Baumarten der objektbasierten Bildanalyse

4.1.2 Genauigkeit der Klassifizierung

Die Konfusionsmatrix in Tabelle 11 zeigt die Leistung der Klassifikation im Testgebiet 1. Die Gesamtgenauigkeit beträgt 83 %. Die Kappa-Statistik hat ein Wert von 81 % ergeben. Es können Unterschiede zwischen den Baumarten festgestellt werden. Die Flaumeiche (PA 90 %; UA 89 %) weist die höchsten und die Lärche (PA 69 %; UA 72 %) die tiefsten Genauigkeiten auf. Die Lärche wird mit der Arve [7], Fichte [7] und Weisstanne [5] verwechselt. Es sind 19 Stichproben fälschlicherweise als Lärche vorhergesagt worden. Bei der Fichte und der Weisstanne sind es jeweils 14 Stichproben.

Die Auswertung der Blinddaten (*Ground Truth*) hat folgende Validierung ergeben: Arve [93 %], Fichte [73 %], Flaumeiche [93 %], Lärche [61 %], übriges Laubholz [84 %], Waldföhre [79 %] und Weisstanne [91 %]. Im Vergleich mit der Producer's Accuracy der Konfusionsmatrix hat die Validierung bei der Arve, der Flaumeiche, dem übrigen Laubholz und der Weisstanne eine höhere Leistung ergeben. Bei der Fichte, Lärche und Waldföhre wurde die Genauigkeit tiefer eingeschätzt.

Tab. 11: Testgebiet 1 - Konfusionsmatrix der objektbasierten Bildanalyse

		Referenzdaten							Total	UA
		Arve	Fichte	Flaumeiche	Lärche	übriges LH	Waldföhre	Weisstanne		
Klassifizierte Daten	Arve	62	1	0	7	1	0	1	72	0.86
	Fichte	0	61	0	7	1	4	2	75	0.81
	Flaumeiche	0	0	64	1	3	4	0	72	0.89
	Lärche	7	3	1	49	5	0	3	68	0.72
	übriges LH	0	0	5	0	55	1	3	64	0.86
	Waldföhre	0	2	0	2	4	62	1	71	0.87
	Weisstanne	2	4	1	5	2	0	61	75	0.81
Total	71	71	71	71	71	71	71	497		
PA	0.87	0.86	0.90	0.69	0.77	0.87	0.86		0.83	

PA: Producer's Accuracy | UA: User's Accuracy

Die Konfusionsmatrix in Tabelle 12 zeigt die Leistung der Klassifikation im Testgebiet 2. Die Gesamtgenauigkeit beträgt 83 %. Die Kappa-Statistik hat ein Wert von 80 % ergeben. Die Arve (PA 89 %; UA 93 %) und Flaumeiche (PA 89 %; UA 90 %) wurden am genauesten vorhergesagt. Die Lärche (PA 72 %; UA 77 %) weist die tiefsten Ergebnisse auf. Neben der Lärche ist die Fichte (PA 79 %; UA 73 %) weniger genau detektiert worden. Die Lärche wird mehrheitlich mit der Fichte [8] und die Fichte mit der Weisstanne [8] verwechselt. Auf 21 Stichproben ist die Fichte und auf 15 Stichproben die Lärche irrtümlich vorhergesagt worden.

Die Auswertung der Blinddaten (*Ground Truth*) hat folgende Validierung ergeben: Arve [94 %], Fichte [74 %], Flaumeiche [93 %], Lärche [64 %], übriges Laubholz [88 %], Waldföhre [80 %] und Weisstanne [92 %]. Die Validierung hat im Vergleich mit der Producer's Accuracy der Konfusionsmatrix für die Arve, Flaumeiche, das übrige Laubholz und die Weisstanne höhere Genauigkeiten ergeben. Bei der Fichte, Lärche und Waldföhre wurde eine tiefere Leistung geschätzt.

Tab. 12: Testgebiet 2 - Konfusionsmatrix der objektbasierten Bildanalyse

		Referenzdaten							Total	UA
		Arve	Fichte	Flaumeiche	Lärche	übriges LH	Waldföhre	Weisstanne		
Klassifizierte Daten	Arve	63	0	0	5	0	0	0	68	0.93
	Fichte	1	56	0	8	2	4	6	77	0.73
	Flaumeiche	0	0	63	0	2	5	0	70	0.90
	Lärche	5	5	0	51	4	0	1	66	0.77
	übriges LH	0	0	5	1	58	2	2	68	0.85
	Waldföhre	0	2	2	3	2	60	1	70	0.86
	Weisstanne	2	8	1	3	3	0	61	78	0.78
Total	71	71	71	71	71	71	71	71	497	
PA	0.89	0.79	0.89	0.72	0.82	0.85	0.86		0.83	

PA: Producer's Accuracy | UA: User's Accuracy

Die Konfusionsmatrix in Tabelle 13 zeigt die Leistung der Klassifikation im Testgebiet 3. Die Gesamtgenauigkeit beträgt 83 %. Die Kappa-Statistik hat ein Wert von 80 % ergeben. Die höchsten Genauigkeiten wurden für die Arve (PA 90 %; 89 UA %) und Flaumeiche (PA 87 %; 90 UA %) ermittelt. Die Lärche (PA 70 %; UA 72 %) weist die tiefsten Ergebnisse vor. Auffällig ist die Verwechslung der Lärche mit der Fichte [10]. Es sind 22 Stichproben fälschlicherweise als Fichte vorhergesagt worden. Bei der Lärche sind 19 Stichproben die irrtümlich als Lärche detektiert wurden.

Die Auswertung der Blinddaten (*Ground Truth*) hat folgende Validierung ergeben: Arve [94 %], Fichte [75 %], Flaumeiche [88 %], Lärche [64 %], übriges Laubholz [85 %], Waldföhre [87 %] und Weisstanne [93 %]. Im Vergleich mit der Producer's Accuracy der Konfusionsmatrix hat die Validierung bei der Arve, Flaumeiche, dem übrigen Laubholz, der Waldföhre und Weisstanne eine höhere Leistung ergeben. Bei der Fichte und Lärche wurde die Genauigkeit tiefer eingeschätzt.

Tab. 13: Testgebiet 3 - Konfusionsmatrix der objektbasierten Bildanalyse

		Referenzdaten							Total	UA
		Arve	Fichte	Flaumeiche	Lärche	übriges LH	Waldföhre	Weisstanne		
Klassifizierte Daten	Arve	64	0	0	6	2	0	0	72	0.89
	Fichte	1	57	0	10	2	5	4	79	0.72
	Flaumeiche	0	0	62	0	3	4	0	69	0.90
	Lärche	4	5	2	50	6	0	2	69	0.72
	übriges LH	0	0	5	0	54	1	2	62	0.87
	Waldföhre	0	3	2	2	2	61	0	70	0.87
	Weisstanne	2	6	0	3	2	0	63	76	0.83
Total	71	71	71	71	71	71	71	497		
PA	0.90	0.80	0.87	0.70	0.76	0.86	0.89		0.83	

PA: Producer's Accuracy | UA: User's Accuracy

Die Konfusionsmatrix in Tabelle 14 zeigt die Leistung der Klassifikation im Testgebiet 4. Die Gesamtgenauigkeit beträgt 84 %. Die Kappa-Statistik hat ein Wert von 81 % ergeben. Die Waldföhre (PA 94 %; UA 94 %) wurde am genauesten vorhergesagt. Die Lärche (PA 73 %; UA 69 %) weist die tiefsten Ergebnisse auf. Die Lärche wird mehrheitlich mit der Fichte verwechselt [9]. Es kommt ausserdem zu Verwechslungen der Flaumeiche mit dem übrigen Laubholz [8] und dem übrigen Laubholz mit der Lärche [8]. Auf 23 Stichproben ist die Lärche irrtümlich vorhergesagt worden. Bei der Weisstanne sind es 17 und bei der Fichte 15 Stichproben.

Die Auswertung der Blinddaten (*Ground Truth*) hat folgende Validierung ergeben: Arve [93 %], Fichte [85 %], Flaumeiche [86 %], Lärche [63 %], übriges Laubholz [90 %], Waldföhre [85 %] und Weisstanne [93 %]. Die Validierung hat im Vergleich mit der Producer's Accuracy der Konfusionsmatrix für die Arve, das übrige Laubholz und die Weisstanne höhere Genauigkeiten ergeben. Bei der Flaumeiche, Lärche und Waldföhre wurde eine tiefere Leistung geschätzt. Die Genauigkeit der Fichte ist bei beiden Analysen gleich.

Tab. 14: Testgebiet 4 - Konfusionsmatrix der objektbasierten Bildanalyse

		Referenzdaten							Total	UA
		Arve	Fichte	Flaumeiche	Lärche	übriges LH	Waldföhre	Weisstanne		
Klassifizierte Daten	Arve	60	0	0	5	1	0	0	66	0.91
	Fichte	0	60	0	9	2	0	4	75	0.80
	Flaumeiche	0	0	63	0	2	2	0	67	0.94
	Lärche	5	4	0	52	8	0	6	75	0.69
	übriges LH	0	0	8	0	55	2	3	68	0.81
	Waldföhre	0	1	0	2	1	67	0	71	0.94
	Weisstanne	6	6	0	3	2	0	58	75	0.77
Total	71	71	71	71	71	71	71	497		
PA	0.85	0.85	0.89	0.73	0.77	0.94	0.82		0.84	

PA: Producer's Accuracy | UA: User's Accuracy

4.2 Pixelbasierte Bildanalyse (O2)

4.2.1 Räumliche Verteilung der Baumarten

Die räumliche Verteilung der Baumarten ist im Anhang B detailliert ersichtlich. In der Abbildung 16 ist ein Überblick der Ergebnisse im Testgebiet 1 aufgeführt. Die Klassifizierung macht gesamthaft eine Fläche von 307 ha aus. Die dominierende Baumart ist die Weisstanne (104 ha; 34 %). Sie liegt verteilt im Perimeter vor. Das übrige Laubholz (51 ha; 17 %) kommt mehrheitlich an den ostexponierten Hängen oberhalb Leukerbad und an Bestandesrändern und in Gerinnehängen vor. Die größten Fichtenbestände (46 ha; 15 %) liegen nördlich von Leukerbad. Die Lärche (44 ha; 14 %) ist beigemischt und ist hauptsächlich an der westexponierten Talflanke zu finden. Die Arve (36 ha; 12 %) kommt ebenfalls vereinzelt in den Beständen vor. Die Waldföhren (19 ha; 6 %) und die Flaumeichen (7 ha; 2 %) liegen verteilt im Perimeter vor.

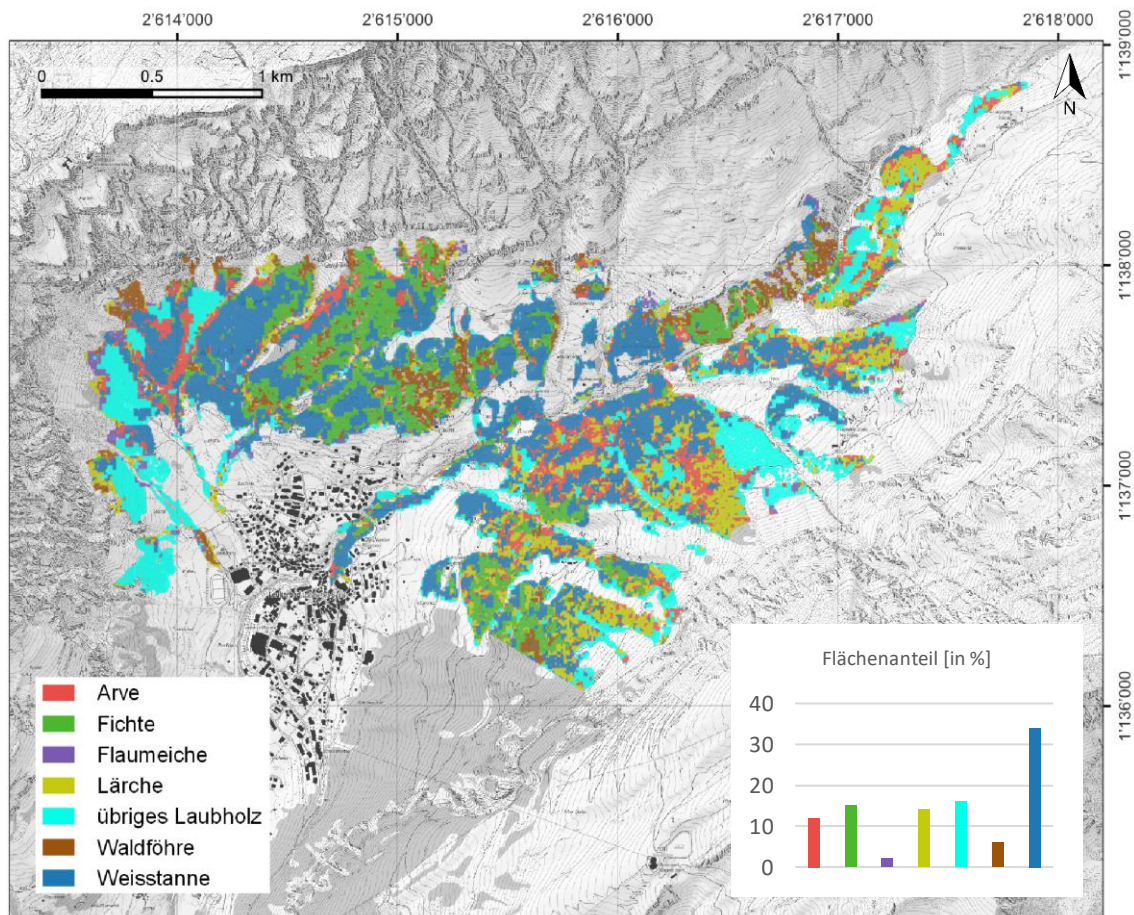


Abb. 16: Testgebiet 1 - Räumliche Verteilung der Baumarten der pixelbasierten Bildanalyse

In der Abbildung 17 ein Überblick der Ergebnisse vom Testgebiet 2 ersichtlich. Auf einer gesamten Fläche von 1'929 ha ist die Waldföhre (594 ha; 31 %) die dominierende Baumart. Sie wurde hauptsächlich oberhalb den Dörfer Varen, Leuk und Gampel detektiert. Daneben ist die Fichte (416 ha; 22 %) und die Weisstanne (400 ha; 21 %) die wichtigsten Baumarten. Die Fichte kommt neben der Waldföhrenbeständen vor. Die Weisstanne ist in Gruppen verteilt über den Perimeter vorhergesagt worden. Die Flaumeiche (228 ha; 12 %) wurde mehrheitlich in den trockenen Hängen oberhalb Jeizinen und Varen und im ehemaligen Waldbrand oberhalb Leuk detektiert. Die Lärche (125 ha; 6 %) kommt in den Beständen gemischt vor. Die Arve (84 ha; 4 %) wird mehrheitlich in den höheren Lagen vorhergesagt. Das übrige Laubholz (82 ha; 4 %) ist v.a. an Bestandesrändern und Gerinneabhängen aufzufinden.

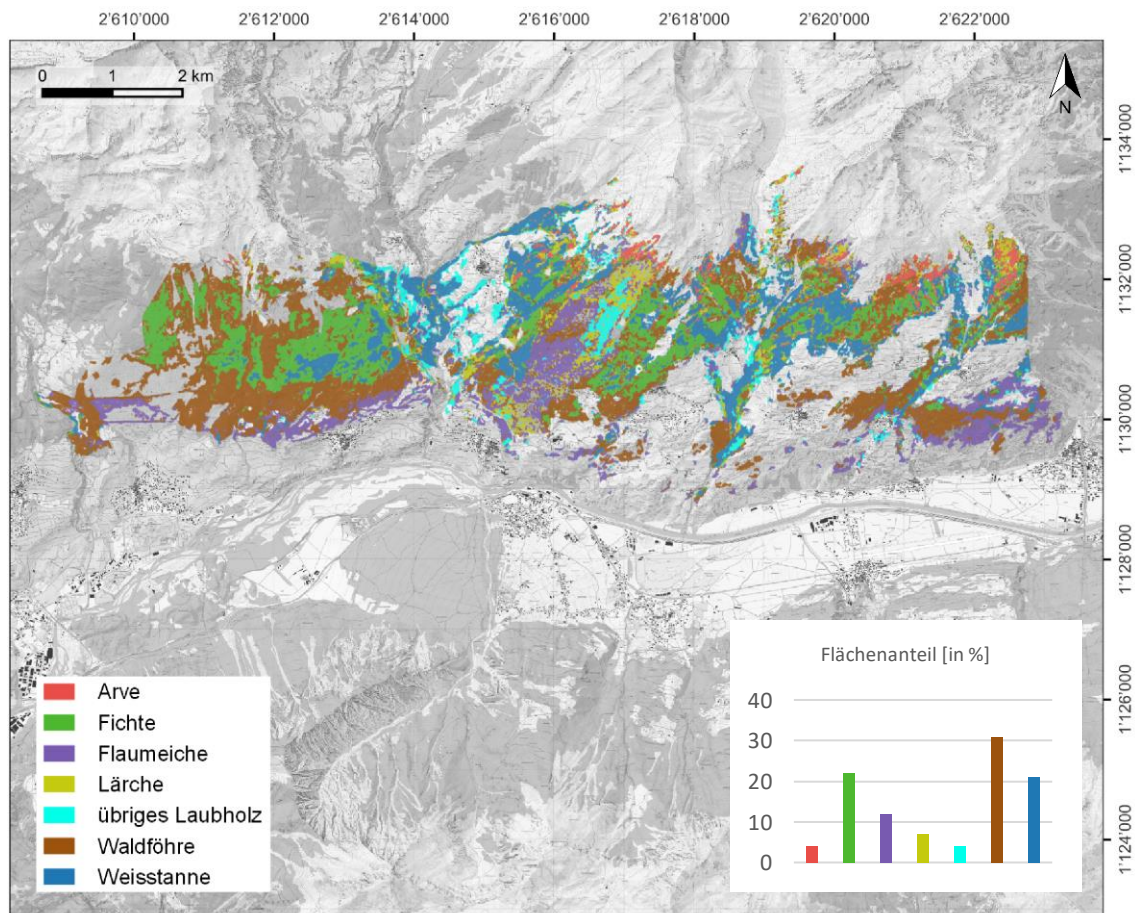


Abb. 17: Testgebiet 2 - Räumliche Verteilung der Baumarten der pixelbasierten Bildanalyse

In der Abbildung 18 ist ein Überblick der Ergebnisse vom Testgebiet 3 ersichtlich. Die Klassifizierung entspricht gesamthaft einer Fläche von 1'846 ha. Die dominierende Baumart ist die Weisstanne (528 ha; 29 %), gefolgt von der Lärche (403 ha; 22 %) und vom übrigen Laubholz (340 ha; 18 %). Die Weisstanne wurde v.a. im Illgraben, oberhalb Agarn und östlich von Ergisch detektiert. Die grössten zusammenhängenden Lärchenbestände liegen oberhalb Oberems und in der ehemaligen Waldbrandfläche Pfyberg. Das übrige Laubholz ist in den unteren Höhenlagen angrenzend an landwirtschaftlichen Flächen und in Gerinneabhängungen vorhergesagt worden. Die Fichte (229 ha; 12 %) kommt gruppiert im Testgebiet vor. Die Waldföhre (149 ha; 8 %) ist vereinzelt im Perimeter zu finden. Die meisten Flächen liegen bei der ehemaligen Waldbrandfläche Pfyberg. Die Arvenbestände (104 ha; 6 %) liegen in den oberen Höhenlagen. Die Flaumeiche (93 ha; 5 %) ist am geringsten vertreten und ist in den unteren Höhenlagen zu finden.

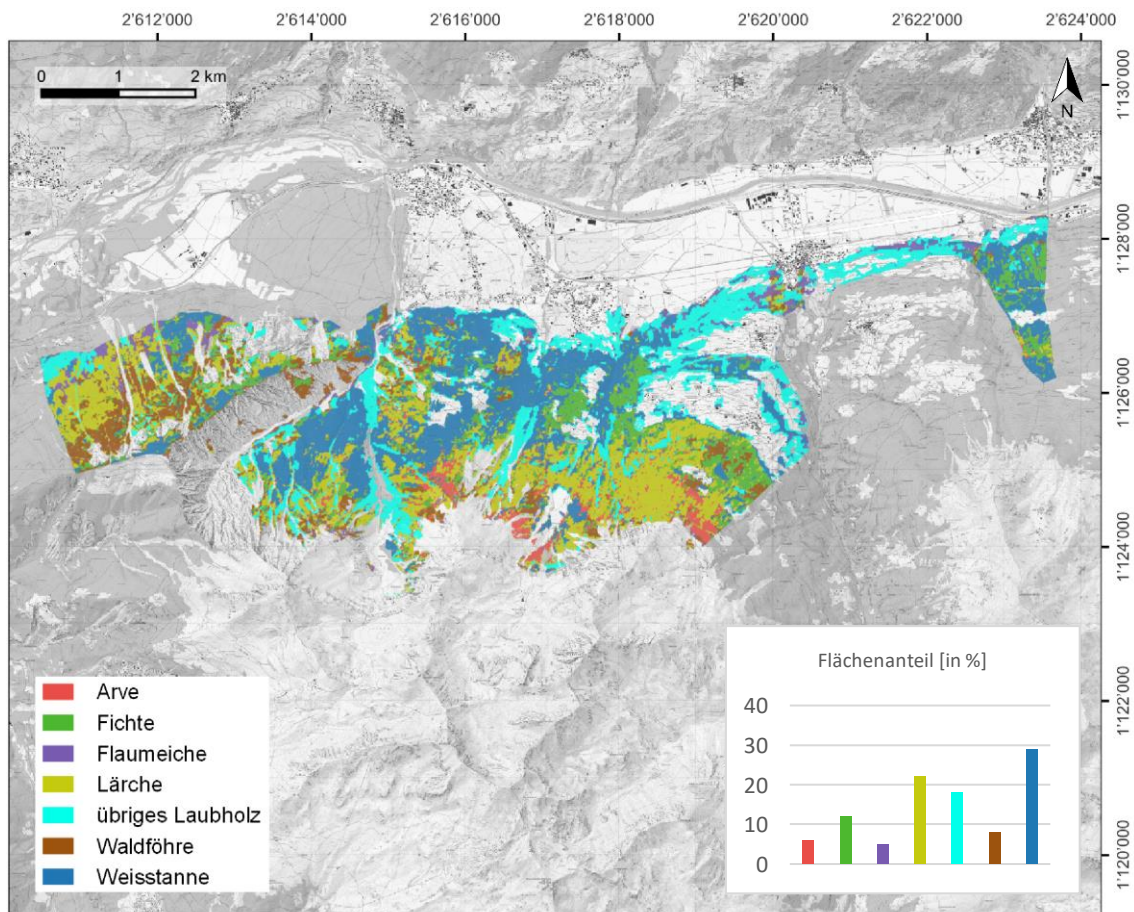


Abb. 18: Testgebiet 3 - Räumliche Verteilung der Baumarten der pixelbasierten Bildanalyse

In der Abbildung 19 ist ein Überblick der Ergebnisse vom Testgebiet 4 ersichtlich. Die Klassifizierung weist gesamthaft einer Fläche von 283 ha auf. Die dominierenden Baumarten sind die Arve (107 ha; 38 %) und die Lärche (96 ha; 34%). Sie liegen verteilt im Perimeter vor. Daneben wurde die Waldföhre (30 ha; 11 %) mehrheitlich an der ostexponierten Talflanke vorhergesagt. Das übrige Laubholz (16 ha; 6 %) ist in Gerinneabhängungen zu finden. Die Weisstanne (13 ha; 4%) und die Flaumeiche (10 ha; 3%) wurden vereinzelt im Testgebiet detektiert. Die Fichte (11 ha; 4%) kommt in Gruppen an der ostexponierten Talflanke vor.

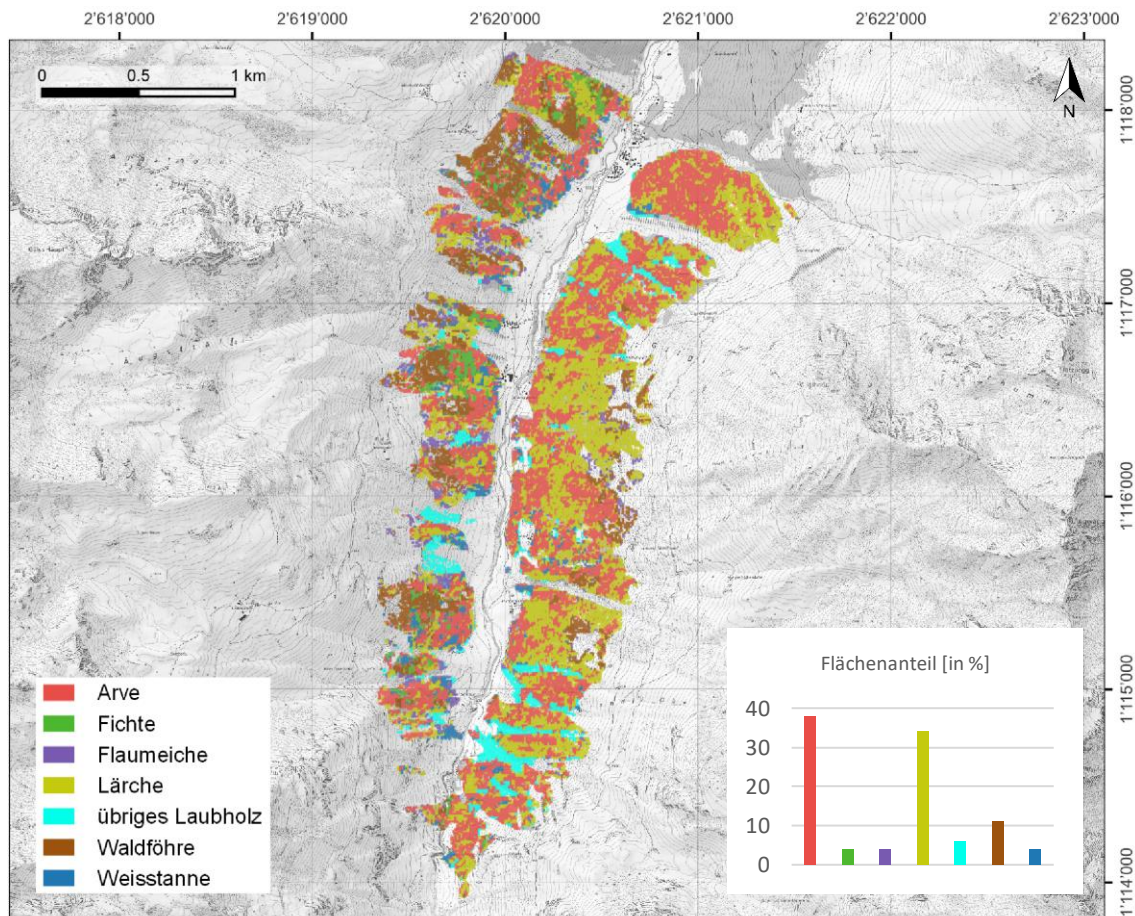


Abb. 19: Testgebiet 4 - Räumliche Verteilung der Baumarten der pixelbasierten Bildanalyse

4.2.2 Genauigkeit der Klassifizierung

Die Konfusionsmatrix in Tabelle 15 zeigt die Leistung der pixelbasierten Klassifikation in allen Testgebieten. Die Gesamtgenauigkeit beträgt 84 %. Die Kappa-Statistik hat ein Wert von 81 % ergeben. Die höchsten Genauigkeiten wurden für die Flaumeiche (PA 99 %; UA 95 %) und das übrige Laubholz (PA 99 %; UA 99 %) ermittelt. Die Fichte (PA 71 %; 74 UA %) und Lärche (PA 66 %; 78 UA %) weisen die tiefsten Genauigkeiten vor. Auffällig ist die Verwechslung der Lärche mit der Arve [17 bzw. 10] und die Fichte mit der Weisstanne [13 bzw. 12]. Es sind 19 Stichproben als Weisstanne, 18 Stichproben als Arve, 16 Stichproben als Fichte und 13 Stichproben als Lärche fälschlicherweise vorhergesagt worden.

Die Auswertung der Blinddaten (*Ground Truth*) hat folgende Validierung ergeben: Arve [72 %], Fichte [68 %], Flaumeiche [96 %], Lärche [68 %], übriges Laubholz [92 %], Waldföhre [96 %] und Weisstanne [80 %]. Im Vergleich mit der Producer's Accuracy der Konfusionsmatrix hat die Validierung bei der Lärche, der Waldföhre und Weisstanne eine höhere Leistung ergeben. Bei der Arve, Fichte, Flaumeiche und dem übrigen Laubholz wurde die Genauigkeit tiefer eingeschätzt.

Tab. 15: Konfusionsmatrix der pixelbasierten Bildanalyse

		Referenzdaten							Total	UA
		Arve	Fichte	Flaumeiche	Lärche	übriges LH	Waldföhre	Weisstanne		
Klassifizierte Daten	Arve	60	0	0	17	0	0	1	78	0.77
	Fichte	1	46	0	2	0	1	12	62	0.74
	Flaumeiche	0	1	69	0	0	2	1	73	0.95
	Lärche	10	1	0	46	0	2	0	59	0.78
	übriges LH	0	0	0	0	70	0	1	71	0.99
	Waldföhre	0	4	1	1	1	61	0	68	0.90
	Weisstanne	0	13	0	4	0	2	56	75	0.75
Total		71	65	70	70	71	68	71	486	
PA		0.85	0.71	0.99	0.66	0.99	0.90	0.79		0.84

PA: Producer's Accuracy | UA: User's Accuracy

4.3 Vergleich und Validation der Ergebnisse (O3)

4.3.1 Verteilung der Baumarten

In der folgenden Abbildung ist die Gegenüberstellung der prozentualen Baumartenverteilung der objektbasierten und pixelbasierten Bildanalyse ersichtlich (Abb. 20). Es sind Unterschiede zwischen den Baumarten erkennbar. Bei der Weisstanne liegt die grösste Diskrepanz vor. Mit der pixelbasierten Bildanalyse wurden um 19 Prozentpunkte mehr Weisstannen detektiert als mit der objektbasierten Bildanalyse. In der objektbasierten Bildanalyse wurden dagegen mehr Fichten vorausgesagt (+9 Prozentpunkte). Der Anteil der Flaumeiche liegt bei beiden Bildanalysen in etwa gleich (± 1 Prozentpunkt). Bei den übrigen Klassen liegt der Unterschied bei 5 bis 6 Prozentpunkten.

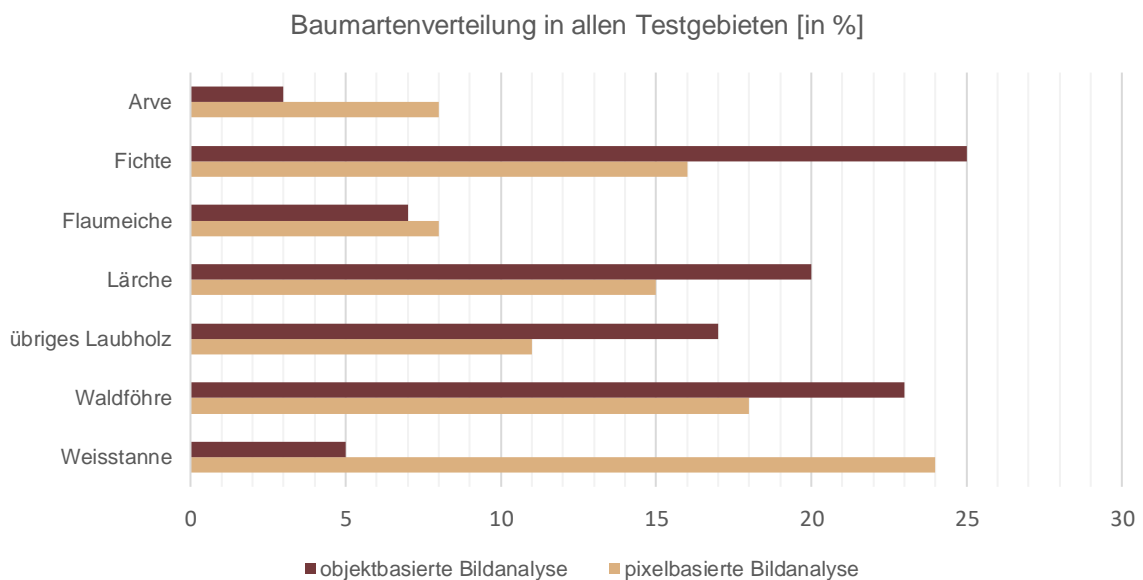


Abb. 20: Gegenüberstellung der Baumartenverteilung der objekt- und pixelbasierten Bildanalyse

4.3.2 Genauigkeit der Klassifizierungen

Die objektbasierte Bildanalyse weist in eine Gesamtgenauigkeit (Konfusionsmatrix) von 83 % auf. Mit der pixelbasierten Bildanalyse konnte dagegen eine Gesamtgenauigkeit (Konfusionsmatrix) von 84 % erreicht werden. In der Tabelle 16 sind die Mittelwerte der *Producer's* und *User's Accuracy* von den Baumarten aufgeführt. Im Vergleich wurde mit der objektbasierten Bildanalyse bei der Arve, der Fichte und der Weisstanne höhere Genauigkeiten erzielt. Mit der pixelbasierten Bildanalyse weisen die Flaumeiche, das übrige Laubholz und die Waldföhre höhere Genauigkeiten auf. Die Genauigkeit der Vorhersage der Lärche ist mit 72 % in beiden Bildanalysen gleich hoch.

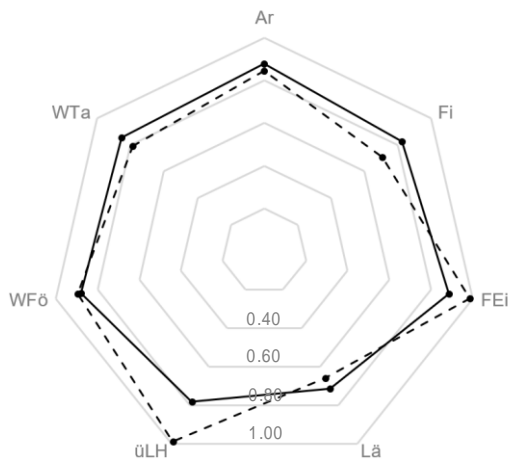
Tab. 16: Gegenüberstellung der Genauigkeiten der objekt- und pixelbasierten Bildanalyse

Baumart	Objektbasierte Bildanalyse			Pixelbasierte Bildanalyse		
	PA	UA	Mittelwert	PA	UA	Mittelwert
Arve	0.88	0.90	0.89	0.85	0.77	0.81
Fichte	0.82	0.77	0.80	0.71	0.74	0.73
Flaumeiche	0.89	0.91	0.90	0.99	0.95	0.97
Lärche	0.71	0.73	0.72	0.66	0.78	0.72
übriges Laubholz	0.78	0.85	0.82	0.99	0.99	0.99
Waldföhre	0.88	0.89	0.89	0.90	0.90	0.90
Weisstanne	0.86	0.80	0.83	0.79	0.75	0.77
<i>Mittelwert</i>	<i>0.83</i>	<i>0.83</i>	<i>0.83</i>	<i>0.84</i>	<i>0.84</i>	<i>0.84</i>


PA: Producer's Accuracy | UA: User's Accuracy

In der Abbildung 21 sind Netzdiagramme aufgeführt, welche die erzielten Genauigkeiten der objekt- und pixelbasierten Bildanalyse beinhalten. Die Ergebnisse aus der Konfusionsmatrix (*Producer's* und *User's Accuracy*) zeigen, dass die objektbasierte Bildanalyse für die Weisstanne, Arve und Fichte höhere Genauigkeiten erzielen konnte. Für die Flaumeiche und das übrige Laubholz konnte die pixelbasierte Bildanalyse bessere Ergebnisse erreichen. Die tiefe Leistung der Lärche ist in allen drei Diagrammen erkennbar. Im Bereich der *Producer's* und *User's Accuracy* ist die grösste Abweichung beim übrigen Laubholz zu verzeichnen. In der Analyse der Blinndaten (*Ground Truth*) können die Tendenzen aus der Konfusionsmatrix ebenfalls beobachtet werden. Bei der Arve kann eine grosse Abweichung festgestellt werden. Die Ergebnisse der Flaumeiche, der Lärche und vom übrigen Laubholz fallen ähnlich aus.

(a) Producer's Accuracy



(b) User's Accuracy



(c) Ground Truth




Abb. 21: Vergleich der objektbasierten und pixelbasierten Bildanalyse bezüglich (a) Producer's Accuracy, (b) User's Accuracy und (c) Ground Truth

4.4 Handlungsempfehlung (O4)

In der Abbildung 22 und 23 ist die räumliche Verbreitung der Handlungsempfehlung für einen mässigen und starken Klimawandel in den Testgebieten ersichtlich. Die Tree-App konnte aufgrund zu weit oben liegender oder nicht verfügbarer Standortstypen nicht überall eine Empfehlung abgeben. Diese Wälder sind als solche in der Abbildung ersichtlich (keine Empfehlung möglich). Bei einem mässigen Klimawandel müssten langfristig rund 1'476 ha und bei einem starken Klimawandel 3'686 ha Wald umgebaut werden. Ausgehend von einer Gesamtfläche von 4'345 ha entspricht dies einem Anteil von 34 bzw. 85 %. Aufgeschlüsselt nach Testgebiet sieht die Handlungsempfehlung wie folgt aus (Tab. 17).

Tab. 17: Fläche und Flächenanteil der Handlungsempfehlung für einen mässigen und starken Klimawandel

Testgebiet	Fläche [ha]	mässiger Klimawandel		starker Klimawandel	
		Fläche [ha]	Anteil [%]	Fläche [ha]	Anteil [%]
Testgebiet 1	306	12	4	236	77
Testgebiet 2	1'919	780	41	1'771	92
Testgebiet 3	1'837	457	25	1'436	78
Testgebiet 4	283	227	80	243	86
<i>Total</i>	<i>4'345</i>	<i>1'476</i>	<i>34</i>	<i>3'686</i>	<i>85</i>

Für die Ermittlung des Ist-Zustandes wurden aufgrund der höheren Gesamtgenauigkeit von 84 % die pixelbasierten Ergebnisse verwendet. Die Testgebiete 1, 2 und 3 liegen in der Standortsregion 2b (Nördliche Zwischenalpen ohne Buche). Das Testgebiet 4 ist in der Standortsregion 3 (Kontinentale Hochalpen). Gemäss der Wegleitung NaiS sind für diese Standortsregionen und Höhenstufen folgende Hauptbaumarten möglich:

- **Standortsregion 2b** Fichte, Fichte-Föhre, Eiche-Föhre
- **Standortsregion 3** Lärche-Arve, Fichte

Mithilfe der kanonalen Wegleitung NaiS wurden aufgrund dieser Information die Bestände in Arven-, Fichten- und Föhrenwälder unterteilt. Für die Festlegung der Bestände wurden gemäss der kantonalen Wegleitung folgenden Annahmen getroffen (Tab. 18):

Tab. 18: Generelle Annahmen für die Festlegung der Bestände

Baumart	Standortstyp	ist beigemischt in
Arve	Arvenwälder	Fichtenwälder
Fichte	Fichtenwälder	Föhrenwälder
Flaumeiche	-	Föhrenwälder
Lärche	-	Arvenwälder, Fichtenwälder
übriges Laubholz	-	Arvenwälder, Fichtenwälder, Föhrenwälder
Waldföhre	Föhrenwälder	Fichtenwälder
Weisstanne	-	Fichtenwälder, Föhrenwälder

Die Ausscheidung des Ist-Zustandes basierte auf einem Ausschlussverfahren. Generell wurden Föhren und Flaumeichen in der hoch- und submontanen Höhenstufe den Föhrenwäldern zugeordnet. Gemischte Bestände aus Arven und Lärchen sind als Arvenwälder und die restlichen Flächen als Fichtenwälder ausgeschieden worden. Ebenfalls wurden Informationen über die Baumartenmischung aus der kantonalen Wegleitung NaiS berücksichtigt. In der Tabelle 19 ist die Ausscheidung des Ist-Zustandes aufgeschlüsselt nach Testgebiet aufgeführt. Zusammen mit den Bestandsgrenzen sind in den Testgebieten rund 733 ha Arvenwälder, 2'717 ha Fichtenwälder und 895 ha Föhrenwälder ausgeschieden worden. Ausgehend von einer Gesamtfläche von 4'345 ha entspricht dies einem Flächenanteil von 17, 62 bzw. 21 %. Die räumliche Verteilung der Bestände und die Handlungsempfehlung ist im Anhang C ersichtlich. Die möglichen Standortstypen, die verschiedenen Kombinationen der Höhenstufen und daraus abgeleitete Empfehlung der Baumartenzusammensetzung ist im Anhang D aufgeführt.

Tab. 19: Ausscheidung Ist-Zustand aufgeschlüsselt nach Testgebiet, Flächengrösse und Flächenanteil

Testgebiet	Fläche [ha]	Arvenwälder		Fichtenwälder		Föhrenwälder	
		Fläche [ha]	Anteil [%]	Fläche [ha]	Anteil [%]	Fläche [ha]	Anteil [%]
Testgebiet 1	306	116	38	178	58	12	4
Testgebiet 2	1'919	71	4	1'246	65	601	31
Testgebiet 3	1'837	316	17	1'239	68	282	15
Testgebiet 4	283	230	81	54	19	-	-
<i>Total</i>	<i>4'345</i>	<i>733</i>	<i>17</i>	<i>2'717</i>	<i>62</i>	<i>895</i>	<i>21</i>

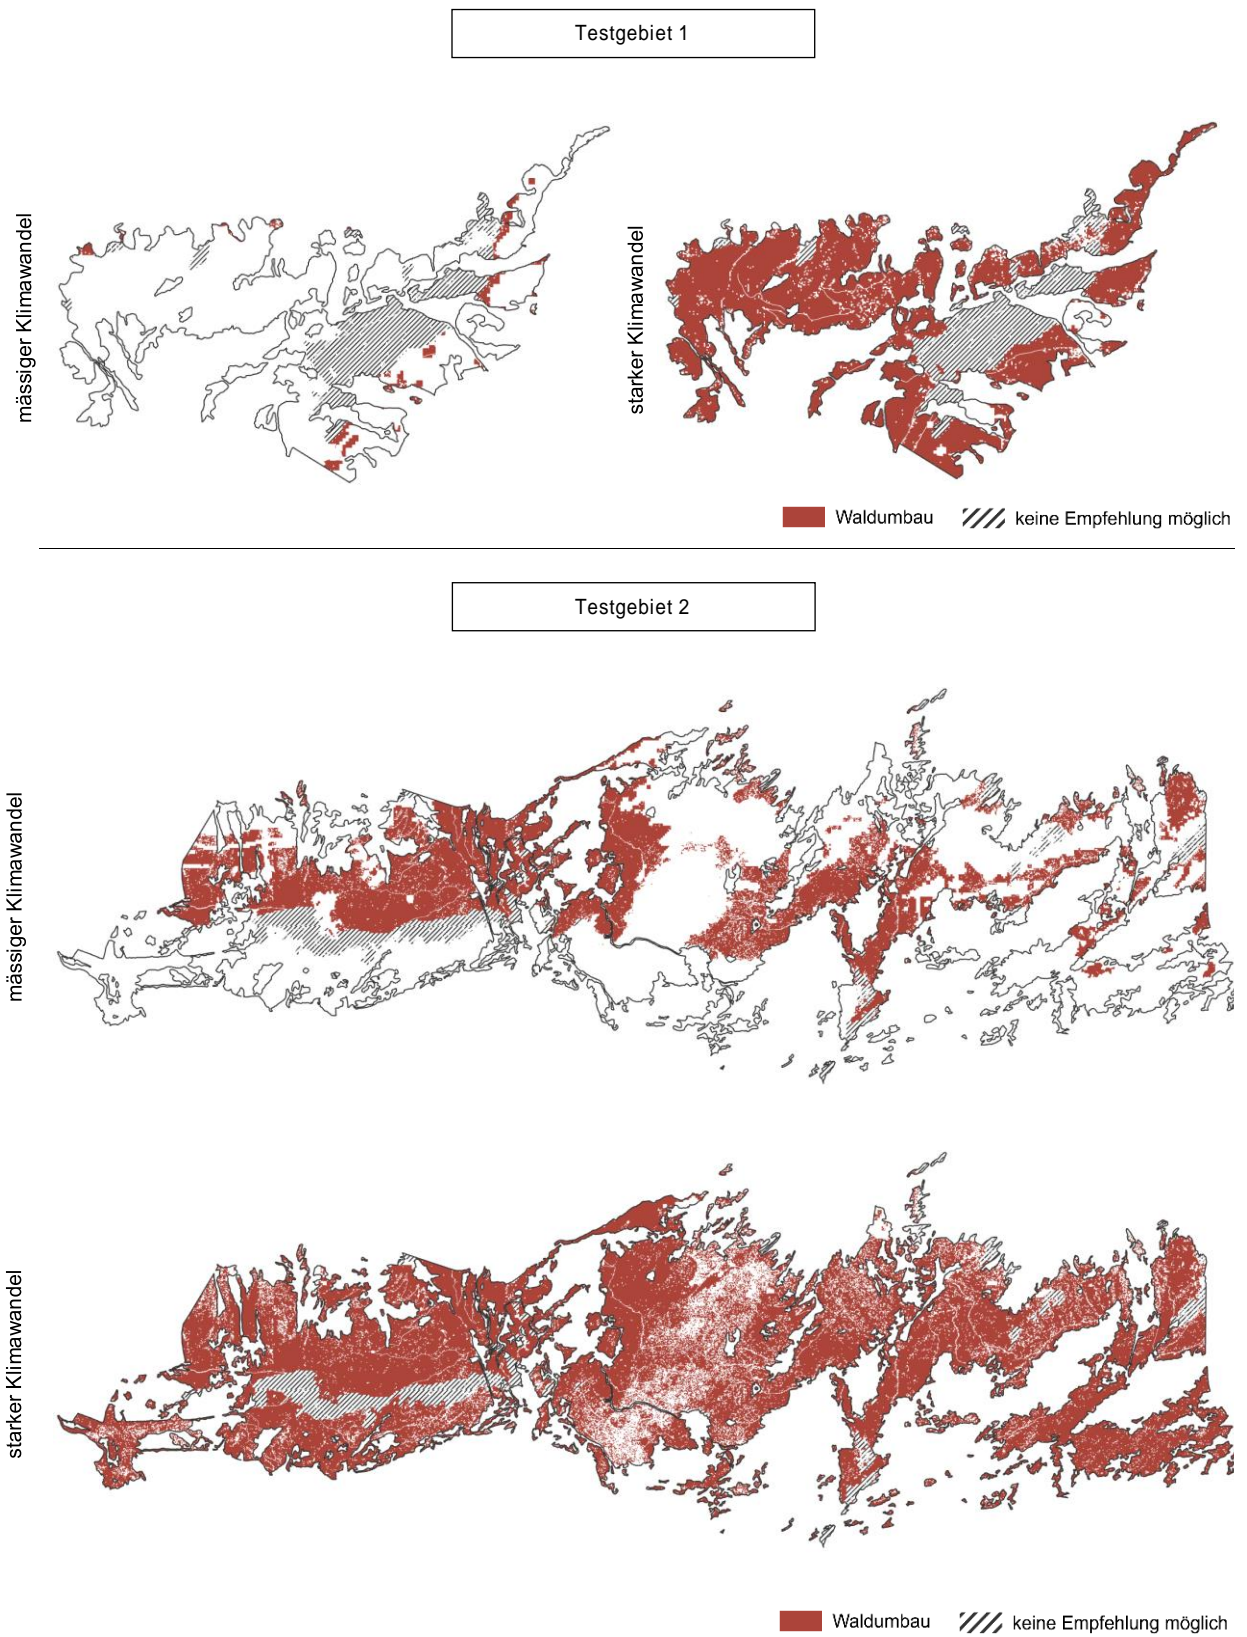


Abb. 22: Räumliche Verteilung der Handlungsempfehlung im Testgebiet 1 und 2 für einen mässigen und starken Klimawandel

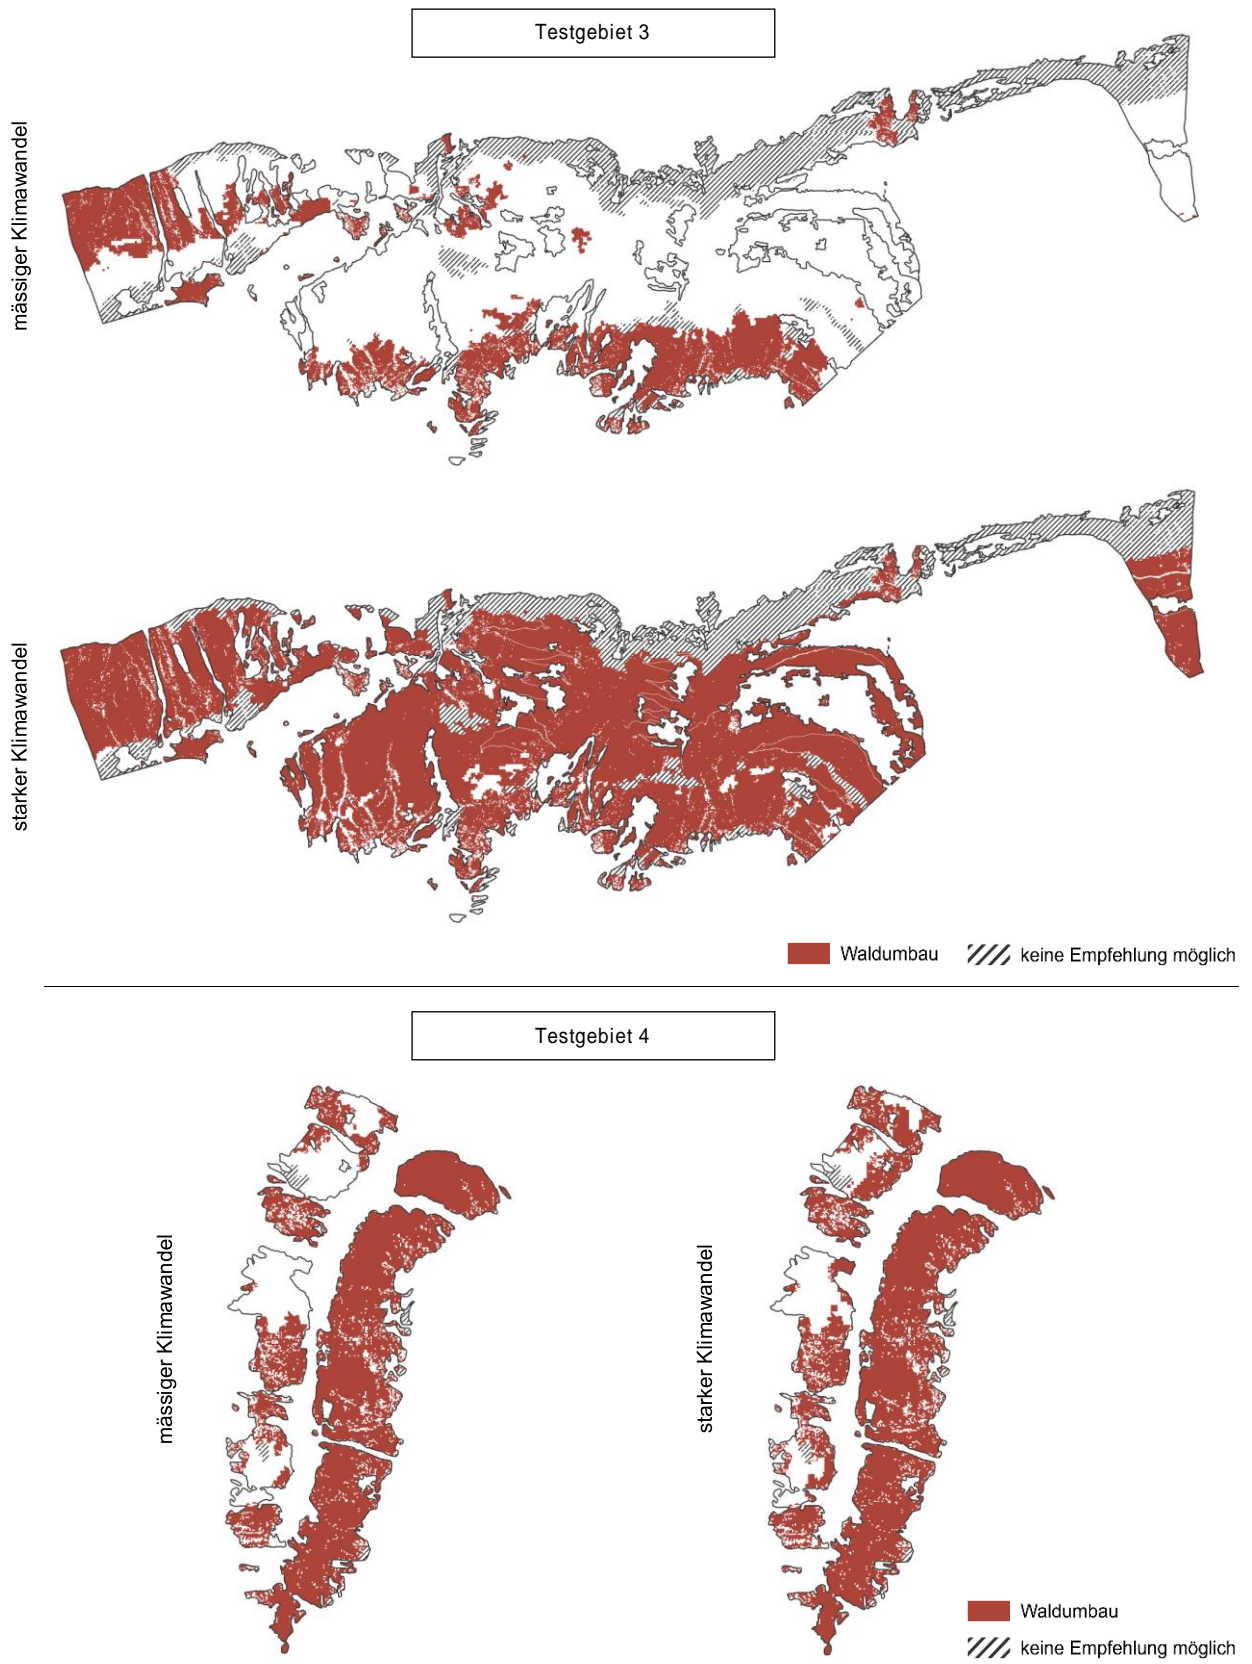


Abb. 23: Räumliche Verteilung der Handlungsempfehlung im Testgebiet 3 und 4 für einen mässigen und starken Klimawandel

5 Diskussion

5.1 Segmentation

Laut Fassnacht et al. (2016) hat die Qualität der Bildsegmentierung einen direkten Einfluss auf die Klassifizierung der Baumarten. Gemäss den Autoren verbessert eine genauere Abgrenzung der Baumkronen die Spektralsignaturen und kann dadurch die Variabilität des Fernerkundungssignals innerhalb einer Art verringern. Laut Ke & Quackenbush (2011) können die Waldbedingungen kompliziert sein und so die Segmentierung erschweren. Sie kamen zum Schluss, dass es zu Problemen bei der Segmentierung kommen kann, wenn die Variation innerhalb der Baumkronen gross ist, die Bäume dicht beieinanderstehen oder sich die Baumkronen überlappen. Laut der Studie können deshalb in gleichförmigen Wäldern bessere Ergebnisse erzielt werden als in Wälder mit unterschiedlichen Merkmalen. Bei der Segmentierung der Baumkronen für die vorliegende Klassifizierung konnten diese Probleme ebenfalls beobachtet werden. Bei den komplexen Gebirgswäldern ist der Grad der horizontalen und vertikalen Strukturierung gross. Im Grossen und Ganzen ist die Segmentierung zufriedenstellend. Lokal können jedoch ungenaue Ergebnisse beobachtet werden. Teilweise wurden in reinen Laubholzbeständen grossflächige Segmente mit mehreren Baumkronen generiert (Abb. 24; a). Andererseits wurden Baumkronen durch mehrere Segmente unterteilt (Abb. 24; b). Ungenaue Segmentierungen resultierten auch durch Verzerrungen in den Bildstreifen (Abb. 24; c).




Abb. 24: Beispiele ungenauer Bildsegmentierung

Mit der Integration von hochauflösenden LiDAR-Daten könnten die Eingabeinformationen erhöht und die Ergebnisse bezüglich der erwähnten Probleme eventuell verbessert werden. Für das Studiengebiet wird in naher Zukunft ein Datensatz mit einer Punktdichte von ca. 15 – 20 Punkten pro m^2 zur Verfügung stehen (swissSURFACE3D). Wie in Freudenberg et al. (2022) dargestellt, könnten ausserdem mit Deep Learning und einem von Hand digitalisierten Trainingsdatensatz wahrscheinlich bessere Abgrenzungen erstellt werden.

5.2 Trainingsdaten

Die Trainingsdaten wurden an verschiedenen Standorten aufgenommen und in Klassen pro Baumart zusammengefasst. Laut Fassnacht et al. (2016) kann es aber durch unterschiedliche Gegebenheiten zu einer hohen Variabilität der Informationen innerhalb den Trainingsdaten kommen. In ihrer Arbeit stellen sie eine Lösung vor, indem für eine Art Unterklassen erstellt werden. Dies könnte gemäss den Autoren in einer Unterteilung in schattigen und sonnigen Hängen erfolgen. Die Anzahl an Trainingsdaten kann mit 334 Stichproben bei der objektbasierten und 253 Stichproben bei der

pixelbasierten Bildanalyse im Vergleich mit verschiedenen Studien (Immitzer et al., 2012; Maschler et al., 2018; Qin et al., 2022) als genügend eingestuft werden. Die Wahl der Baumarten war abhängig von den vorherrschenden Gegebenheiten. Eine weitere Unterteilung der Laubholzarten wäre in Hinblick auf den Klimawandel sicher von Interesse gewesen. Aufgrund der minimalen Stichprobengrösse von über 250 Exemplaren pro Baumart wäre dies mit einem grossen Aufwand verbunden gewesen. Ausser der Flaumeiche kommen reine Bestände mit anderen Laubholzarten im Studiengebiet nicht vor. Neben der Waldföhre kommt im Perimeter noch die Bergföhre als Föhrenart vor. In der Baumartenklassifizierung ist es deshalb möglich, dass die Bergföhre als Waldföhre vorhergesagt wurde. Eine Mischklasse mit Wald- und Bergföhrenarten wäre daher für das Studiengebiet sinnvoll gewesen.

Um Fehler bei der Positionierung der Baumarten auf der Hintergrundkarte zu vermeiden, wurde für die Kartierung die swissimage RS Bildstreifen als Grundlage verwendet. Aufgrund der Bodenauflösung von 25 cm gab es teilweise Schwierigkeiten bei der Kartierung auf der Hintergrundkarte. Ein hochauflösender Hintergrund wäre von Vorteil, jedoch könnte dann die Position der Stichproben nicht mehr mit den multispektralen Grundlagedaten übereinstimmen. Neben der Bodenauflösung kam es bei der Kartierung wegen der teilweise hohen vertikalen Strukturierung der Bestände zu Schwierigkeiten. Die Zeitverzögerung zwischen den Bildaufnahmen (2020) und der Kartierung (2022) ist als gering einzustufen und hat deshalb keinen Einfluss auf die Qualität der Erhebung.

Für die pixelbasierte Bildanalyse sind die Trainingsdaten mithilfe einer Fotointerpretation um 139 Stichproben pro Baumart erweitert worden. Neben der Wahrscheinlichkeit von Fehlern in der Feldbegehung, muss in der Fotointerpretation auch mit Fehlinterpretationen gerechnet werden. Mithilfe der *Color Infrared* Band-Kombination konnte dem in einem gewissen Mass entgegengewirkt werden. Wegen der Auflösung von 10 m wurde ein Anteil der Zielbaumart von ungefähr Zweidrittel festgelegt. Durch diesen Umstand weisen die Trainingsdaten ein gewisses Rauschen auf. Im Studiengebiet kommt es aufgrund der vorkommenden Mischwälder und unterschiedlichen Altersklassen selten vor, dass ein Pixel genau einen Baum oder einen Bestand einer einzigen Art abdeckt. Gemäss Fassnacht et al. (2016) deckt mit einer tieferen Auflösung das Reflexionssignal eine grössere Bandbreite an Oberflächenbedingungen ab. In der Studie konnte festgestellt werden, dass Probleme eher entstehen, wenn in einem Pixel mehrere Arten vorkommen. Deshalb wurde wie in Adelabu et al. (2013) beschrieben mit einem Prozentsatz einer bestimmten Zielbaumart ausgegangen. Durch die vorkommenden Mischwälder sind diese Art von Trainingsdaten sicher von Vorteil als Plots mit Bäumen einer einzigen Art. Laut Fassnacht et al. (2016) wäre ein weiterer Ansatz die Verwendung von Fuzzylogiken. Damit könnte die Artenmischung in einer Klasse definiert werden (bspw. Lärchen-Arvenwald). Shang & Chisholm (2014) kamen in ihrer Studie zum Schluss, dass wegen dem Einfluss des Hintergrundsignals die Klassifizierung von einem Bestand schwieriger ist als auf Einzelbaumstufe. Diesem Problem könnte entgegen gewirkt werden in dem wie in Mallinis et al. (2008) beschrieben die Trainingsdaten zwischen dichten und offenen Beständen unterschieden werden.

5.3 Bildklassifizierung

5.3.1 Variablen und Klassifikator

Im einem Variantenstudium wurde mit der Kombination von verschiedenen Variablen die bestmögliche Genauigkeit für beide Bildanalysen ermittelt. In der Tabelle 20 ist die Entwicklung der Gesamtgenauigkeit in Abhängigkeit mit den Variablen ersichtlich. Bei der objektbasierten Bildanalyse führte einerseits der Wechsel des Klassifikators zum *Support Vector Machine* Algorithmus und andererseits die Zugabe von mehr Variablen zu einer höheren Gesamtgenauigkeit. Auffällig ist, dass mit der Integration der Vegetationshöhe (VHM; +5 Prozentpunkte) und der Information vom Nadelholzanteil (NH; +4 Prozentpunkte) die Ergebnisse wesentlich verbessert werden konnten. Die Farbmodellkonvertierung der *Color-Infrared*-Farben (CIR) in HSV führte zu einem schlechteren Ergebnis (-1 Prozentpunkt). Bei der pixelbasierten Bildanalyse ist erkennbar, dass die Ergebnisse mit zwei weiteren Bildszenen vom gleichen Jahr (+5 Prozentpunkte), den Informationen über den Nadelholzanteil (+5 Prozentpunkte) sowie die Farbmodellkonvertierung (RGB in HSV) (+5 Prozentpunkte) am deutlichsten verbessert werden konnten. Die Integration der Bänder im *Vegetation Red Edge* (B5, B6, B7, B8A) und kurzwelligen Infrarotlicht-Bereich (B11, B12) (+3 Prozentpunkte) konnte das Modell weiter optimieren. Die Berücksichtigung einer vierten Bildszene (2020-07-08) konnten die Ergebnisse jedoch nicht verbessern (-1 Prozentpunkt). In der Analyse wurde stellenweise versucht, die Informationen über den Nadelholzanteil (NH) mit den Informationen über den Waldmischungsgrad (WMG) (Waser et al., 2017) zu ersetzen. Dies führte zu Beginn zu geringen Verbesserungen. Am Ende konnte jedoch kein Unterschied in den Genauigkeiten mehr festgestellt werden.

Tab. 20: Variantenstudium für Bestimmung der Variablen und des Klassifikators

Bildanalyse	Klassifikator	Variablen	Gesamtgenauigkeit	
objektbasiert	Random Forest	NIR, Rot, Grün, Blau	0.67	
		Support Vector Machine	0.75	
	Machine	NIR, Rot, Grün, Blau, NDVI	0.76	
		NIR, Rot, Grün, Blau, NDVI, VHM	0.81	
		NIR, Rot, Grün, Blau, NDVI, VHM, HSV (RGB)	0.82	
		NIR, Rot, Grün, Blau, NDVI, VHM, HSV (RGB), HSV (CIR)	0.81	
		NIR, Rot, Grün, Blau, NDVI, VHM, HSV (RGB), NH	0.85	
pixelbasiert	Support Vector Machine	2020-08-07 [B2 (Blau), B3 (Grün), B4 (Rot), B8 (NIR)]	0.59	
	Machine	2020-08-07 [B2, B3, B4, B8], NH	0.64	
		2020-08-07 [B2, B3, B4, B8], WMG	0.65	
		2020-08-07 [B2, B3, B4, B8], NH, VHM	0.66	
		2020-08-07 [B2, B3, B4, B8, NDVI], NH, VHM	0.67	
		2020-08-07 [B2, B3, B4, B8, NDVI, HSV (RGB)], NH, VHM	0.72	
		2020-08-07 [B2, B3, B4, B8, NDVI, HSV (RGB)], WMG, VHM	0.71	
		Random Forest	2020-08-07 [B2, B3, B4, B8, NDVI, HSV (RGB)], NH, VHM	0.76
	Forest	2020-08-07 [B2, B3, B4, B5, B6, B7, B8, B8a, B11, B12, NDVI, HSV (RGB)], NH, VHM	0.79	
		2020-05-29 [B2, B3, B4, B5, B6, B7, B8, B8a, B11, B12, NDVI, HSV (RGB)], 2020-08-07 [B2, B3, B4, B5, B6, B7, B8, B8a, B11, B12, NDVI, HSV (RGB)], NH, VHM	0.81	
		2020-05-29 [B2, B3, B4, B5, B6, B7, B8, B8a, B11, B12, NDVI, HSV (RGB)], 2020-06-23 [B2, B3, B4, B5, B6, B7, B8, B8a, B11, B12, NDVI, HSV (RGB)], 2020-08-07 [B2, B3, B4, B5, B6, B7, B8, B8a, B11, B12, NDVI, HSV (RGB)], NH, VHM	0.84	
		2020-05-29 [B2, B3, B4, B5, B6, B7, B8, B8a, B11, B12, NDVI, HSV (RGB)], 2020-06-23 [B2, B3, B4, B5, B6, B7, B8, B8a, B11, B12, NDVI, HSV (RGB)], 2020-07-08 [B2, B3, B4, B5, B6, B7, B8, B8a, B11, B12, NDVI, HSV (RGB)], 2020-08-07 [B2, B3, B4, B5, B6, B7, B8, B8a, B11, B12, NDVI, HSV (RGB)], NH, VHM	0.83	
		Support Vector Machine	2020-05-29 [B2, B3, B4, B5, B6, B7, B8, B8a, B11, B12, NDVI, HSV (RGB)], 2020-06-23 [B2, B3, B4, B5, B6, B7, B8, B8a, B11, B12, NDVI, HSV (RGB)], 2020-08-07 [B2, B3, B4, B5, B6, B7, B8, B8a, B11, B12, NDVI, HSV (RGB)], NH, VHM	0.84
		Machine	2020-05-29 [B2, B3, B4, B5, B6, B7, B8, B8a, B11, B12, NDVI, HSV (RGB)], 2020-06-23 [B2, B3, B4, B5, B6, B7, B8, B8a, B11, B12, NDVI, HSV (RGB)], 2020-08-07 [B2, B3, B4, B5, B6, B7, B8, B8a, B11, B12, NDVI, HSV (RGB)], WMG, VHM	0.84

In Raczko & Zagajewski (2017) konnte in einem Vergleich festgestellt werden, dass mit dem *Support Vector Machine* Algorithmus eine höhere Genauigkeiten und somit die besseren Ergebnisse erzielt werden konnten als mit *Random Forest*. Die besseren Ergebnisse mit *Support Vector Machine* werden auch in Wessel et al. (2018) bestätigt. Im Variantenstudium konnte bei der objektbasierten Bildanalyse mit dem *Support Vector Machine* Algorithmus im Vergleich zu *Random Forest* die Genauigkeit um 8 Prozentpunkte erhöht werden (berechnet nur mit swissimage RS-Bildstreifen ohne weiteren Variablen). Im Variantenstudium der pixelbasierten Bildanalyse ist erkennbar, dass *Support Vector Machine* gegenüber *Random Forest* im Vorteil sein kann. Bei einer hohen Anzahl Variablen konnte aber eine Annäherung der Gesamtgenauigkeit beider Algorithmen festgestellt werden. Für die vorliegende Studie wurde bei der pixelbasierte Bildanalyse der *Random Forest* Algorithmus ausgewählt, weil die Genauigkeiten der einzelnen Baumarten besser ausfielen.

Die Abbildung 25 zeigt die Gegenüberstellung der mittleren spektralen Signaturen der sieben Baumarten hinsichtlich der verschiedenen Grundlagedaten im Bereich von Blau, Grün, Rot und Nahinfrarot. Bei allen Grundlagedaten weisen die Laubholzarten höhere Reflexionswerte auf als die Nadelholzarten. Dies insbesondere im Bereich des Nahinfrarots. In den Sentinel-Bildern ist der Abstand der Reflexion vom übrigen Laubholz zu den anderen Arten am grössten. In den swissimage RS-Bildstreifen sind die Werte für die Flaumeiche und das übrige Laubholz ähnlich. Die Signaturen basierend auf den swissimage RS-Bildstreifen scheinen generell höhere Werte der Reflexion aufzuweisen als bei den Sentinel-Bildern. Ausserdem kann beobachtet werden, dass die Reflexion im grünen Bereich im August höher liegt als in den anderen Monaten. Tendenziell sieht der Verlauf der Werte bei beiden Systemen im August ähnlich aus. Es ist auffällig, dass die Baumarten insbesondere im Bereich des Nahinfrarots unterschieden werden können. Dies wird in den Studien von Maschler et al. (2018) und Immitzer et al. (2012) ebenfalls bestätigt. In den Bereichen Blau, Grün und Rot des sichtbaren Lichts sind die Unterschiede weniger ausgeprägt. Lediglich bei den Sentinel-Aufnahmen vom Mai und Juni können deutlichere Unterschiede im Bereich des blauen Spektrums beobachtet werden. Deshalb ist die Berücksichtigung von mehreren Bildaufnahmen über das Jahr hinweg in der Klassifikation sicher von Vorteil gewesen. Die Genauigkeit könnte eventuell noch weiter erhöht werden, wenn noch zusätzliche Bildszenen für die Klassifikation verwendet werden. In anderen Studien wurden bspw. 8 (Ma et al., 2021), 18 (Immitzer et al., 2019) oder sogar 23 (Axelsson et al., 2021) Sentinel-Bildszenen berücksichtigt. In Immitzer et al. (2019) wurde festgestellt, dass eine Kombination mit sechs bis sieben Bildszenen bereits gute Ergebnisse liefern kann. Wenn mehrere Sentinel-Bildszenen in einem Modell kombiniert werden, ist eine Co-Registrierung der Bilddaten sicher nutzbringend, so wie es in Zeitreihen-Analysen durchgeführt wird (Da Gomes Silva et al., 2020). In der vorliegenden Studie wurde diese Korrektur nicht ausgeführt, wodurch wahrscheinlich die schlechteren Ergebnisse mit 4 Bildszenen zu begründen sind.

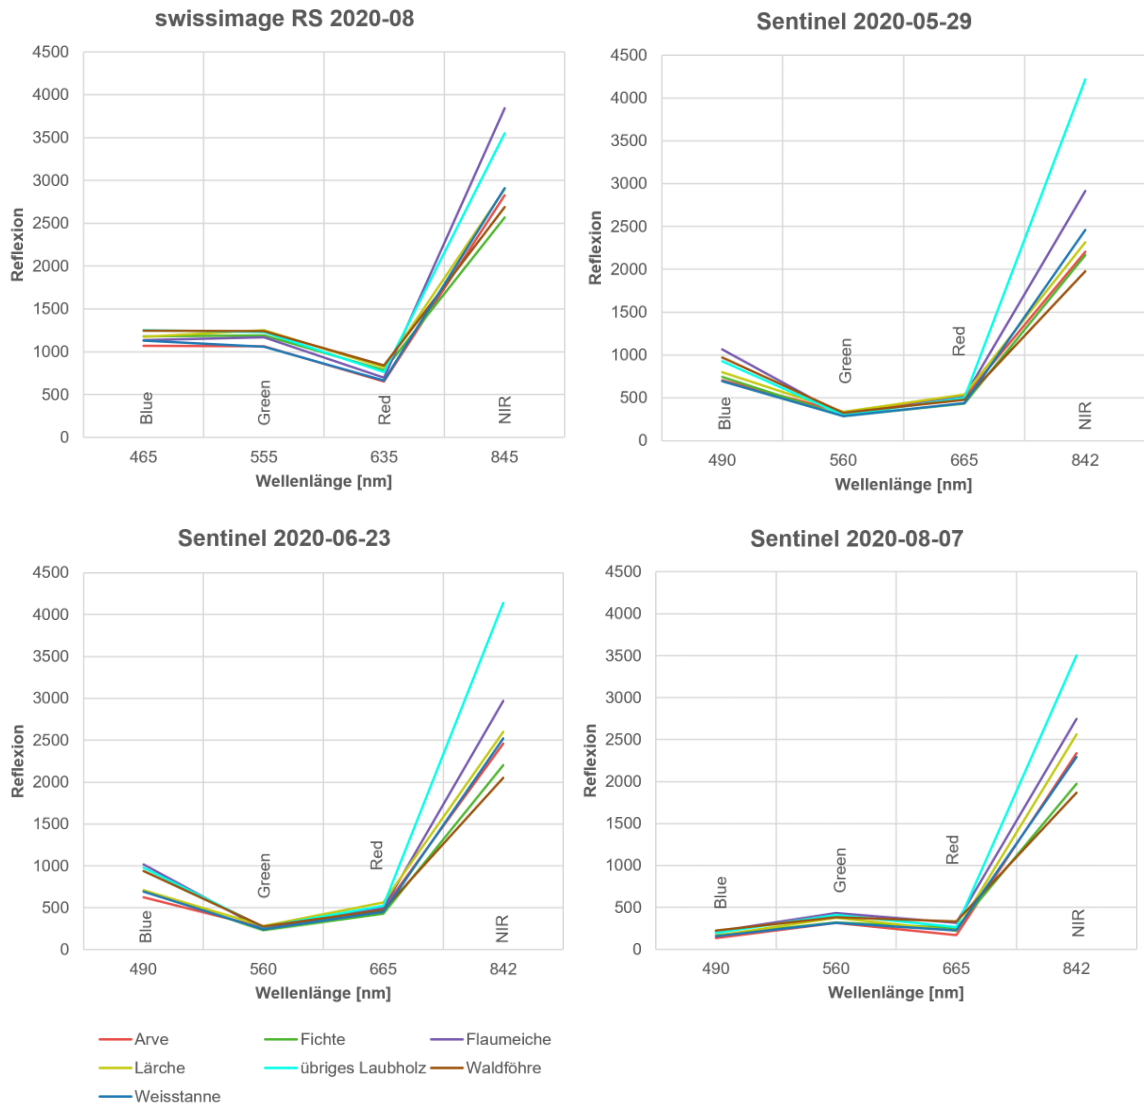


Abb. 25: Mittlere spektrale Signaturen der 7 Baumarten hinsichtlich der verschiedenen Grundlagedaten im Bereich Blau, Grün, Rot und Nahinfrarot

In der Abbildung 26 sind die mittleren spektralen Signaturen der 7 Baumarten hinsichtlich der verwendeten Sentinel-Bilder im gesamten genutzten Spektrum ersichtlic. In der Gegenüberstellung ist sichtbar, dass die Werte der Reflexion im August generell tiefer liegen als in den vorangegangenen Monaten. Besonders die Flaumeiche und das übrige Laubholz weisen im Mai und Juni ab 783 nm deutlichere Unterschiede zu den anderen Baumarten auf. Allgemein weisen Fichten und Waldföhren die tiefsten mittleren Werte auf. So wie in den Diagrammen ersichtlic ist, können die Baumarten in den Bereichen NIR, SWIR und ab 740 nm im *Vegetation Red Edge* sehr gut differenziert werden. Die Verwendung von den tiefer aufgelösten Sentinel-Daten in einer räumlic Auflösung 20 m scheinen hilfreich gewesen zu sein, wie in Immitzer et al. (2016) ebenfalls aufgezeigt wurde.




Abb. 26: Mittlere spektrale Signaturen der 7 Baumarten hinsichtlich der verwendeten Sentinel-Bilder im ganzen Spektrum

In der Tabelle 21 sind die Mittelwerte der aus den Bilddaten generierten Variablen und Indizes gegenübergestellt. Bezüglich des NDVI gibt es teilweise ähnliche Werte zwischen den Baumarten: Arve und Weisstanne (swissimage RS); Fichte und Waldföhre (swissimage RS); Arve, Fichte und Lärche (Sentinel 2020-05-29). Ansonsten können unterschiedliche Werte beobachtet werden. Bei den Sentinel-Bildern ist ersichtlich, dass das übrige Laubholz in allen Szenen die höchsten Werte aufweist. Für die Verbesserung der Ergebnisse hätten allenfalls noch mehr Vegetationsindizes eingebunden werden können. In Ma et al. (2021) konnte festgestellt werden, dass neben dem NDVI für die Unterscheidung von Baumarten im Berggebiet auch der Red Edge Normalized Difference Vegetation Index (NDVI705), der Enhanced Vegetation Index (EVI) und der Land Surface Water Index (LSWI) verwendet werden können. Neben diesen Indizes könnten laut Maschler et al. (2018) auch der Photochemical Reflectance Index (PRI), der Blue Ratio (BR), der Plant Senescence Reflectance Index (PSRI), der Green Normalized Difference Vegetation Index (GNDVI) und der Modified Normalized Difference Index (mND705) eingesetzt werden. Bezüglich der Farbmodellkonvertierung in HSV ist ersichtlich, dass bei

den swissimage RS-Bilddaten höhere Werte generiert wurden als bei den Sentinel-Bildern. Zwischen den Baumarten sind Unterschiede in den Werten feststellbar. Es können jedoch keine spezifischen Merkmale zwischen den Baumarten erkannt werden.

Tab. 21: Gegenüberstellung der Mittelwerte aus den Bilddaten generierten Variablen / Indizes

	Swissimage RS 2020-08				Sentinel 2020-05-29				Sentinel 2020-06-23				Sentinel 2020-08-07			
	NDVI	Hue	Sat.	Value	NDVI	Hue	Sat.	Value	NDVI	Hue	Sat.	Value	NDVI	Hue	Sat.	Value
Arve	162	121	110	70	174	80	97	31	179	77	120	31	187	72	149	20
Fichte	152	119	97	78	174	70	90	27	174	62	117	27	177	58	122	20
Flaumeiche	169	118	110	76	179	68	112	32	181	65	132	31	179	62	131	27
Lärche	155	114	95	80	174	76	101	34	178	73	129	35	184	68	146	23
übriges Laubholz	164	122	108	82	187	82	113	31	185	71	124	33	185	67	132	26
Waldföhre	152	121	91	81	165	52	86	30	168	55	107	30	170	53	112	24
Weisstanne	162	125	110	72	179	78	96	27	179	67	120	28	182	63	131	20

In der Tabelle 22 sind die Mittelwerte und Standardabweichungen der Vegetationshöhe und des Nadelholzanteils aufgeführt. In beiden Bildanalysen weisen Weisstannen hohe und Flaumeichen niedrige Baumhöhen auf. Bei der Fichte gibt es die grösste Diskrepanz zwischen den Bildanalysen. Bei der Fichte liegt auch die grösste mittlere Abweichung der Streuung vor. Im Grossen und Ganzen können die Baumarten über die Vegetationshöhe charakterisiert werden. Nadelbaumarten sind generell höher als Laubbaumarten und innerhalb der Nadelbaumarten weist die Waldföhre die niedrigsten Werte auf. Das ist mitunter sicher ein wichtiger Faktor gewesen für die gute Vorhersage dieser Baumart. Die Arve und die Lärche weisen ähnliche Baumhöhen auf. Bezüglich des Nadelholzanteils können die Werte bei der pixelbasierten Bildanalyse besser den Baumarten zugeordnet werden. Die Unterscheidung der Nadel- und Laubholzarten ist eindeutiger. Bis auf die Weisstanne weisen alle Nadelholzarten Werte über 90 % auf. Das übrige Laubholz kann mit 5 % Nadelholzanteil gut differenziert werden. Ebenfalls ist die mittlere Abweichung der Streuung weniger ausgeprägt als bei der objektbasierten Bildanalyse. Insbesondere für die Unterscheidung der Nadel- und Laubholzarten ist diese Variable von Nutzen gewesen ist.

Tab. 22: Mittelwerte und Standardabweichung (SD) der Vegetationshöhe und des Nadelholzanteils

	objektbasierte Bildanalyse				pixelbasierte Bildanalyse			
	VHM		NH		VHM		NH	
	Mittelwert	SD	Mittelwert	SD	Mittelwert	SD	Mittelwert	SD
Arve	15	2	94	5	15	3	97	5
Fichte	14	8	89	15	18	8	91	8
Flaumeiche	5	2	37	30	6	3	30	26
Lärche	16	6	88	17	16	6	94	13
übriges Laubholz	12	4	23	34	13	6	5	13
Waldföhre	8	4	80	27	10	4	94	15
Weisstanne	18	4	79	18	17	5	85	18

In den Bildanalysen hätten noch weitere Variablen eingebunden werden können. In der Studie von Ma et al. (2021) konnte festgestellt werden, dass mit der Zugabe von topografischen Merkmalen wie der Höhenlage, Ausrichtung und Hangneigung die Trennbarkeit zwischen den verschiedenen Baumarten verbessert werden konnte. Damit diese Variablen in der vorliegenden Studie genutzt werden könnten, müssten die Trainingsgebiete im Studienperimeter gleichmässig verteilt sein. Mit vielen erklärenden Variablen und relativ wenigen Trainingsdaten kann jedoch das Problem entstehen, dass das Modell hervorragend an die Trainingsdaten angepasst ist, aber für das restliche Gebiet schlechte Vorhersagen macht (Fassnacht et al., 2016; Waser et al., 2011). In der Studie von Hughes (1968) wurde festgestellt, dass die Vorhersagekraft eines Klassifikators mit der Zunahme der Dimensionen (Variablen) verbessert wird, bei gleichbleibender Anzahl Trainingsdaten ab einer bestimmten Anzahl der Dimensionen die Leistung jedoch verschlechtert wird. Deshalb ist eine flächige Validation des Modells bezüglich der Übereinstimmung der räumlichen Verteilung mit der Realität von grosser Wichtigkeit. Dies könnte mit lokalen Inventurdaten durchgeführt werden. Das Problem der Überanpassung des Modells könnte mit einer Reduzierung der *Features* mittels *Feature Extraction* oder *Feature Selection* Methoden gelöst werden (Fassnacht et al., 2016).

5.3.2 Objektbasierte Bildanalyse (O1)

Mit den orthorektifizierten Luftbildstreifen in einer Auflösung von 25 cm konnte mit einer objektbasierten Bildanalyse die Baumartenzusammensetzung in der Hauptschicht auf Stufe Baum mit einer durchschnittlichen Gesamtgenauigkeit von 83 % (Konfusionsmatrix) bestimmt werden. Das Ziel von einer Genauigkeit von 85 % wurde knapp nicht erreicht. Zwischen den Baumarten gibt es jedoch erkennbare Unterschiede (Abb. 27). Aus diesem Grund ist die Gesamtgenauigkeit nicht aussagekräftig für die Klassifikation. Hinsichtlich der *Producer's Accuracy* weisen die Arve (88 %), die Flaumeiche (89 %), die Waldföhre (88 %) und die Weisstanne (86 %) Genauigkeiten über 85 % auf. Bezüglich der *User's Accuracy* haben die Arve (90 %), die Flaumeiche (91 %), das übrige Laubholz (85 %) und die Waldföhre (89 %) zufriedenstellende Ergebnisse mit einer Genauigkeit über 85 %. Einzig die Fichte und die Lärche weisen in beiden Kategorien unbefriedigende Resultate auf. Die Kappa-Statistik liegt zwischen 80 und 81 %. Bei einem Kappa von 100% würde eine vollkommene Übereinstimmung vorliegen. Deshalb weist das Modell gemäss McHugh (2012) mit einem Kappa-Wert von über 80 % eine starke Übereinstimmung auf.




Abb. 27: Vergleich der Genauigkeiten zwischen den Baumarten der objektbasierten Bildanalyse

Die Grenze der Klassifizierung im östlichen Bereich auf rund 2'000 m Höhe ist mit der Zusammenführung zweier Luftbildstreifen zu begründen (Abb. 28). Ob dabei die Fichte oder Lärche falsch vorhergesagt wurde, kann nicht abschliessend festgestellt werden.




Abb. 28: Fehler bei der Vorhersage von Fichte / Lärche in der objektbasierten Bildanalyse

5.3.3 Pixelbasierte Bildanalyse (O2)

Mit Sentinel-Satellitenbilder in einer Auflösung von 10 m konnte mit einer pixelbasierten Bildanalyse die Baumartenzusammensetzung in der Hauptschicht auf Stufe Bestand mit einer durchschnittlichen Gesamtgenauigkeit von 84 % (Konfusionsmatrix) bestimmt werden. Das Ziel von einer Genauigkeit von 85 % wurde fast erreicht. Zwischen den Baumarten gibt es wie bei der objektbasierten Bildanalyse deutliche Unterschiede (Abb. 29). Hinsichtlich der *Producer's Accuracy* konnten für die Arve (85 %), die Flaumeiche (99 %), das übrige Laubholz (99 %) und die Waldföhre (90 %) Genauigkeiten über 85 % erreicht werden. Bezüglich der *User's Accuracy* liegen bei der Flaumeiche (95 %), das übrige Laubholz (99 %) und die Waldföhre (90 %) Genauigkeiten über 85 % vor. Die Ergebnisse der Fichte, der Lärche und der Weisstanne liegen unter dem Schwellenwert und sind weniger befriedigend. Die Kappa-Statistik hat 81 % ergeben. Die Vorhersage im Modell weist daher gemäss McHugh (2012) eine starke Übereinstimmung auf.





Abb. 29: Vergleich der ermittelten Genauigkeiten zwischen den Baumarten der pixelbasierten Bildanalyse

5.4 Vergleich und Validation der Ergebnisse (O3)


5.4.1 Vergleich beider Bildanalysen

Die Ergebnisse beider Bildanalysen konnten miteinander verglichen und anhand der ermittelten Gesamtgenauigkeit validiert werden. Die Gesamtgenauigkeit und der Kappa-Wert liegen bei beiden Bildanalysen in einem ähnlichen Bereich. Mit der pixelbasierten Bildanalyse konnte mit 84 % jedoch eine höher Gesamtgenauigkeit erzielt werden. Der Vergleich zwischen den Baumarten zeigt Abweichungen auf. Bei der *Producer's* und *User's Accuracy* ist die Diskrepanz zwischen den Daten beim übrigen Laubholz am grössten, ansonsten sehen die Tendenzen ähnlich aus.

Obwohl mit beiden Bildanalyse ähnliche Gesamtgenauigkeiten erzielt wurden, gibt es im Vergleich miteinander Unterschiede in der räumlichen Verteilung der Ergebnisse. Aus dem Vergleich der Baumartenverteilung gehen unterschiedliche Ergebnisse hervor. Diese Abweichung kann in einer visuellen Überprüfung der Ergebnisse bestätigt werden. In den Testgebieten gibt es Beispiele von gut und weniger gut übereinstimmenden Beständen. Im Testgebiet 1 können zum Beispiel im Osten Lärchen-Arvenwälder beobachtet werden, welche bei beiden Methoden vorhergesagt wurden (Abb. 30; a). Im nördlichen Teil stimmen die Vorhersagen hingegen weniger gut überein (Abb. 30; b). Im Testgebiet gibt es ausserdem eine Verwechslung zwischen dem übrigen Laubholz (pixelbasierte Bildanalyse) mit der Flaumeiche (objektbasierte Bildanalyse). Im Testgebiet 2 und 3 wird ebenfalls die Weisstanne in der pixelbasierten Bildanalyse grossflächiger vorhergesagt. Bei der objektbasierten Bildanalyse wurde in diesen Bereichen die Fichte, Waldföhre oder Lärche detektiert. Ansonsten sehen die Tendenzen der Verbreitung der Waldföhre, Flaumeiche, Fichte, Lärche und dem übrigen Laubholz ähnlich aus. In den höheren Lagen wurde bei der pixelbasierten Bildanalyse die Arve deutlich mehr vorhergesagt. Im Testgebiet 4 sieht das Bild ähnlich aus. Es liegt eine Verwechslung vom übrigen Laubholz (pixelbasierte Bildanalyse) mit der Flaumeiche (objektbasierte Bildanalyse) vor und die Arve wurde bei der pixelbasierten Bildanalyse grossflächiger detektiert.



(a) Gute Übereinstimmung der Ergebnisse in einem Lärchen-Arvenwald



(b) Weniger gute Übereinstimmung der Ergebnisse zwischen Lärche und Weisstanne

Abb. 30: Visueller Vergleich Ergebnisse aus objekt- und pixelbasierten Bildanalyse

5.4.2 Vergleich Genauigkeiten mit anderen Publikationen

In der Tabelle 23 sind die Genauigkeiten (Mittelwert aus *Producer's* und *User's Accuracy*) der vorliegenden Studie mit Ergebnissen aus anderen Publikationen gegenübergestellt. In der Studie von Immitzer et al. (2012) wurde ebenfalls eine objekt- und pixelbasierte Bildanalyse durchgeführt. In der Studie resultierte mit der objektbasierten mit 82 % eine höhere Gesamtgenauigkeit (+9 Prozentpunkte) gegenüber der pixelbasierten Bildanalyse. Im Gegensatz zur vorliegenden Studie wurden für beide Analysen jedoch dieselben Satellitenbilder verwendet. In der Studie kann ebenfalls beobachtet werden, dass die Vorhersage der Lärche am schlechtesten ausfiel. Im Vergleich mit den Studien von Maschler et al. (2018) und Immitzer et al. (2019) weist die Lärche jedoch gute Ergebnisse auf. Es wäre somit möglich die Lärche mit einer höheren Genauigkeit voraussagen zu können. In Maschler et al. (2018) wurden viel mehr Variablen eingesetzt, unter anderem diverse Vegetationsindizes. Ausserdem wurde mittels einer *Feature Selection* das Modell optimiert. In Immitzer et al. (2019) wurden für die Klassifikation 18 Sentinel-2-Bildszenen verwendet, welche innerhalb von drei Jahren aufgenommen wurden. Die Fichte konnte in der vorliegenden Studie im Vergleich weniger gut detektiert werden. Die Ergebnisse vom übrigen Laubholz sind mit der objektbasierten eher schlechter und mit der pixelbasierten Bildanalyse besser zu bewerten. Die Ergebnisse der Waldföhre liegen im Vergleich mit den anderen Publikationen im oberen Bereich. Für die Arve, die Flaumeiche und die Weisstanne gibt es in den aufgeführten Publikationen keine Informationen. Hinsichtlich der Gesamtgenauigkeit könnte das Modell noch weiter optimiert werden. Im Vergleich wurde eher eine tiefere Gesamtgenauigkeit erzielt.

Tab. 23: Vergleich der ermittelten Genauigkeiten (Studie) mit anderen Publikationen

Publikation	Studie	Li et al. (2021)	Maschler et al. (2018)	Immitzer et al. (2012)	Studie	Axelsson et al. (2021)	Immitzer et al. (2019)	Immitzer et al. (2012)
Arve	0.89				0.81			
Fichte	0.79	0.91	0.93	0.8	0.72	0.93	97.1	0.66
Flaumeiche	0.9				0.97			
Lärche	0.72		0.94	0.68	0.72		0.94	0.52
übriges LH	0.81	0.88	0.86	0.79	0.99	0.81	0.82	0.71
Waldföhre	0.88	0.96	0.97	0.88	0.9	0.74	0.94	0.77
Weisstanne	0.83				0.77			
Gesamtgenauigkeit	0.83	0.91	0.89	0.82	0.84	0.87	0.9	0.73
Ansatz	objektb.	objektb.	objektb.	objektb.	pixelb.	pixelb.	pixelb.	pixelb.
Klassifikator	SVM	CNN	RF	RF	RF	ML	RF	RF
Daten	Luftbild	WorldView-2	Luftbild	WorldView-2	Sentinel-2	Sentinel-2	Sentinel-2	WorldView-2
Bodenauflösung	0.25 m	0.4 m	0.4 m	0.5 m	10 m	10 m	10 m	0.5 m

SVM: Support Vector Machine | CNN: Convolutional Neural Network | RF: Random Forest | ML: Maximum Likelihood

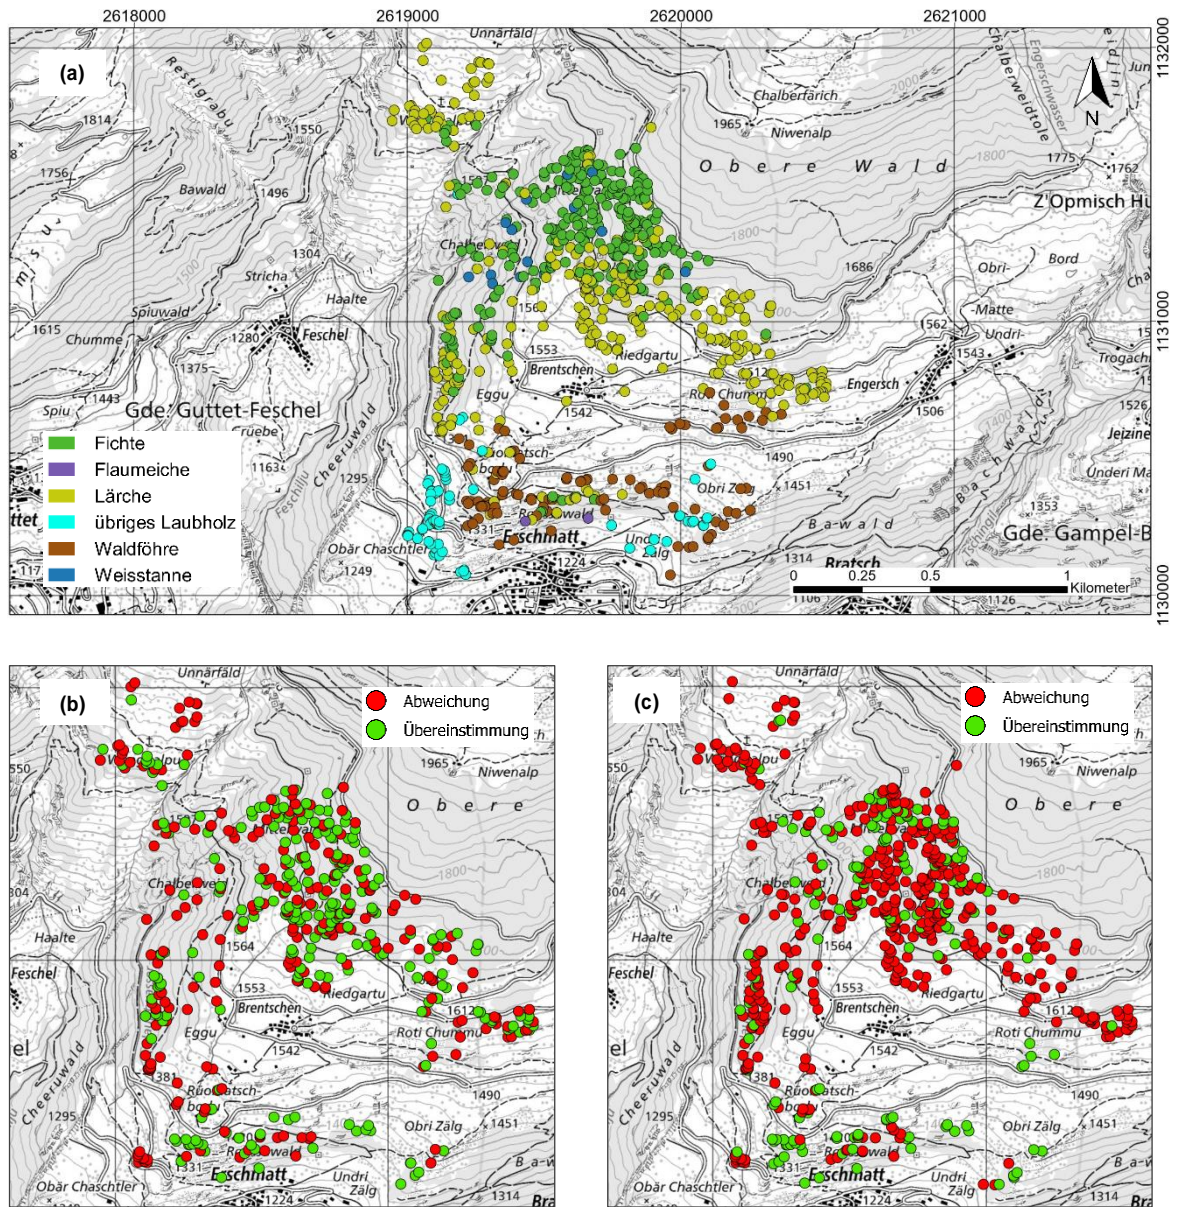
5.4.3 Vergleich räumliche Verteilung mit anderen Publikationen

Im Naturpark Pfyn-Finges wurde 2022 ein Projekt zur Inventarisierung und Schutz der wertvollen Bäume lanciert (Theler, 2022). Dabei wurden diverse Baumarten in einer Felderhebung aufgenommen. Der Projektperimeter liegt oberhalb Erschmatt (Abb. 31). Die Daten sind für die Validierung der Ergebnisse zur Verfügung gestellt worden. Der Datensatz enthält Stichproben von der Fichte, Flaumeiche, Lärche, Waldföhre, Weisstanne und vom übrigen Laubholz (Bergahorn, Birke, Esche, Salweide und Waldkirsche). In der Tabelle 24 sind die Übereinstimmungen mit der objektbasierten und pixelbasierten Baumartenklassifikation ersichtlich.

Tab. 24: Übereinstimmung Baumartenklassifikation mit Inventarisierung Projekt Naturpark Pfyn-Finges

Baumart	Inventar Naturpark Pfyn- Finges	Übereinstimmung mit		Übereinstimmung mit pixelbasierten	
		objektbasierten Bildanalyse	Bildanalyse	Bildanalyse	
		Anzahl	Anteil [%]	Anzahl	Anteil [%]
Fichte	284	112 von 178	63	81 von 259	31
Flaumeiche	2	0 von 1	0	0 von 2	0
Lärche	304	89 von 216	41	23 von 245	9
übriges Laubholz	65	2 von 11	18	1 von 11	9
Waldföhre	97	37 von 56	66	53 von 62	85
Weisstanne	14	0 von 8	0	4 von 12	33
<i>Total</i>	<i>766</i>	<i>240 von 470</i>	<i>51</i>	<i>162 von 591</i>	<i>27</i>

Die untersuchten Flächen beider Studien sind nicht deckungsgleich. Dies wurde bei der Berechnung der prozentualen Übereinstimmung berücksichtigt (Anzahl Übereinstimmungen). Wie in der Tabelle ersichtlich ist, gibt es bei den Ergebnissen der objektbasierten Bildanalyse mit 51 % eine fast doppelt so hohe Übereinstimmung wie bei der pixelbasierten Bildanalyse mit gesamthaft 27 %. Auffällig ist die gute Übereinstimmung mit den Waldföhren verglichen mit beiden Methoden. In der objektbasierten Bildanalyse weist die Fichte ebenfalls gute Resultate auf. Die räumliche Darstellung der Übereinstimmung sieht wie folgt aus (Abb. 31).



(a) Inventarisierung Projekt Naturpark Pfinz-Finges (Theler, 2022) (b) Übereinstimmung mit objektbasierten und (c) pixelbasierten Bildanalyse

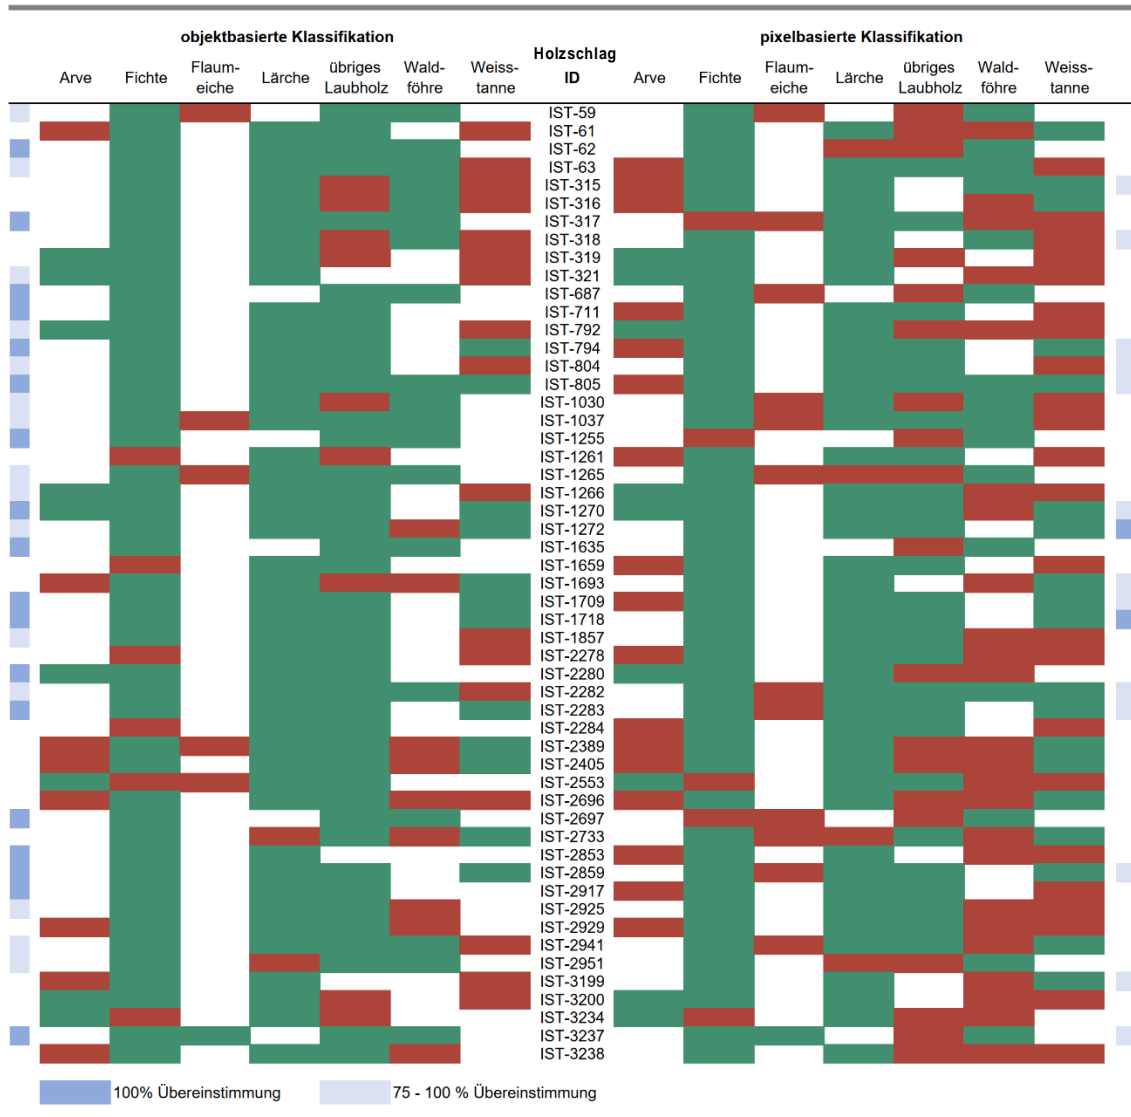
Abb. 31: Vergleich Baumartenklassifikation mit Inventarisierung Projekt Naturpark Pfinz-Finges

Der Kanton Wallis verfügt über ein Waldinformationssystem (WIS VS) in dem seit 2015 alle forstlichen Massnahmen erfasst werden. Für das Studiengebiet stehen in allen vier Testgebieten ausgeführte Holzschläge von den Jahren 2015 bis 2022 zur Verfügung. Vor der Ausführung einer Massnahme wird jeweils vom zuständigen Förster die Baumartenmischung im Wald abgeschätzt. Es liegen 53 Holzschläge mit Informationen über die Baumarten vor. Nach der Ausführung einer Massnahme entspricht die Baumartenmischung nicht mehr mit dem Ausgangszustand überein. Im Vergleich mit den Ergebnissen der vorliegenden Studie können die Informationen jedoch einen Hinweis über die Verbreitung der Arten liefern.

Die Baumartenmischung von den Holzschlägen sind im Anhang E in einer Tabelle mit den Ergebnissen der Bildanalysen gegenübergestellt. Es wurde in einem ersten Schritt analysiert, welche Baumarten übereinstimmen oder nicht vorhergesagt wurden. In einem zweiten Schritt wurden zusätzliche detektierte Baumarten mit einem Anteil von über 4 % als falsch vorhergesagt deklariert. Der prozentuale Anteil der Baumartenmischung ist in der Validation nicht berücksichtigt worden. Trotzdem liegen Holzschläge vor, welche hinsichtlich der prozentualen Mischung mit den Ergebnissen der objektbasierten Bildanalyse sehr gut übereinstimmen. Dies sind insbesondere folgende Holzschläge: IST-62, IST-1709, IST-1718, IST-2280 und IST-2697.

Die Ergebnisse der Gegenüberstellung sind in der Tabelle 25 ersichtlich. Bei der objektbasierten Bildanalyse wurden in 18 von 53 Holzschlägen die gleichen Baumarten vorhergesagt (rund 34 %). Bei der pixelbasierten Bildanalyse stimmen lediglich 2 von 53 Holzschlägen hinsichtlich der Baumarten überein (rund 4 %). Wenn man mit einer Übereinstimmung grösser als 75 % ausgeht, sind es bei der objektbasierten Bildanalyse 33 (rund 62 %) und bei der pixelbasierten Bildanalyse 15 von 53 Holzschlägen (rund 28 %). Daraus geht hervor, dass die Ergebnisse der objektbasierte Bildanalyse im Vergleich mit den Holzschlägen wesentlich besser einzuschätzen sind.

Tab. 25: Vergleich der detektierten Baumarten beider Bildanalysen mit den ausgeführten forstlichen Massnahmen; in grün die richtig vorhergesagten und in rot die falsch oder nicht vorhergesagten Baumarten



In der Abbildung 32 ist die Verteilung der korrekt vorhergesagten Baumarten mit einer Übereinstimmung von mehr als 75 % ersichtlich. Es ist erkennbar, dass die objektbasierte Bildanalyse in allen Testgebieten übereinstimmende Baumarten detektiert hat. Insbesondere auf der Westseite im Testgebiet 2 und mehrheitlich der Flächen im Testgebiet 3 wurden die Baumarten zufriedenstellend detektiert. Die pixelbasierte Bildanalyse stimmt lediglich in den Testgebieten 2 und 3 mit Holzschlägen überein. Mit der objektbasierten Bildanalyse konnten im Vergleich mit den Holzschlägen in allen Testgebieten bessere Ergebnisse generiert werden als mit der pixelbasierten Bildanalyse.

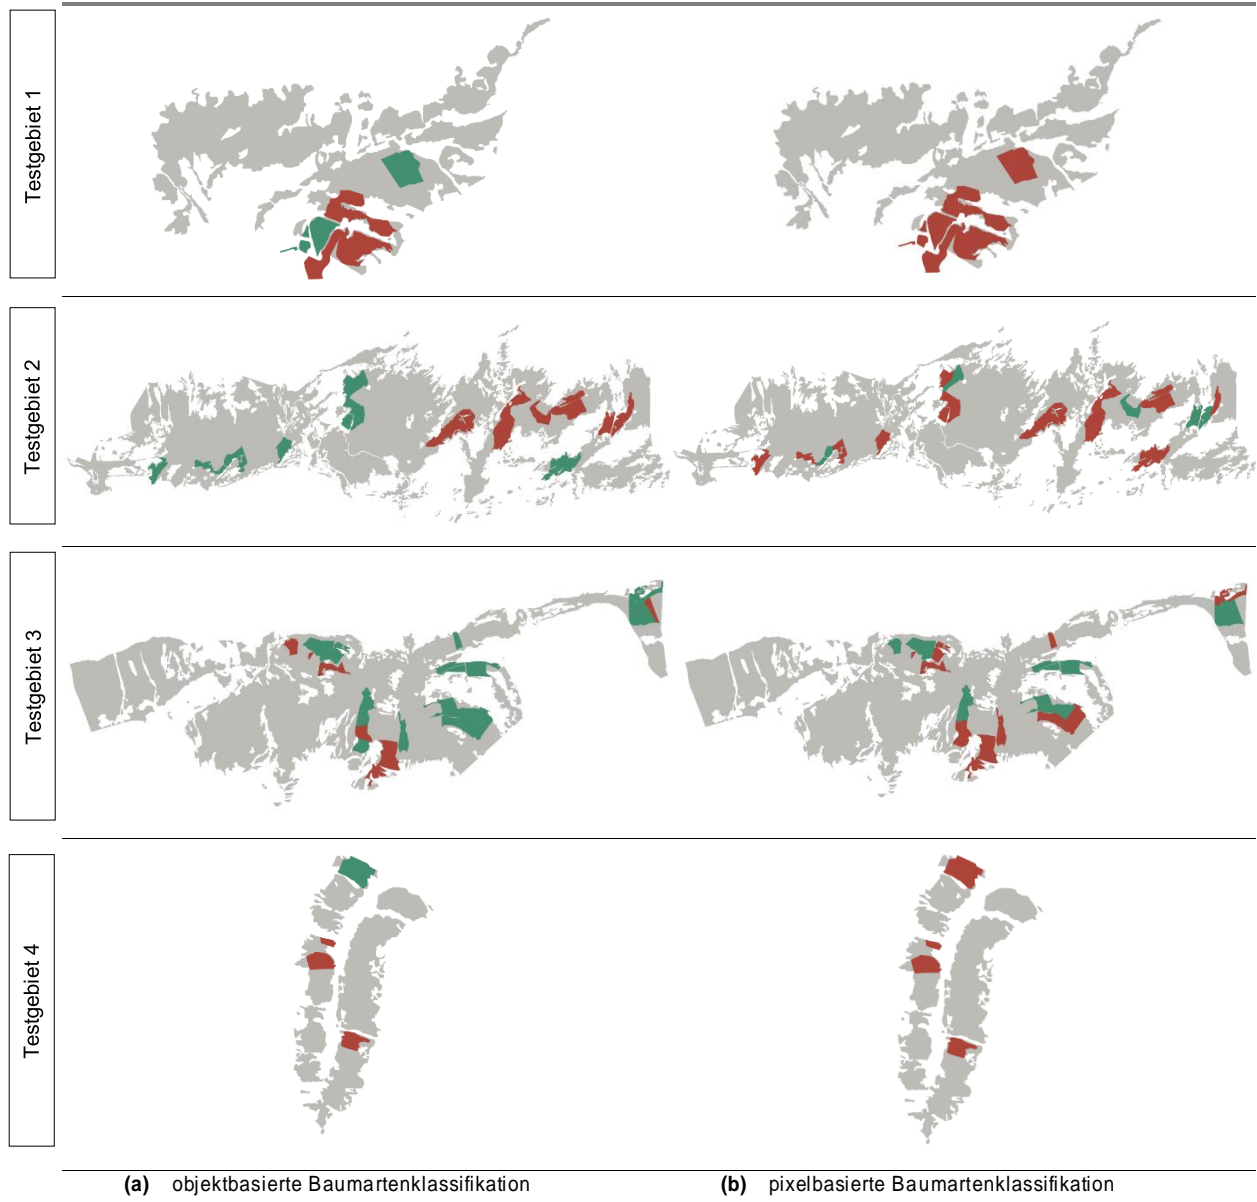


Abb. 32: Räumliche Verteilung der Übereinstimmung von mehr als 75 % mit forstlichen Massnahmen

5.5 Handlungsempfehlung (O4)

Aufgrund der höheren Gesamtgenauigkeit ist für die Ausscheidung des Ist-Zustandes die Ergebnisse der pixelbasierten Bildanalyse verwendet worden. Obwohl mit beiden Bildanalyse ähnliche Genauigkeiten erzielt wurden, gibt es Unterschiede in der Baumartenmischung. Der Vergleich der räumlichen Verteilung mit den anderen Publikationen hat gezeigt, dass es wahrscheinlich besser gewesen wäre die Ergebnisse der objektbasierten Bildanalyse für die Herleitung der Handlungsempfehlung zu verwenden.

Mit der vorgestellten Methodik konnten Wälder mit zukunftsfähigen Baumarten analysiert und Bestände mit einem Handlungsbedarf lokalisiert werden. Die Methodik basiert einerseits auf einer gutachterlichen Bestandausscheidung, welche andererseits mit einem vereinfachten Verfahren mit den Informationen aus der Tree App erweitert wurde.

Aus der Analyse geht hervor, dass insbesondere bei einem starken Klimawandel in allen Testgebieten grossflächig keine zukunftsfähigen Baumarten vorkommen (77 - 92% der Fläche). Im Vergleich mit einem mässigen Klimawandel gibt es grösstenteils im Testgebiet 1 und im Testgebiet 2 in den unteren Lagen noch viele überlebensfähige Wälder. Die meisten Arvenwälder müssen aufgrund der Veränderung des Klimas zugunsten der Fichte umgebaut werden. Bei den Fichtenwäldern spielt v.a. der Wechsel der subalpinen zur collinen Höhenstufe bei einem mässigen wie auch starkem Klimawandel eine bedeutende Rolle. In den betroffenen Wäldern werden in Zukunft nur noch Laubholzarten überlebensfähig sein. Bei den Föhrenwäldern besteht Handlungsbedarf, wenn bei einem starken Klimawandel die hochmontane zur collinen Höhenstufe wird. In diesen Wäldern wird die dominante Baumart die Flaumeiche sein.

6 Schlussfolgerungen

Mit der objektbasierten Bildanalyse konnte mithilfe multispektralen Luftbildstreifen die Baumartenzusammensetzung auf Stufe Baum mit einer Gesamtgenauigkeit von 83 % bestimmt werden. Die Baumarten wurden im Modell unterschiedlich genau vorhergesagt. Am besten wurde die Flaumeiche (90 %) detektiert, gefolgt von der Arve (89 %) und der Waldföhre (89 %). Die Lärche (72 %), die Fichte (80 %), das übrige Laubholz (82 %) und die Weisstanne (83 %) weisen Genauigkeiten unter 85 % auf. In den Testgebieten kam es am häufigsten zu einer Verwechslung von der Lärche mit der Fichte. Mit dem *Support Vector Machine* Algorithmus wurden bessere Ergebnisse erzeugt als mit dem *Random Forest* Algorithmus. Insgesamt wurde die Klassifikation mit 10 verschiedenen Variablen durchgeführt. Das Modell konnte mit der Information über die Vegetationshöhe (+5 Prozentpunkte) und den Nadelholzanteil (+4 Prozentpunkte) am wirksamsten verbessert werden. Innerhalb dieser Variablen sind insbesondere zwischen den Laub- und Nadelholzarten deutliche Abweichungen erkennbar. Hinsichtlich der spektralen Auflösung ist die Unterscheidung der Baumarten im Bereich des Nahinfrarots am deutlichsten. Dabei weisen die Laubholzarten höhere Reflexionswerte auf als die Nadelholzarten. In Anbetracht der spektralen Variablen (NDVI und HSV) konnte das Modell nur geringfügig verbessert werden. Um das Modell zu optimieren hätten weitere Vegetationsindizes oder Beziehungen mit den Grundlagedaten berechnet werden müssen.

Mit der pixelbasierten Bildanalyse ist mithilfe Sentinel-Satellitenbilder die Baumartenzusammensetzung auf Stufe Bestand mit einer Gesamtgenauigkeit von 84 % bestimmt worden. Wie bei der objektbasierten Bildanalyse gibt es unterschiedliche Ergebnisse zwischen den Baumarten. Das übrige Laubholz (99 %) weist die höchste Genauigkeit auf. Die Flaumeiche (97 %) und die Waldföhre (90 %) weisen ebenfalls Genauigkeiten über 85 % auf. Die Lärche (72 %), die Fichte (73 %), die Weisstanne (77 %) und die Arve (81 %) liegen unter der Vorgabe von 85 %. In der Klassifikation wurde die Lärche mit der Arve und die Fichte mit der Weisstanne am meisten verwechselt. Anfänglich konnte mit dem *Random Forest* bessere Ergebnisse als mit dem *Support Vector Machine* Algorithmus erzielt werden. Mit Zunahme der Anzahl Variablen resultierten mit beiden Algorithmen gleich hohe Gesamtgenauigkeiten. Das Endergebnis der pixelbasierten Bildanalyse wurde mittels *Random Forest* berechnet, weil die Genauigkeiten der einzelnen Baumarten besser ausfielen. Insgesamt sind 44 Variablen berücksichtigt worden. Die Ergebnisse konnten mit weiteren zwei Bildszenen vom gleichen Jahr (+5 Prozentpunkte), den Informationen über den Nadelholzanteil (+5 Prozentpunkte) sowie von der Farbmodellkonvertierung (RGB in HSV) (+5 Prozentpunkte) am deutlichsten verbessert werden. Die Integration der Bänder im *Vegetation Red Edge* und kurzwelligen Infrarotlicht-Bereichs (+3 Prozentpunkte) konnten das Modell weiter optimieren. Bezüglich der spektralen Auflösung der Sentinel-Daten können die Baumarten besonders ab 740 nm in den Bereichen *Vegetation Red Edge*, Nahinfrarot und kurzwelligen Infrarot differenziert werden. Obwohl die Sentinel-Daten in diesem Bereich mehrheitlich nur in einer räumlichen Auflösung von 20 m verfügbar sind, sind sie für die Klassifizierung von Baumarten entscheidend. Neben weiterer Vegetationsindizes könnte das Modell mit zusätzlichen

Bildszenen verbessert werden. Dabei müssten allenfalls die Satellitenbilder mittels einer Co-Registrierung aufeinander abgestimmt werden.

Im Vergleich beider Bildanalysen konnte mit der pixelbasierten Bildanalyse mit 84 % eine höhere Gesamtgenauigkeit erzielt werden. Mit der objektbasierten Bildanalyse sind bei der Arve, der Fichte und der Weisstanne höhere Genauigkeiten erreicht worden. Mit der pixelbasierten Bildanalyse liegen dagegen bessere Ergebnisse bei der Flaumeiche, der Waldföhre und beim übrigen Laubholz vor. Die Genauigkeit der Vorhersage der Lärche ist mit 72 % in beiden Bildanalysen am tiefsten. Im Vergleich mit anderen Publikationen können ebenfalls Probleme bei der Detektion der Lärche festgestellt werden. Andererseits gibt es auch Studien, welche gute Ergebnisse für die Lärche erzielt haben. Mittels mehr Variablen und einer *Feature* Reduzierung könnten möglicherweise bessere Ergebnisse für die Lärche berechnet werden. Obwohl mit beiden Bildanalysen ähnliche Gesamtgenauigkeiten erreicht wurden ist die räumliche Verteilung der Baumarten unterschiedlich. Die pixelbasierte Bildanalyse detektierte mehr Weisstannen und Arven. Die objektbasierte Bildanalyse hat dagegen mehr Fichten, Lärchen, Waldföhren und übriges Laubholz vorhergesagt. Die grössten Differenzen liegen zwischen den Ergebnissen der Weisstanne und der Fichte. Hinsichtlich der räumlichen Verteilung kann festgestellt werden, dass die objektbasierte Klassifizierung mit anderen Publikationen wesentlich besser übereinstimmt (Vergleich mit einer Inventarisierung und ausgeführten forstlichen Massnahmen).

Aufgrund der höheren Gesamtgenauigkeit wurde der Ist-Zustand für die Handlungsempfehlung mit den Ergebnissen der pixelbasierten Bildanalyse erstellt. Aufgrund der besseren Übereinstimmung mit anderen Publikationen wäre es wahrscheinlich besser gewesen die Ergebnisse der objektbasierten Bildanalyse zu verwenden. Mit der gutachterlichen Analyse wurden 62 % Fichten-, 21 % Föhren- und 17 % Arvenwälder ausgeschieden. Durch die Differenz vom Ist-Zustand mit den Modelldaten konnte berechnet werden, dass bei einem mässigen Klimawandel rund 1'476 ha (34 %) und bei einem starken Klimawandel 3'686 ha (85 %) der Waldfläche umgebaut werden müssten. Zwischen den Testgebieten gibt es Abweichungen zum Mittelwert. Im Testgebiet 1 müssen bei einem mässigen Klimawandel nur 4 % und bei einem starken Klimawandel 77 % der Fläche umgebaut werden. Im Testgebiet 4 ist der Unterschied zwischen den Klimaszenarien weniger ausgeprägt. Beim mässigen Klimawandel liegt der Flächenanteil bei 80 % und beim starken Klimawandel bei 86 %. Bei einem starken Klimawandel kommen in den Testgebieten grösstenteils keine zukunftsfähige Baumarten vor. Bei einem mässigen Klimawandel gibt es im Testgebiet 1 und 2 in den unteren Lagen noch viele überlebensfähige Wälder. Die meisten Arvenwälder müssten zugunsten der Fichte umgebaut werden. In Fichtenwälder müssen beim Wechsel der subalpinen zur collinen Höhenstufe Laubholzarten gefördert werden. Bei einem starken Klimawandel in Föhrenwälder müssen beim Wechsel der hochmontanen zur collinen Höhenstufe Flaumeichen begünstigt werden.

Gesamthaft gesehen konnten mit den schwierigen Verhältnissen hinsichtlich der Topografie und der hohen Strukturierung der Wälder (vertikal und horizontal) mit beiden Methoden relativ gute Ergebnisse erzielt werden. Das Ergebnis der pixelbasierten Bildanalyse weist gesamthaft eine höhere Genauigkeit gegenüber der objektbasierten Bildanalyse auf. Dies könnte neben den drei verwendeten Bildszenen durch die zusätzlichen spektralen Informationen im Bereich des *Vegetation Red Edge* und kurzwelligen Infrarots (*SWIR*) begründet werden. Ebenfalls wurden Trainingsdaten eingesetzt, welche ein grösseres Gebiet abdecken und so mehr standörtliche Unterschiede repräsentieren. Im Vergleich mit anderen Publikationen stimmt die räumliche Verteilung der Baumarten jedoch schlecht überein. Im Zusammenhang der vielen erklärenden Variablen könnte dies auf eine Überanpassung an die Trainingsdaten hindeuten. Dem könnte mit einer Methode zur *Feature* Reduzierung entgegengewirkt werden. Für grossflächige Analysen auf Bestandes-Niveau sind Sentinel-Satellitenbilder hinsichtlich der Verfügbarkeit, der Informationsdichte und der besseren Performance in der Datenbearbeitung gegenüber kostenpflichtigen multispektralen Luftbildern klar im Vorteil. Für die Bestimmung von Baumarten werden deshalb diese Grundlagen künftig von grossem Interesse sein.

7 Literaturverzeichnis

- Adelabu, S., Mutanga, O., Adam, E. & Cho, M. A. (2013) „Exploiting machine learning algorithms for tree species classification in a semiarid woodland using RapidEye image“, *Journal of Applied Remote Sensing*, Vol. 7, No. 1, S. 73480.
- Axelsson, A., Lindberg, E. & Olsson, H. (2018) „Exploring Multispectral ALS Data for Tree Species Classification“, *Remote Sensing*, Vol. 10, No. 3, S. 183.
- Axelsson, A., Lindberg, E., Reese, H. & Olsson, H. (2021) „Tree species classification using Sentinel-2 imagery and Bayesian inference“, *International Journal of Applied Earth Observation and Geoinformation*, Vol. 100, S. 102318.
- Blaschke, T. (2010) „Object based image analysis for remote sensing“, *ISPRS Journal of Photogrammetry and Remote Sensing*, Vol. 65, No. 1, S. 2–16.
- Choi, K., Lim, W., Chang, B., Jeong, J., Kim, I., Park, C.-R. & Ko, D. W. (2022) „An automatic approach for tree species detection and profile estimation of urban street trees using deep learning and Google street view images“, *ISPRS Journal of Photogrammetry and Remote Sensing*, Vol. 190, S. 165–180.
- Da Gomes Silva, P., Beck, A.-L., Martinez Sanchez, J., Medina Santanmaria, R., Jones, M. & Taji, A. (2020) „Advances on coastal erosion assessment from satellite earth observations: exploring the use of Sentinel products along with very high resolution sensors“, in Bonora, L., Carboni, D. & Vincenzi, M. de (Hg.) *Eighth International Symposium "Monitoring of Mediterranean Coastal Areas. Problems and Measurement Techniques"*, Florence, Firenze University Press, S. 412–421.
- Dorren, L., Dumollard, G., Erbach, A., Horneber, H., Kurt, M., May, D., Rosset, C., Schaller, C., Ginzler, C., Fischer, C., Waser, L., Weber, D. & Bebi, P. (2021) *FINT-CH (Find Individual Trees Schweiz): Grossflächige Erfassung von Waldstrukturen und Kennzahlen mittels Waldstrukturabgrenzung und Einzelbaumdetektion basierend auf luftgestützten Fernerkundungsdaten*.
- European Space Agency (2015) *Sentinel-2 User Handbook*.
- Fassnacht, F. E., Latifi, H., Stereńczak, K., Modzelewska, A., Lefsky, M., Waser, L. T., Straub, C. & Ghosh, A. (2016) „Review of studies on tree species classification from remotely sensed data“, *Remote Sensing of Environment*, Vol. 186, S. 64–87.
- Frehner, M., Brang, P., Kaufmann, G. & Küchli, C. (2018) *Standortkundliche Grundlagen für die Waldbewirtschaftung im Klimawandel*. WSL Ber. 66 [Online]. Verfügbar unter www.wsl.ch/berichte.
- Frehner, M., Wasser, B. & Schwitter, R. (2005) *Nachhaltigkeit und Erfolgskontrolle im Schutzwald: Wegleitung für Pflegemassnahmen in Wäldern mit Schutzfunktion*.
- Freudenberg, M., Magdon, P. & Nölke, N. (2022) „Individual tree crown delineation in high-resolution remote sensing images based on U-Net“, *Neural Computing and Applications*, Vol. 34, No. 24, S. 22197–22207.
- Ginzler, C. (2018) *Vegetation Height Model NFI*.
- Guo, Y., Zhang, H., Li, Q., Lin, Y. & Michalski, J. (2022) „New morphological features for urban tree species identification using LiDAR point clouds“, *Urban Forestry & Urban Greening*, Vol. 71, S. 127558.


- Hughes, G. (1968) „On the mean accuracy of statistical pattern recognizers“, *IEEE Transactions on Information Theory*, Vol. 14, No. 1, S. 55–63.
- Immitzer, M., Atzberger, C. & Koukal, T. (2012) „Tree Species Classification with Random Forest Using Very High Spatial Resolution 8-Band WorldView-2 Satellite Data“, *Remote Sensing*, Vol. 4, No. 9, S. 2661–2693.
- Immitzer, M., Neuwirth, M., Böck, S., Brenner, H., Vuolo, F. & Atzberger, C. (2019) „Optimal Input Features for Tree Species Classification in Central Europe Based on Multi-Temporal Sentinel-2 Data“, *Remote Sensing*, Vol. 11, No. 22, S. 2599.
- Immitzer, M., Vuolo, F. & Atzberger, C. (2016) „First Experience with Sentinel-2 Data for Crop and Tree Species Classifications in Central Europe“, *Remote Sensing*, Vol. 8, No. 3, S. 166.
- Jamal, J., Zaki, N. A. M., Talib, N., Saad, N. M., Mokhtar, E. S., Omar, H., Latif, Z. A. & Suratman, M. N. (2022) „Dominant Tree Species Classification using Remote Sensing Data and Object -Based Image Analysis“, *IOP Conference Series: Earth and Environmental Science*, Vol. 1019, No. 1, S. 12018.
- Javaheri, S. H., Sepehri, M. M. & Teimourpour, B. (2014) „Response Modeling in Direct Marketing“, in *Data Mining Applications with R*, Elsevier, S. 153–180.
- Ke, Y. & Quackenbush, L. J. (2011) „A review of methods for automatic individual tree -crown detection and delineation from passive remote sensing“, *International Journal of Remote Sensing*, Vol. 32, No. 17, S. 4725–4747.
- Li, H., Hu, B., Li, Q. & Jing, L. (2021) „CNN-Based Individual Tree Species Classification Using High-Resolution Satellite Imagery and Airborne LiDAR Data“, *Forests*, Vol. 12, No. 12, S. 1697.
- Liu, B., Huang, H., Su, Y., Chen, S., Li, Z., Chen, E. & Tian, X. (2022) „Tree Species Classification Using Ground-Based LiDAR Data by Various Point Cloud Deep Learning Methods“, *Remote Sensing*, Vol. 14, No. 22, S. 5733.
- Ma, M., Liu, J., Liu, M., Zeng, J. & Li, Y. (2021) „Tree Species Classification Based on Sentinel-2 Imagery and Random Forest Classifier in the Eastern Regions of the Qilian Mountains“, *Forests*, Vol. 12, No. 12, S. 1736.
- Mallinis, G., Koutsias, N., Tsakiri-Strati, M. & Karteris, M. (2008) „Object-based classification using Quickbird imagery for delineating forest vegetation polygons in a Mediterranean test site“, *ISPRS Journal of Photogrammetry and Remote Sensing*, Vol. 63, No. 2, S. 237–250.
- Maschler, J., Atzberger, C. & Immitzer, M. (2018) „Individual Tree Crown Segmentation and Classification of 13 Tree Species Using Airborne Hyperspectral Data“, *Remote Sensing*, Vol. 10, No. 8, S. 1218.
- McHugh, M. L. (2012) „Interrater reliability: the kappa statistic“, *Biochemia medica*, Vol. 22, No. 3, S. 276–282.
- Miyoshi, G. T., Arruda, M. d. S., Osco, L. P., Marcato Junior, J., Gonçalves, D. N., Imai, N. N., Tommaselli, A. M. G., Honkavaara, E. & Gonçalves, W. N. (2020) „A Novel Deep Learning Method to Identify Single Tree Species in UAV-Based Hyperspectral Images“, *Remote Sensing*, Vol. 12, No. 8, S. 1294.
- Nguyen, H. M., Demir, B. & Dalponte, M. (2019) „A Weighted SVM-Based Approach to Tree Species Classification at Individual Tree Crown Level Using LiDAR Data“, *Remote Sensing*, Vol. 11, No. 24, S. 2948.
- Qian, C., Yao, C., Ma, H., Xu, J. & Wang, J. (2023) „Tree Species Classification Using Airborne LiDAR Data Based on Individual Tree Segmentation and Shape Fitting“, *Remote Sensing*, Vol. 15, No. 2, S. 406.

- Qin, H., Zhou, W., Yao, Y. & Wang, W. (2022) „Individual tree segmentation and tree species classification in subtropical broadleaf forests using UAV-based LiDAR, hyperspectral, and ultrahigh-resolution RGB data“, *Remote Sensing of Environment*, Vol. 280, S. 113143.
- Raczko, E. & Zagajewski, B. (2017) „Comparison of support vector machine, random forest and neural network classifiers for tree species classification on airborne hyperspectral APEX images“, *European Journal of Remote Sensing*, Vol. 50, No. 1, S. 144–154.
- Sàrl, L. (2011) *Nachhaltigkeit und Erfolgskontrolle im Schutzwald: Umsetzung für den Kanton Wallis*.
- Schiefer, F., Kattenborn, T., Frick, A., Frey, J., Schall, P., Koch, B. & Schmidlein, S. (2020) „Mapping forest tree species in high resolution UAV-based RGB-imagery by means of convolutional neural networks“, *ISPRS Journal of Photogrammetry and Remote Sensing*, Vol. 170, S. 205–215.
- Shang, X. & Chisholm, L. A. (2014) „Classification of Australian Native Forest Species Using Hyperspectral Remote Sensing and Machine-Learning Classification Algorithms“, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, Vol. 7, No. 6, S. 2481–2489.
- Shojanoori, R., Shafri, H. Z. M., Mansor, S. & Ismail, M. H. (2018) „Generic rule-sets for automated detection of urban tree species from very high-resolution satellite data“, *Geocarto International*, Vol. 33, No. 4, S. 357–374.
- Tarekegn, A. N., Giacobini, M. & Michalak, K. (2021) „A review of methods for imbalanced multi-label classification“, *Pattern Recognition*, Vol. 118, S. 107965.
- Theiler, A. (2022) *Inventar wertvoller Bäume im Naturpark Pfyn-Finges: Bericht Pilotphase*.
- United States Geological Survey (1976): *A Land Use and Land Cover Classification System for Use with Remote Sensor Data*, Washington: United States Government Printing Office.
- Waser, L., Ginzler, C. & Rehus, N. (2017) „Wall-to-Wall Tree Type Mapping from Countrywide Airborne Remote Sensing Surveys“, *Remote Sensing*, Vol. 9, No. 8, S. 766.
- Waser, L. T., Ginzler, C., Kuechler, M., Baltsavias, E. & Hurni, L. (2011) „Semi-automatic classification of tree species in different forest ecosystems by spectral and geometric variables derived from Airborne Digital Sensor (ADS40) and RC30 data“, *Remote Sensing of Environment*, Vol. 115, No. 1, S. 76–85.
- Wessel, M., Brandmeier, M. & Tiede, D. (2018) „Evaluation of Different Machine Learning Algorithms for Scalable Classification of Tree Types and Tree Species Based on Sentinel-2 Data“, *Remote Sensing*, Vol. 10, No. 9, S. 1419.
- Yu, X., Hyyppä, J., Litkey, P., Kaartinen, H., Vastaranta, M. & Holopainen, M. (2017) „Single-Sensor Solution to Tree Species Classification Using Multispectral Airborne Laser Scanning“, *Remote Sensing*, Vol. 9, No. 2, S. 108.

Anhang A


Baumartenkartierung

Trainingsgebiet 1: Hewald




Waldfläche: ~1.5 ha
Holzvorrat: 299 m³/ha
Stammzahl: 301 Stämme/ha
Mittlere Baumhöhe: 16 m
Maximaler BHD: 39 cm
Bestandesmerkmale:
 locker, stufiger Fichten-Bestand, gemischt mit
 Lärche, Bäume mit teils Kronen bis zum Boden

Quelle forstliche Bestandesdaten: FINT-CH




Trainingsgebiet 2: Teelwald

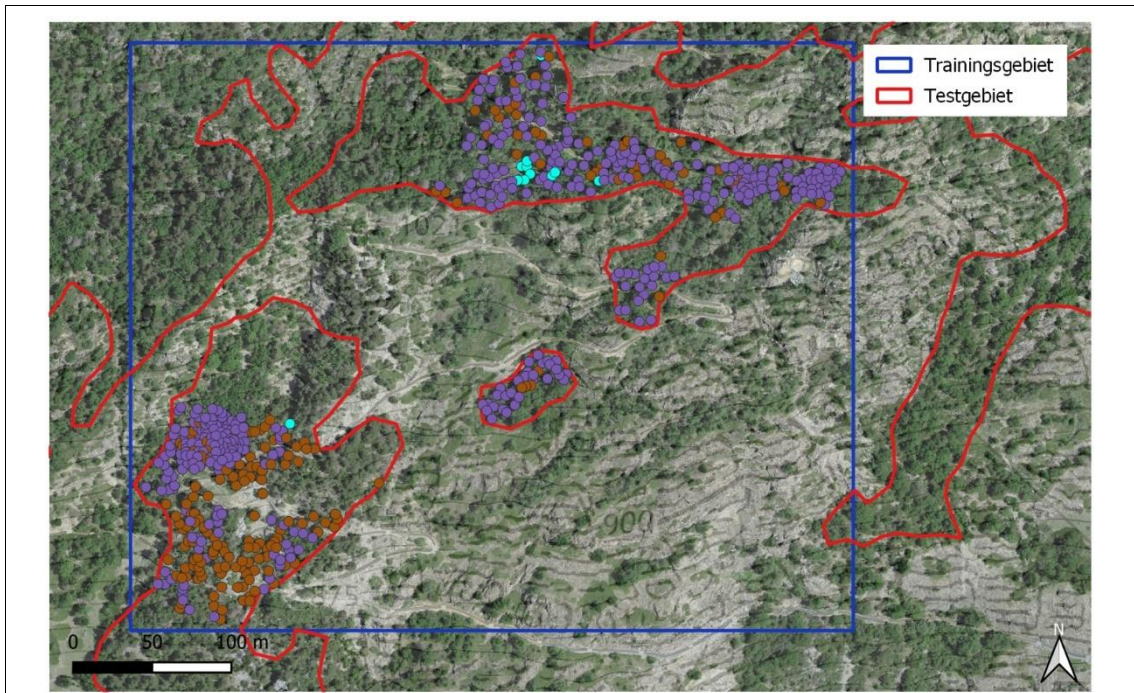


Waldfläche: ~2.4 ha
Holzvorrat: 348 m³/ha
Stammzahl: 402 Stämme/ha
Mittlere Baumhöhe: 13 m
Maximaler BHD: 34 cm
Bestandesmerkmale:
 lichter Waldföhren-Bestand mit geringer Mischung
 anderer Baumarten

Quelle forstliche Bestandesdaten: FINT-CH





Trainingsgebiet 3: Jeizibärg

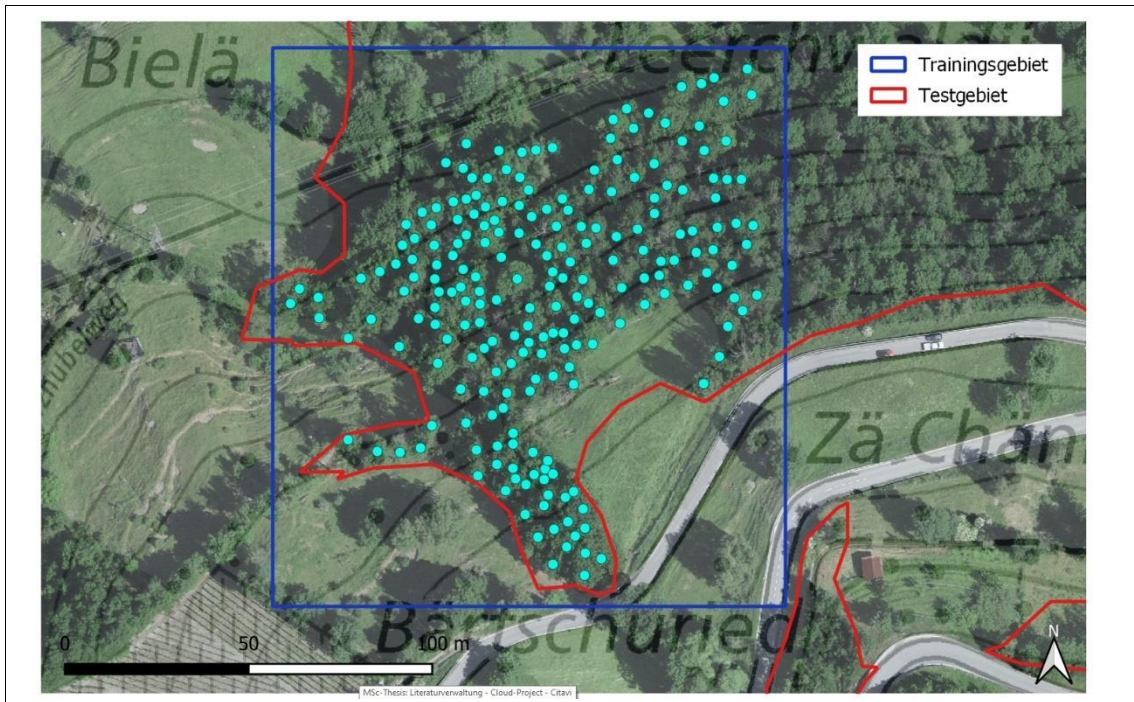


Waldfläche: ~2.7 ha
Holzvorrat: 197 m³/ha
Stammzahl: 320 Stämme/ha
Mittlere Baumhöhe: 7 m
Maximaler BHD: 22 cm
Bestandesmerkmale:
 lockerer, niederer Flaumeichenwald gemischt mit
 Waldföhre


Quelle forstliche Bestandesdaten: FINT-CH



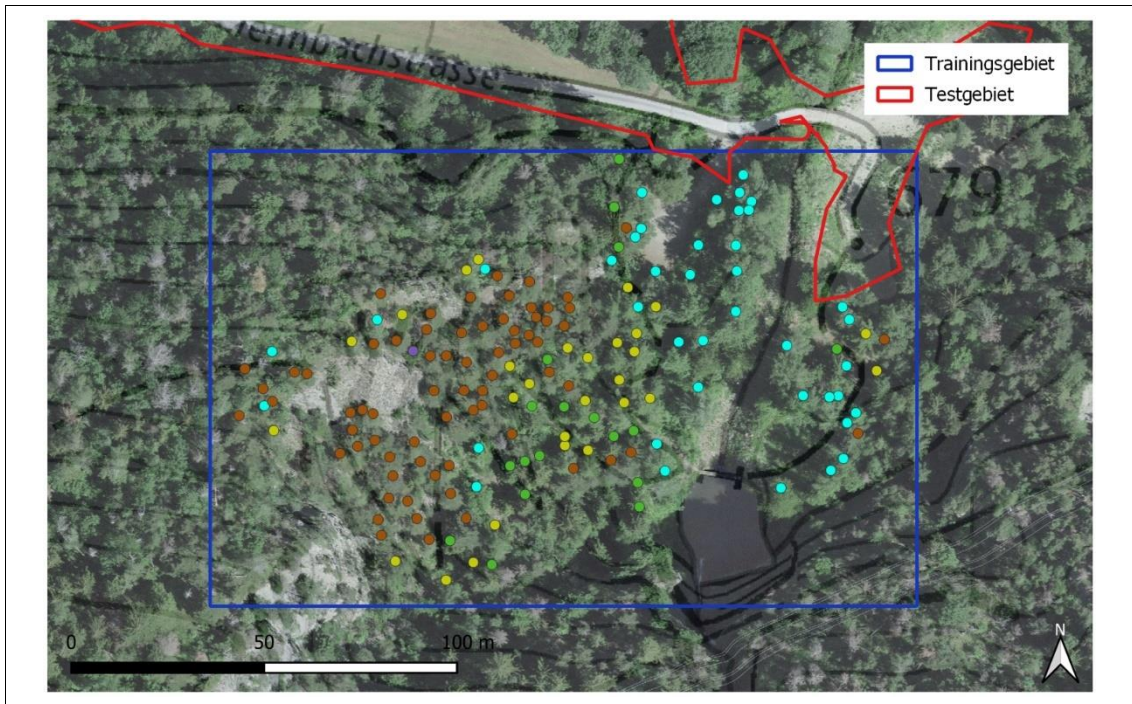
Trainingsgebiet 4: Chrizhubil



Waldfläche: ~1.1 ha
Holzvorrat: 242 m³/ha
Stammzahl: 392 Stämme/ha
Mittlere Baumhöhe: 12 m
Maximaler BHD: 31 cm
Bestandesmerkmale:
 reiner Laubmischwald mit mehrheitlich Esche (*Fraxinus excelsior*), gemischt mit Kirsche (*Prunus avium*), Berg-Ahorn (*Acer pseudoplatanus*) und Grau-Erle (*Alnus incana*)
 Quelle forstliche Bestandesdaten: FINT-CH




Trainingsgebiet 5: Tennen




Waldfläche: ~1.3 ha
Holzvorrat: 270 m³/ha
Stammzahl: 321 Stämme/ha
Mittlere Baumhöhe: 14 m
Maximaler BHD: 39 cm
Bestandesmerkmale:
 durchmischter teils lockerer (auf Kuppe), teils dichter Wald (Graben), Waldföhre dominierend

Quelle forstliche Bestandesdaten: FINT-CH




Trainingsgebiet 6: Tähholz

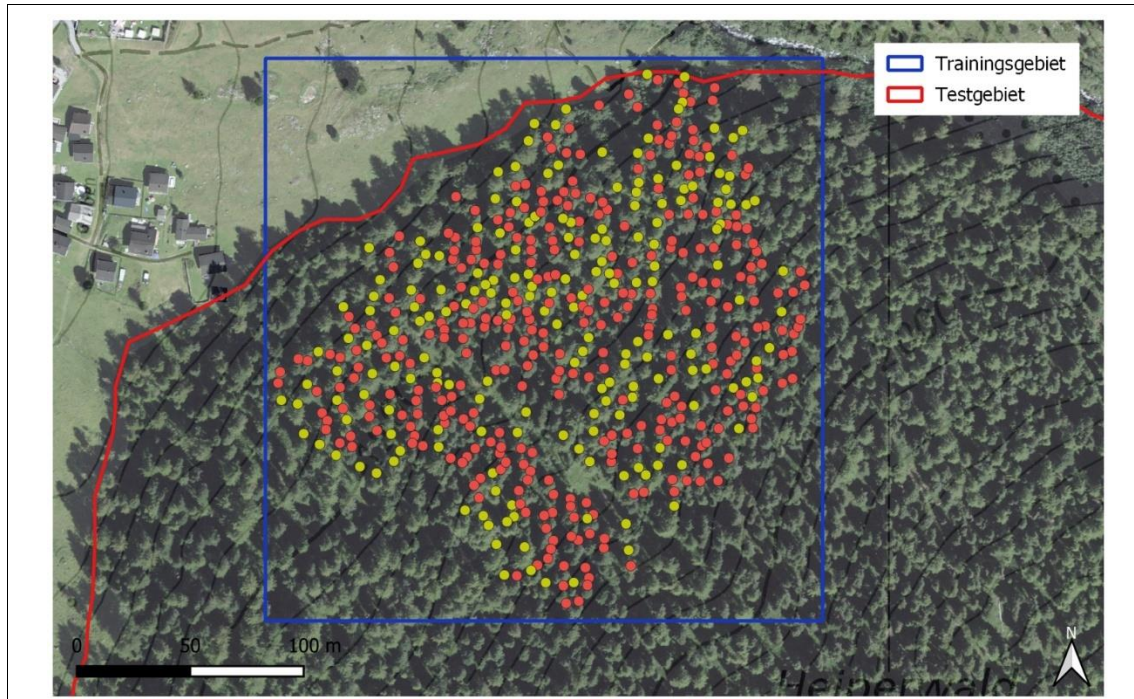


Waldfläche: ~6.5 ha
Holzvorrat: 460 m³/ha
Stammzahl: 505 Stämme/ha
Mittlere Baumhöhe: 20 m
Maximaler BHD: 55 cm
Bestandesmerkmale:
 stufiger Plenterwald, Weisstannen in Rotten,
 gemischt mit Fichte und Lärche

Quelle forstliche Bestandesdaten: FINT-CH




Trainingsgebiet 7: Gruben



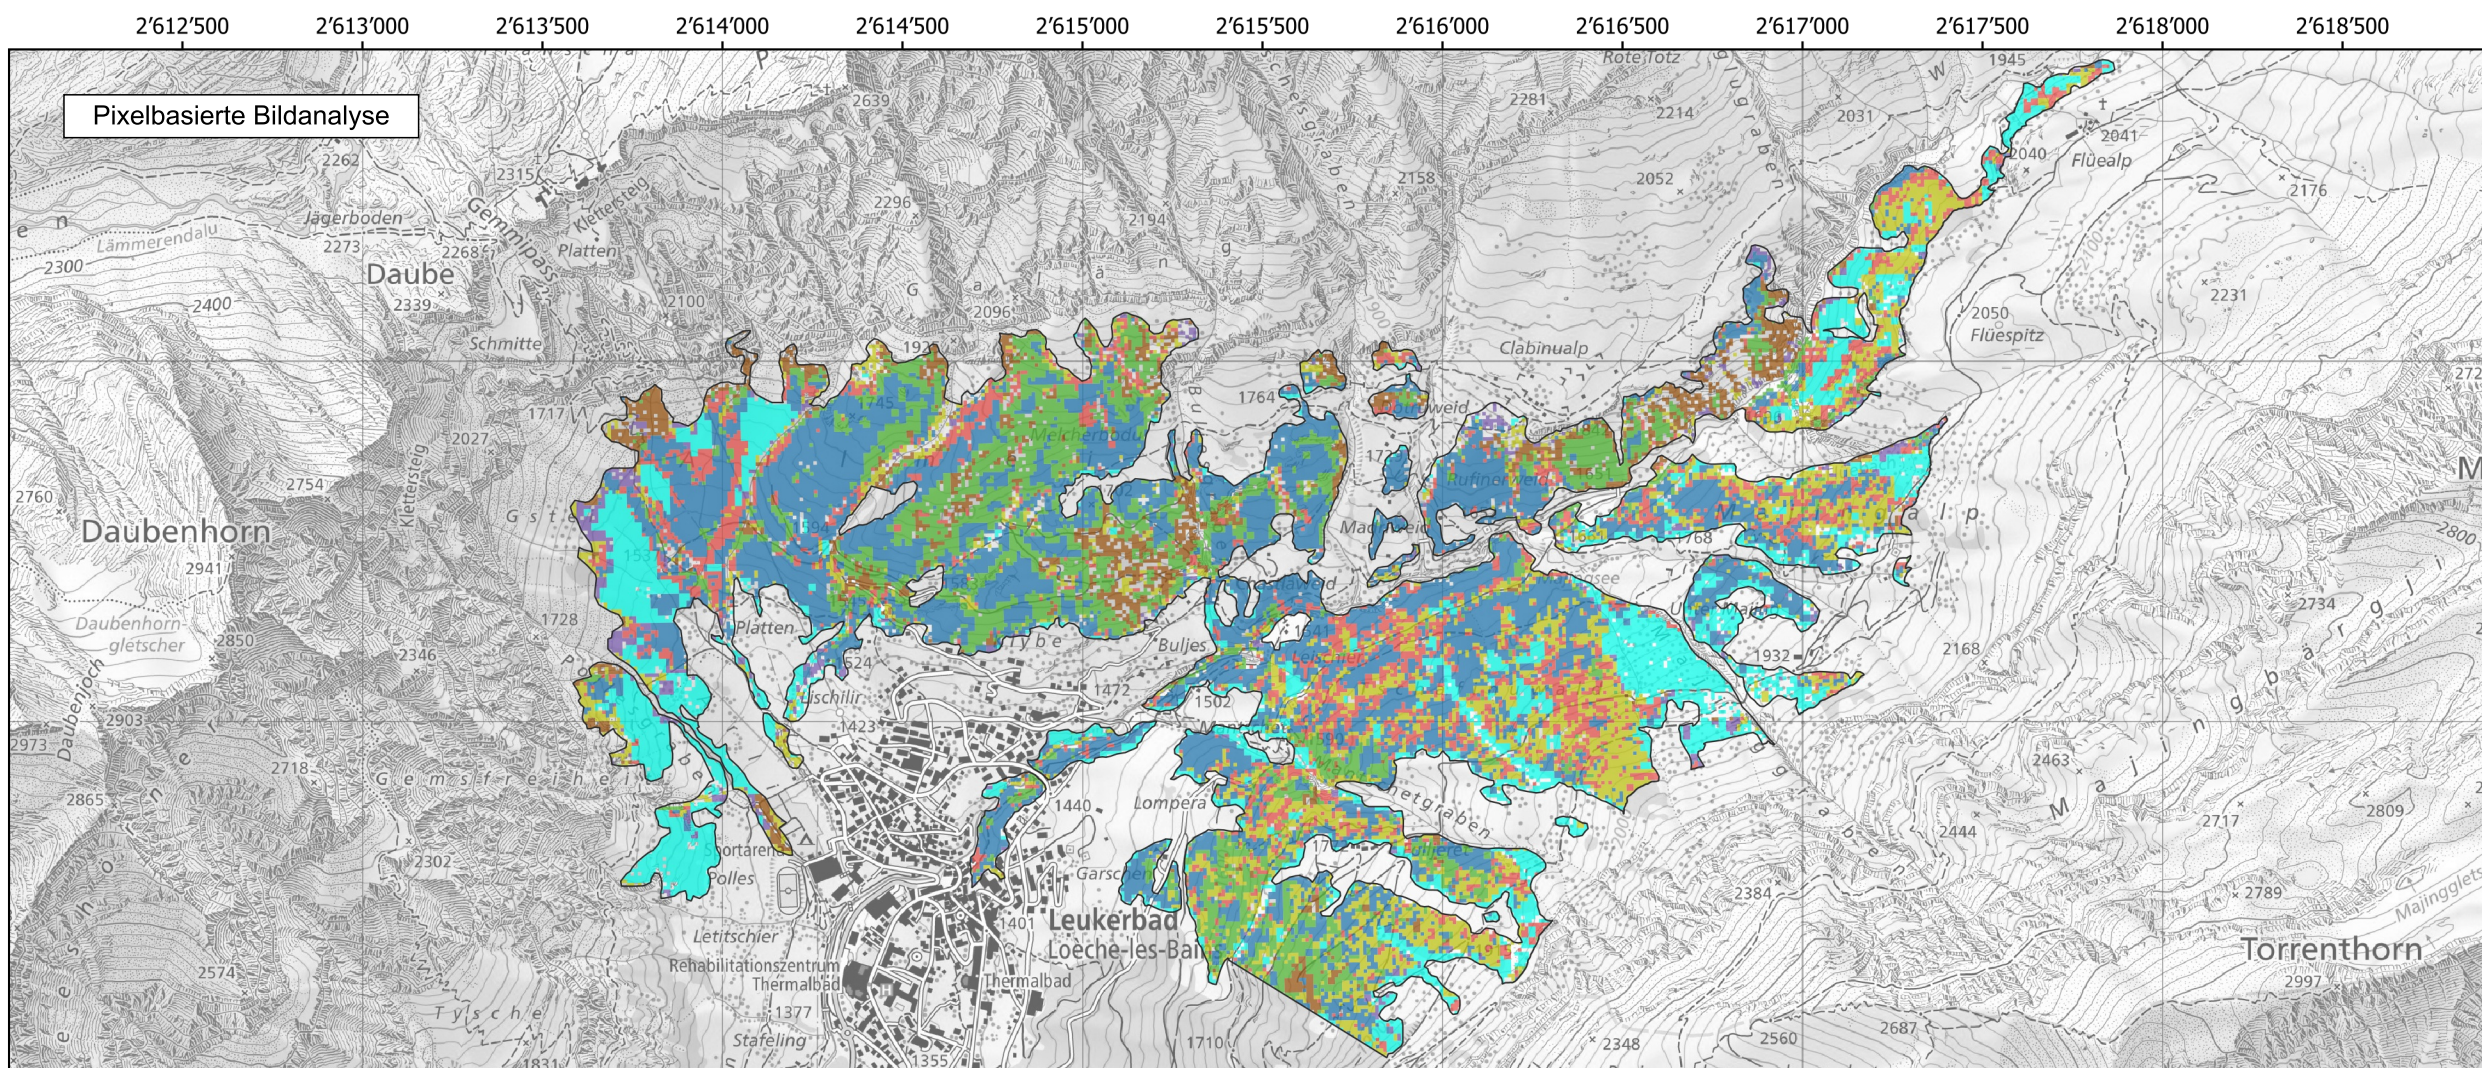
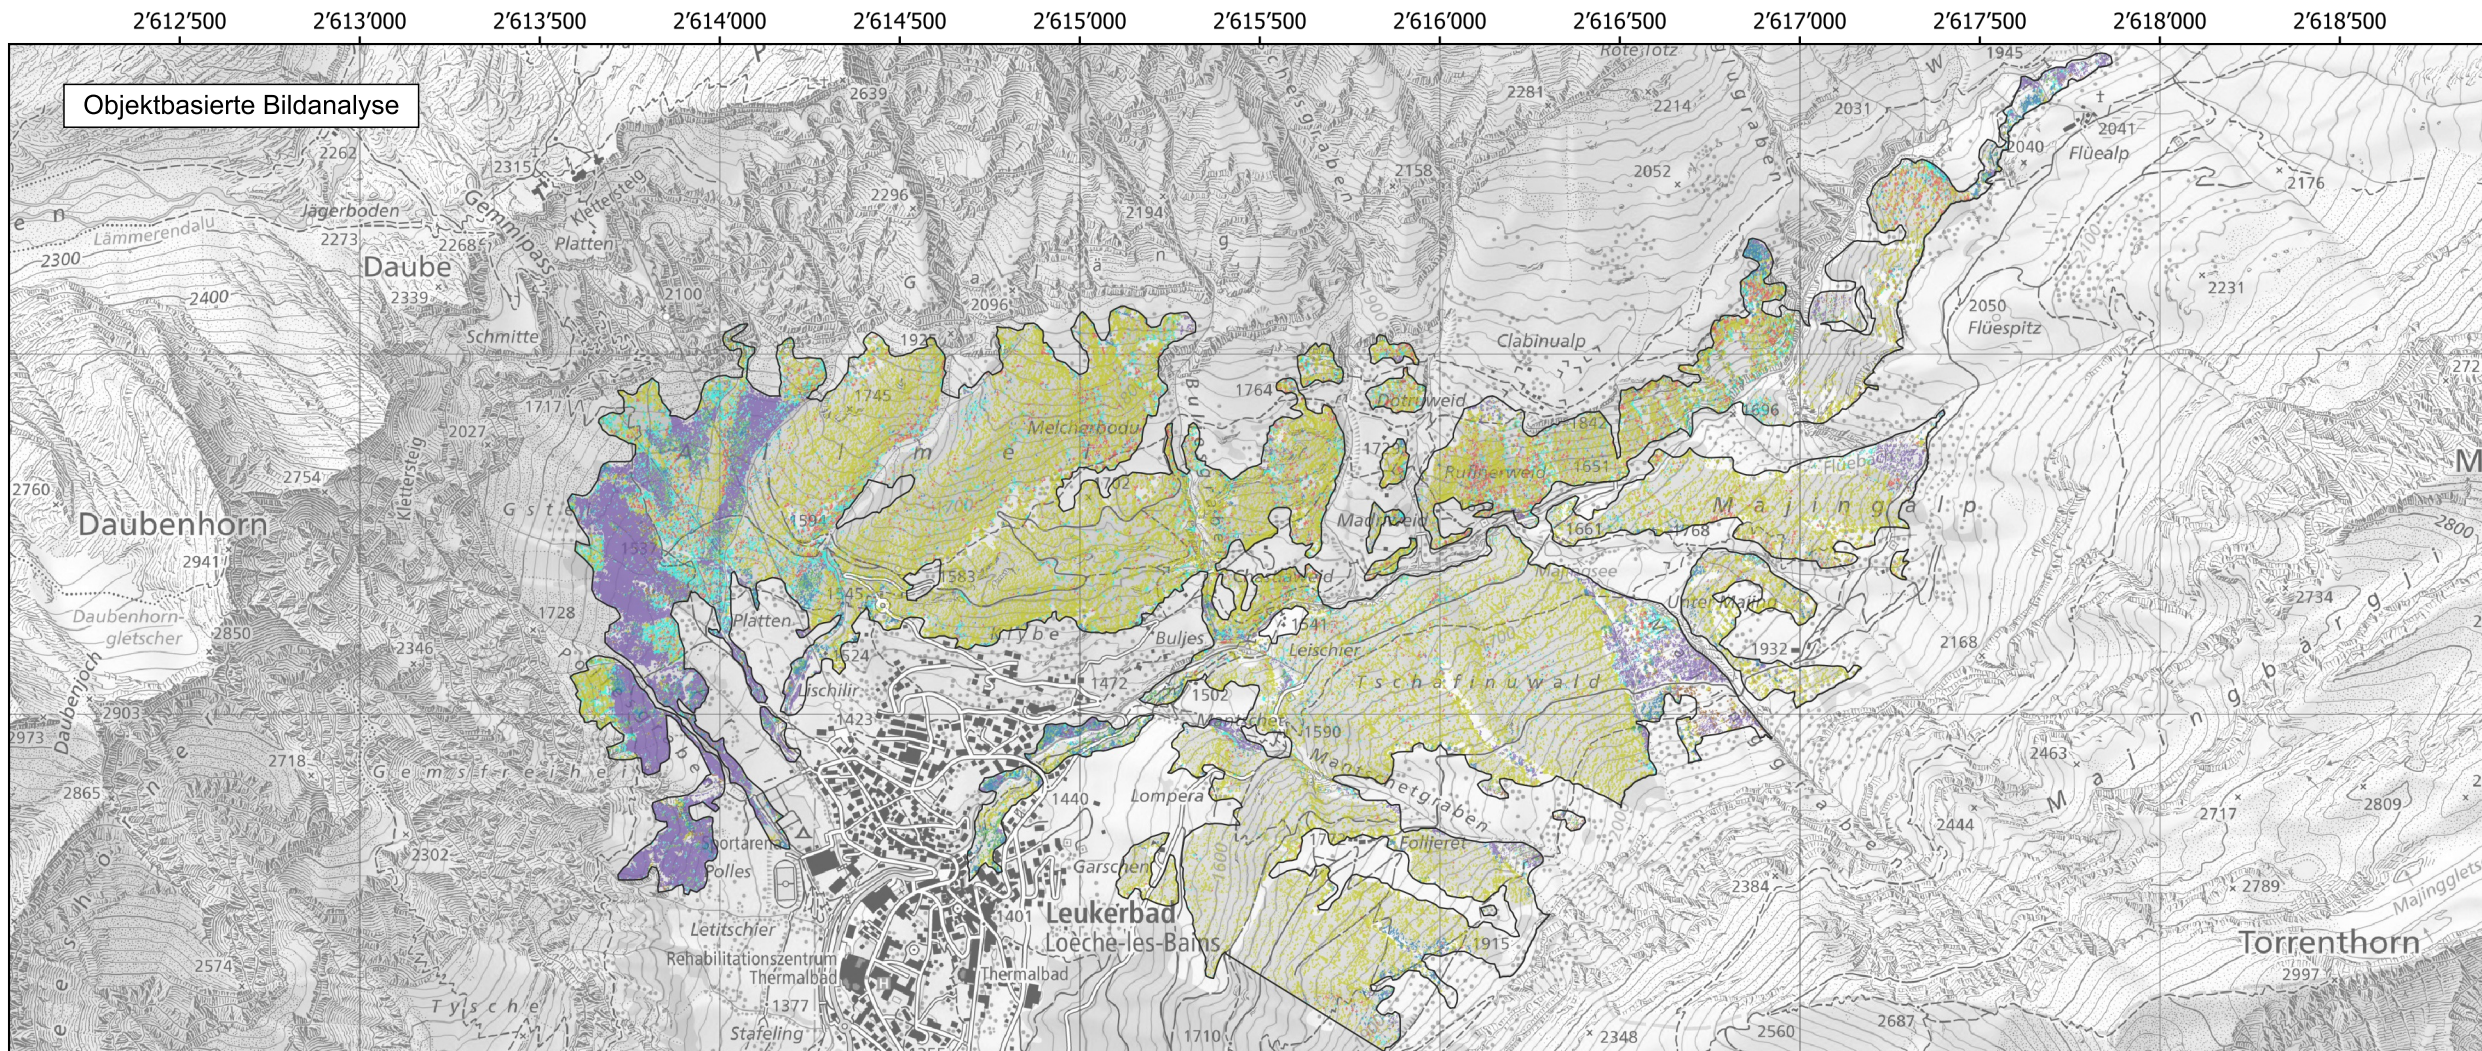
Waldfläche: ~3.7 ha
Holzvorrat: 405 m³/ha
Stammzahl: 417 Stämme/ha
Mittlere Baumhöhe: 17 m
Maximaler BHD: 41 cm
Bestandesmerkmale:
 stufiger Arvenwald, gemischt mit Lärche,
 mehrheitlich lange Kronen

Quelle forstliche Bestandesdaten: FINT-CH



Anhang B

Objekt- und pixelbasierte Baumartenklassifikation



Anhang B.1

Objekt- und pixelbasierte
Baumartenklassifikation

Testgebiet 1

Baumart

- Arve
- Fichte
- Flaumeiche
- Lärche
- übriges Laubholz
- Waldföhre
- Weisstanne

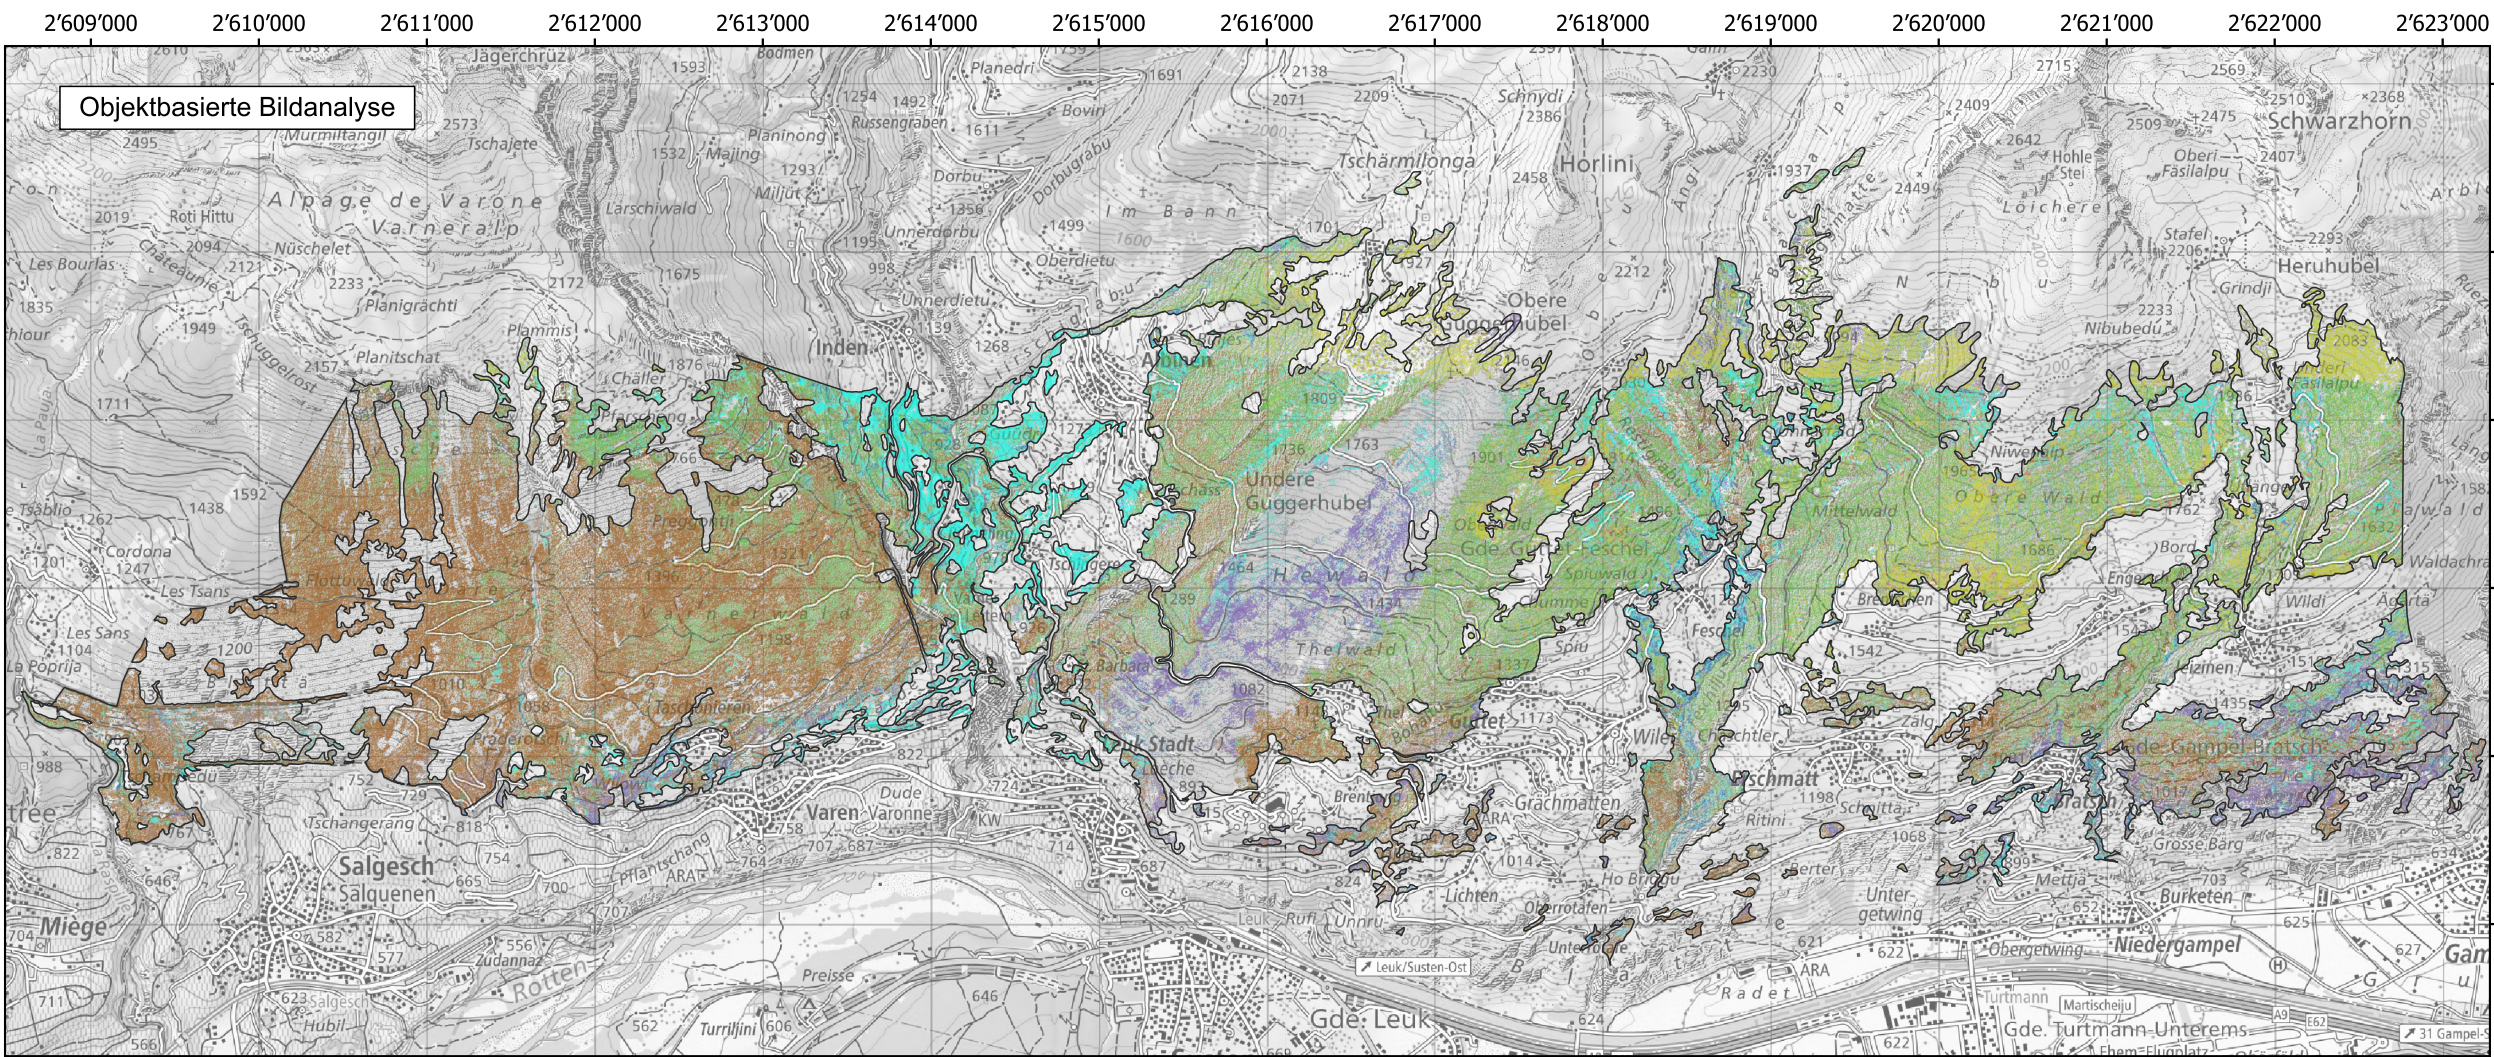
Grenze Testgebiet



Geodatenquellen:
© swisstopo

Masstab 1:21'000

gezeichnet	Datum	Planformat
Mario Werlen	31.08.2023	A3



Objektbasierte Bildanalyse

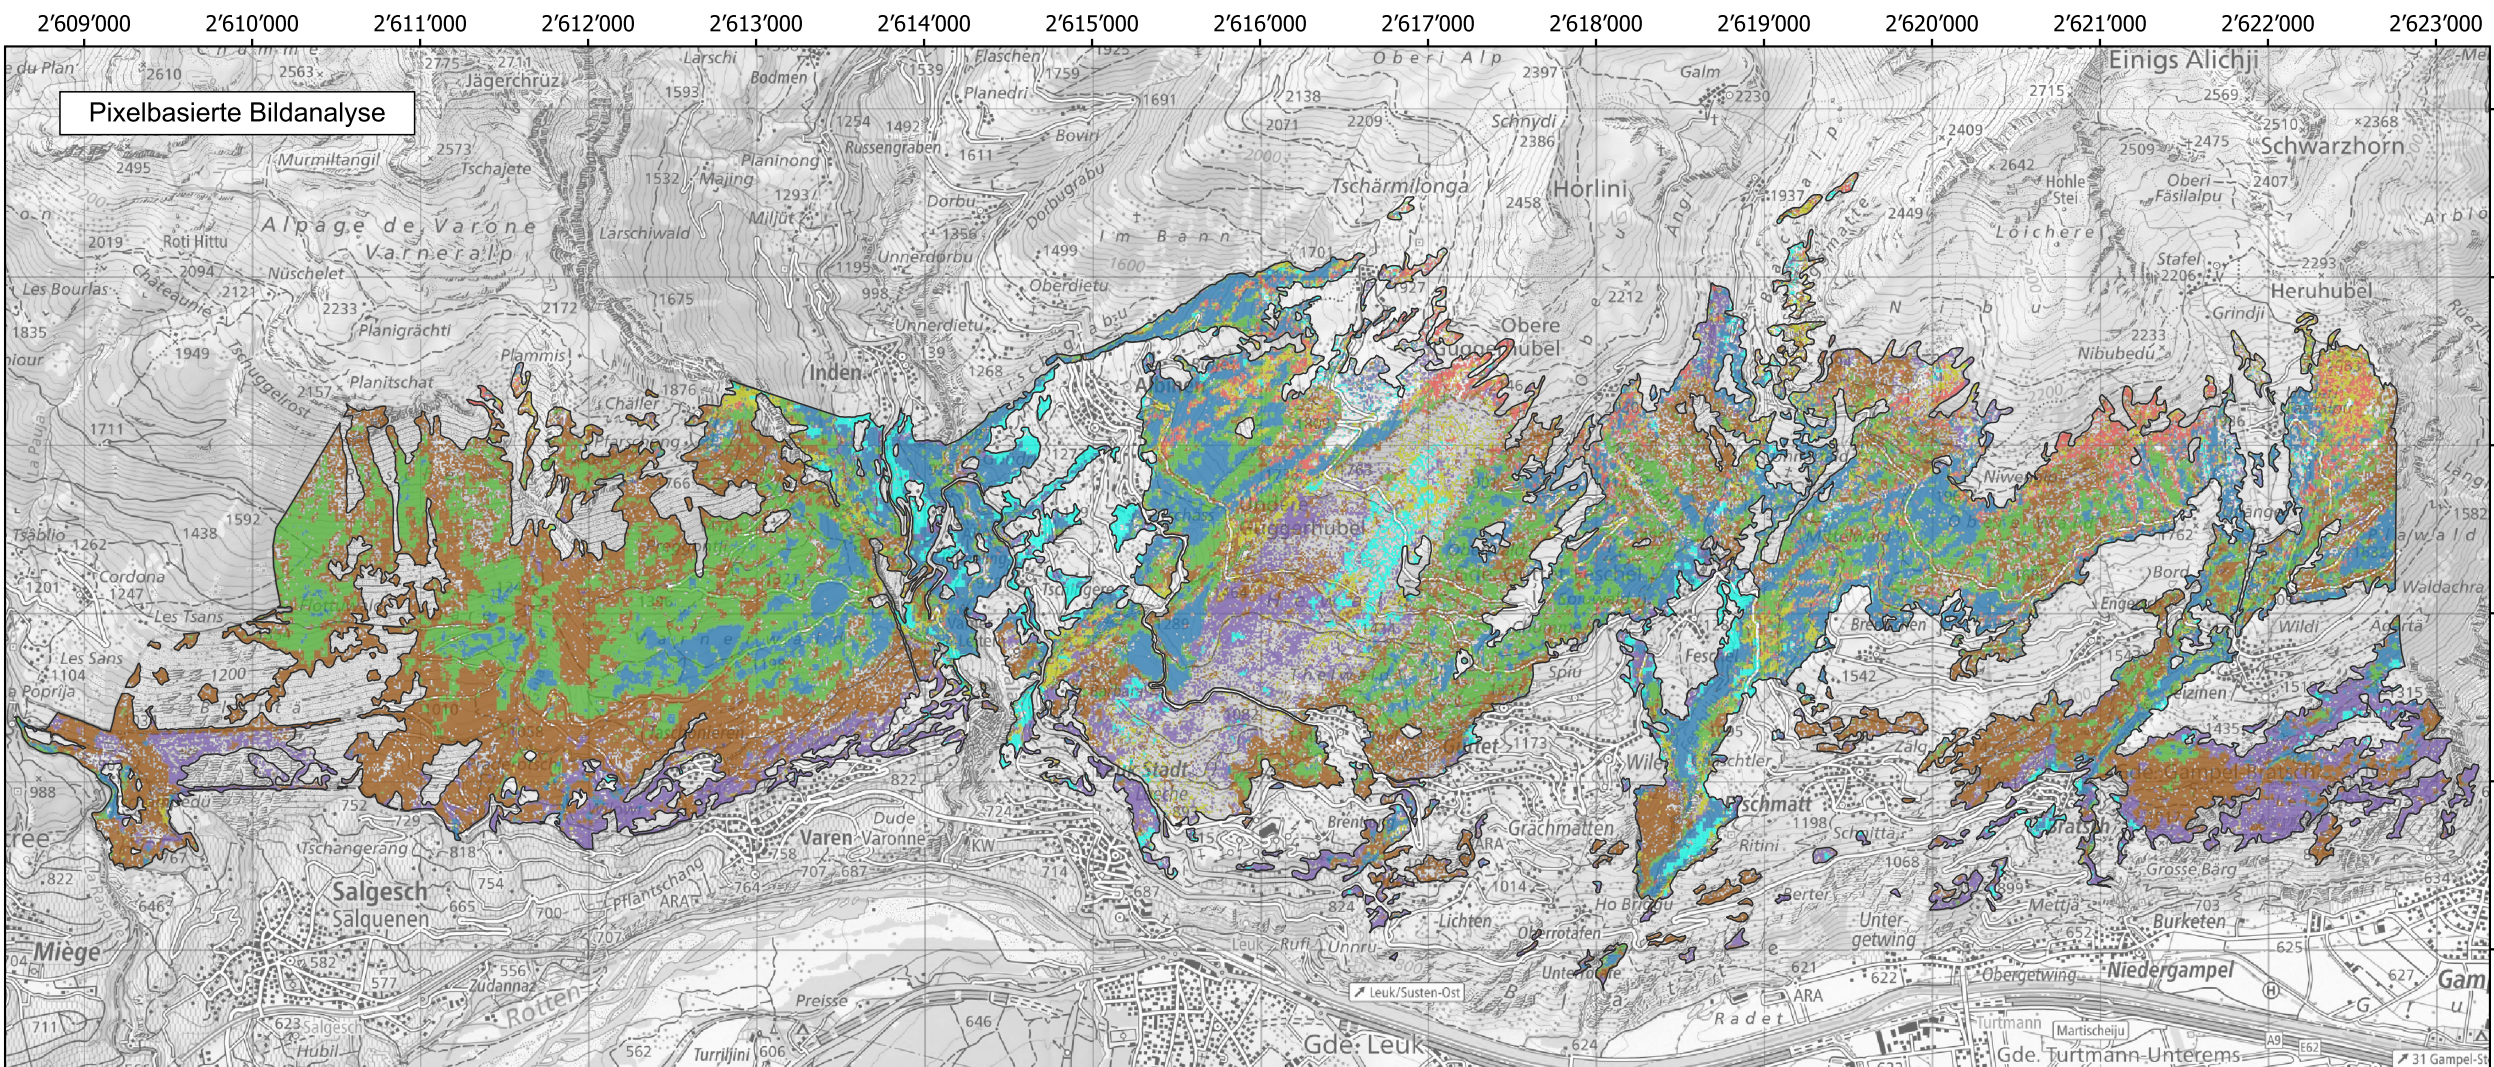
Anhang B.2

Objekt- und pixelbasierte Baumartenklassifikation

Testgebiet 2

- Baumart**
- Arve
 - Fichte
 - Flaumeiche
 - Lärche
 - übriges Laubholz
 - Waldföhre
 - Weisstanne

- Grenze Testgebiet**
-

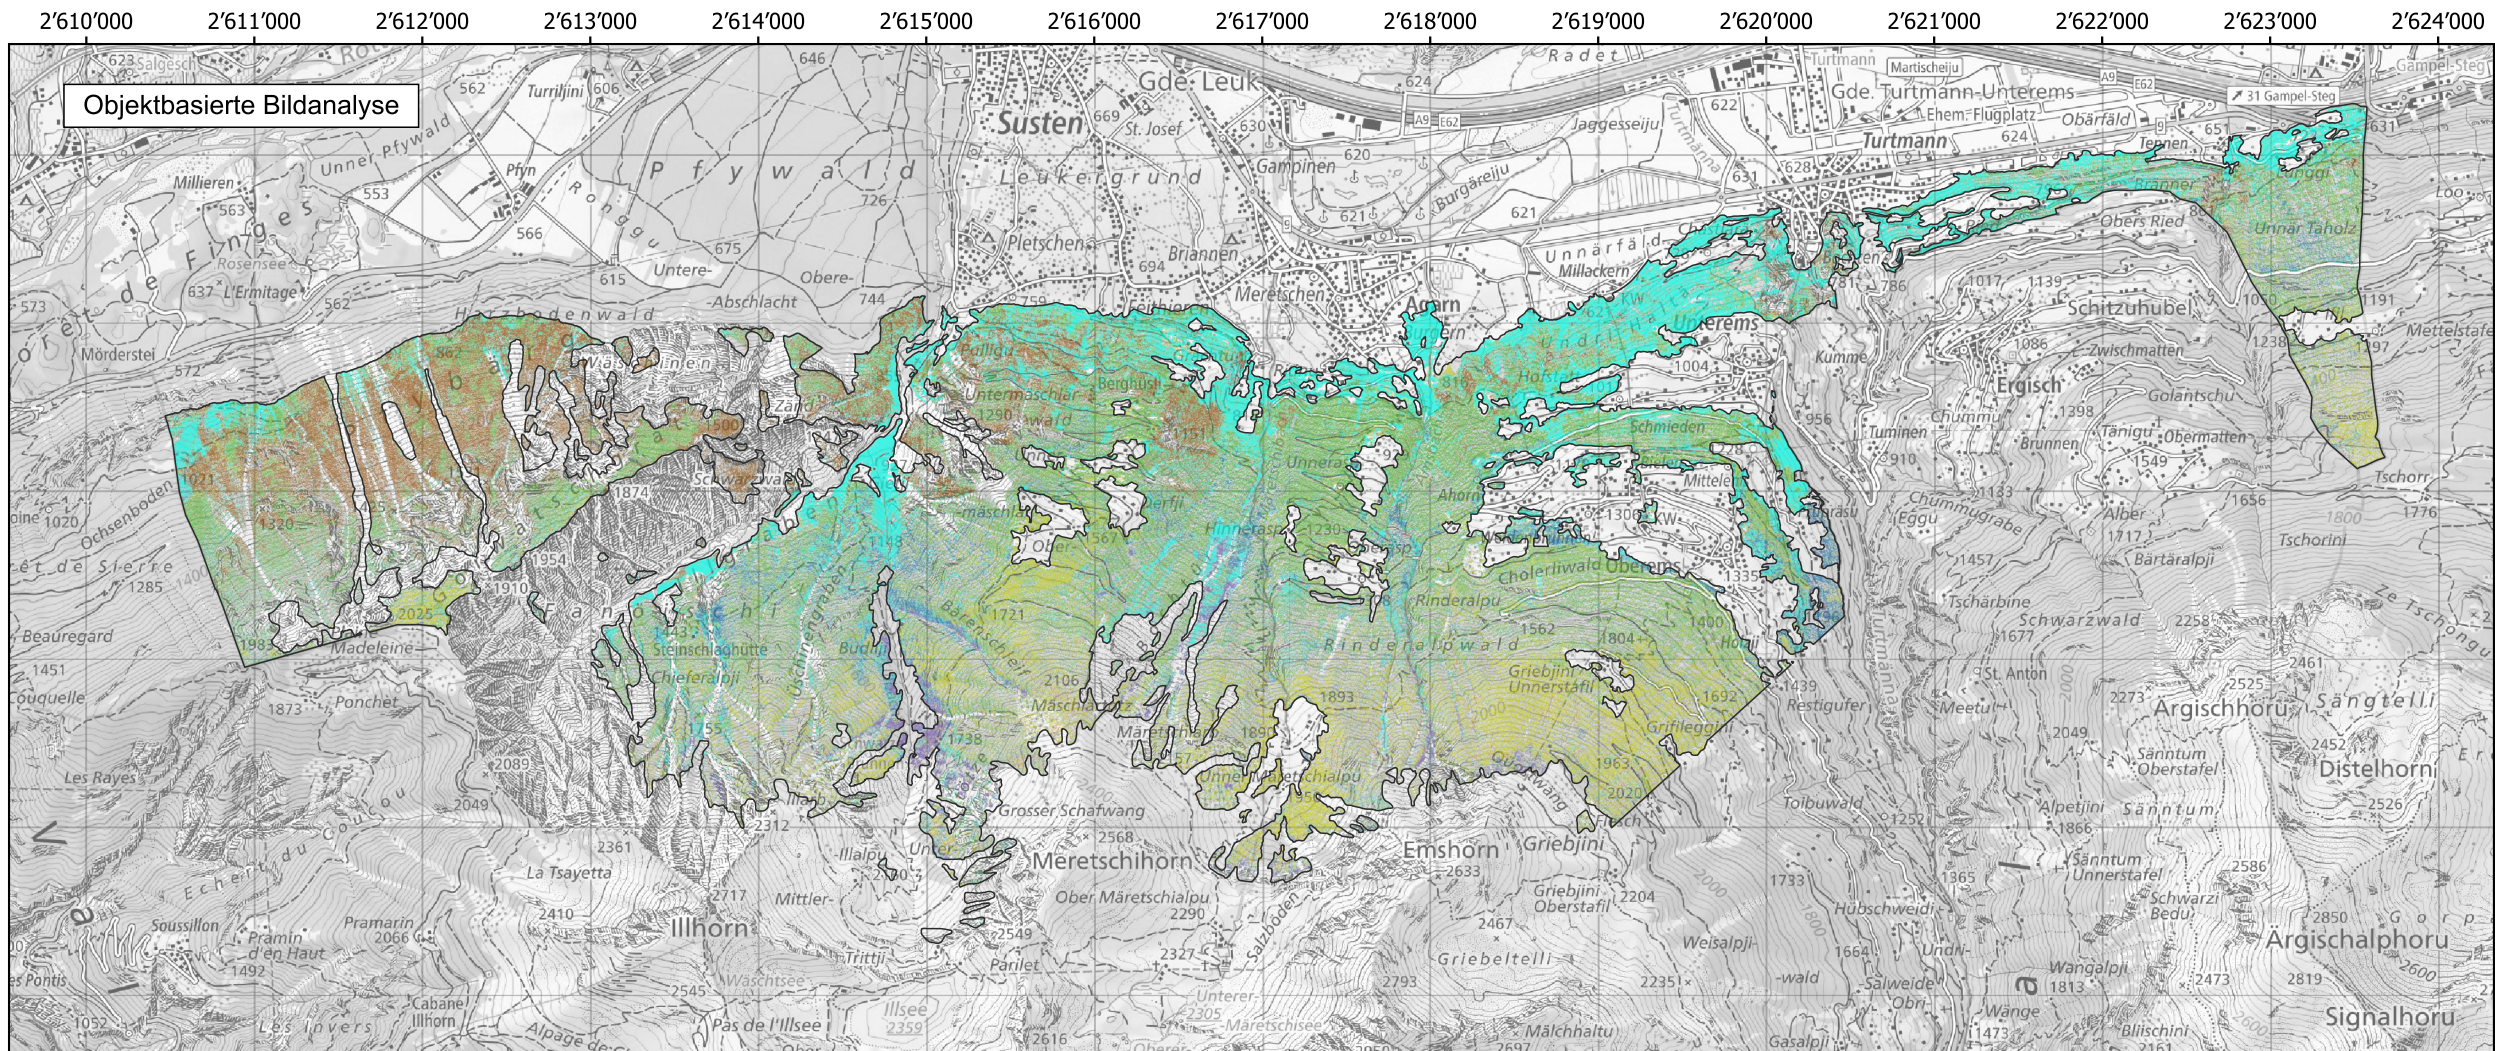


Pixelbasierte Bildanalyse



Masstab 1:45'000

gezeichnet	Datum	Planformat
Mario Werlen	31.08.2023	A3



Anhang B.3

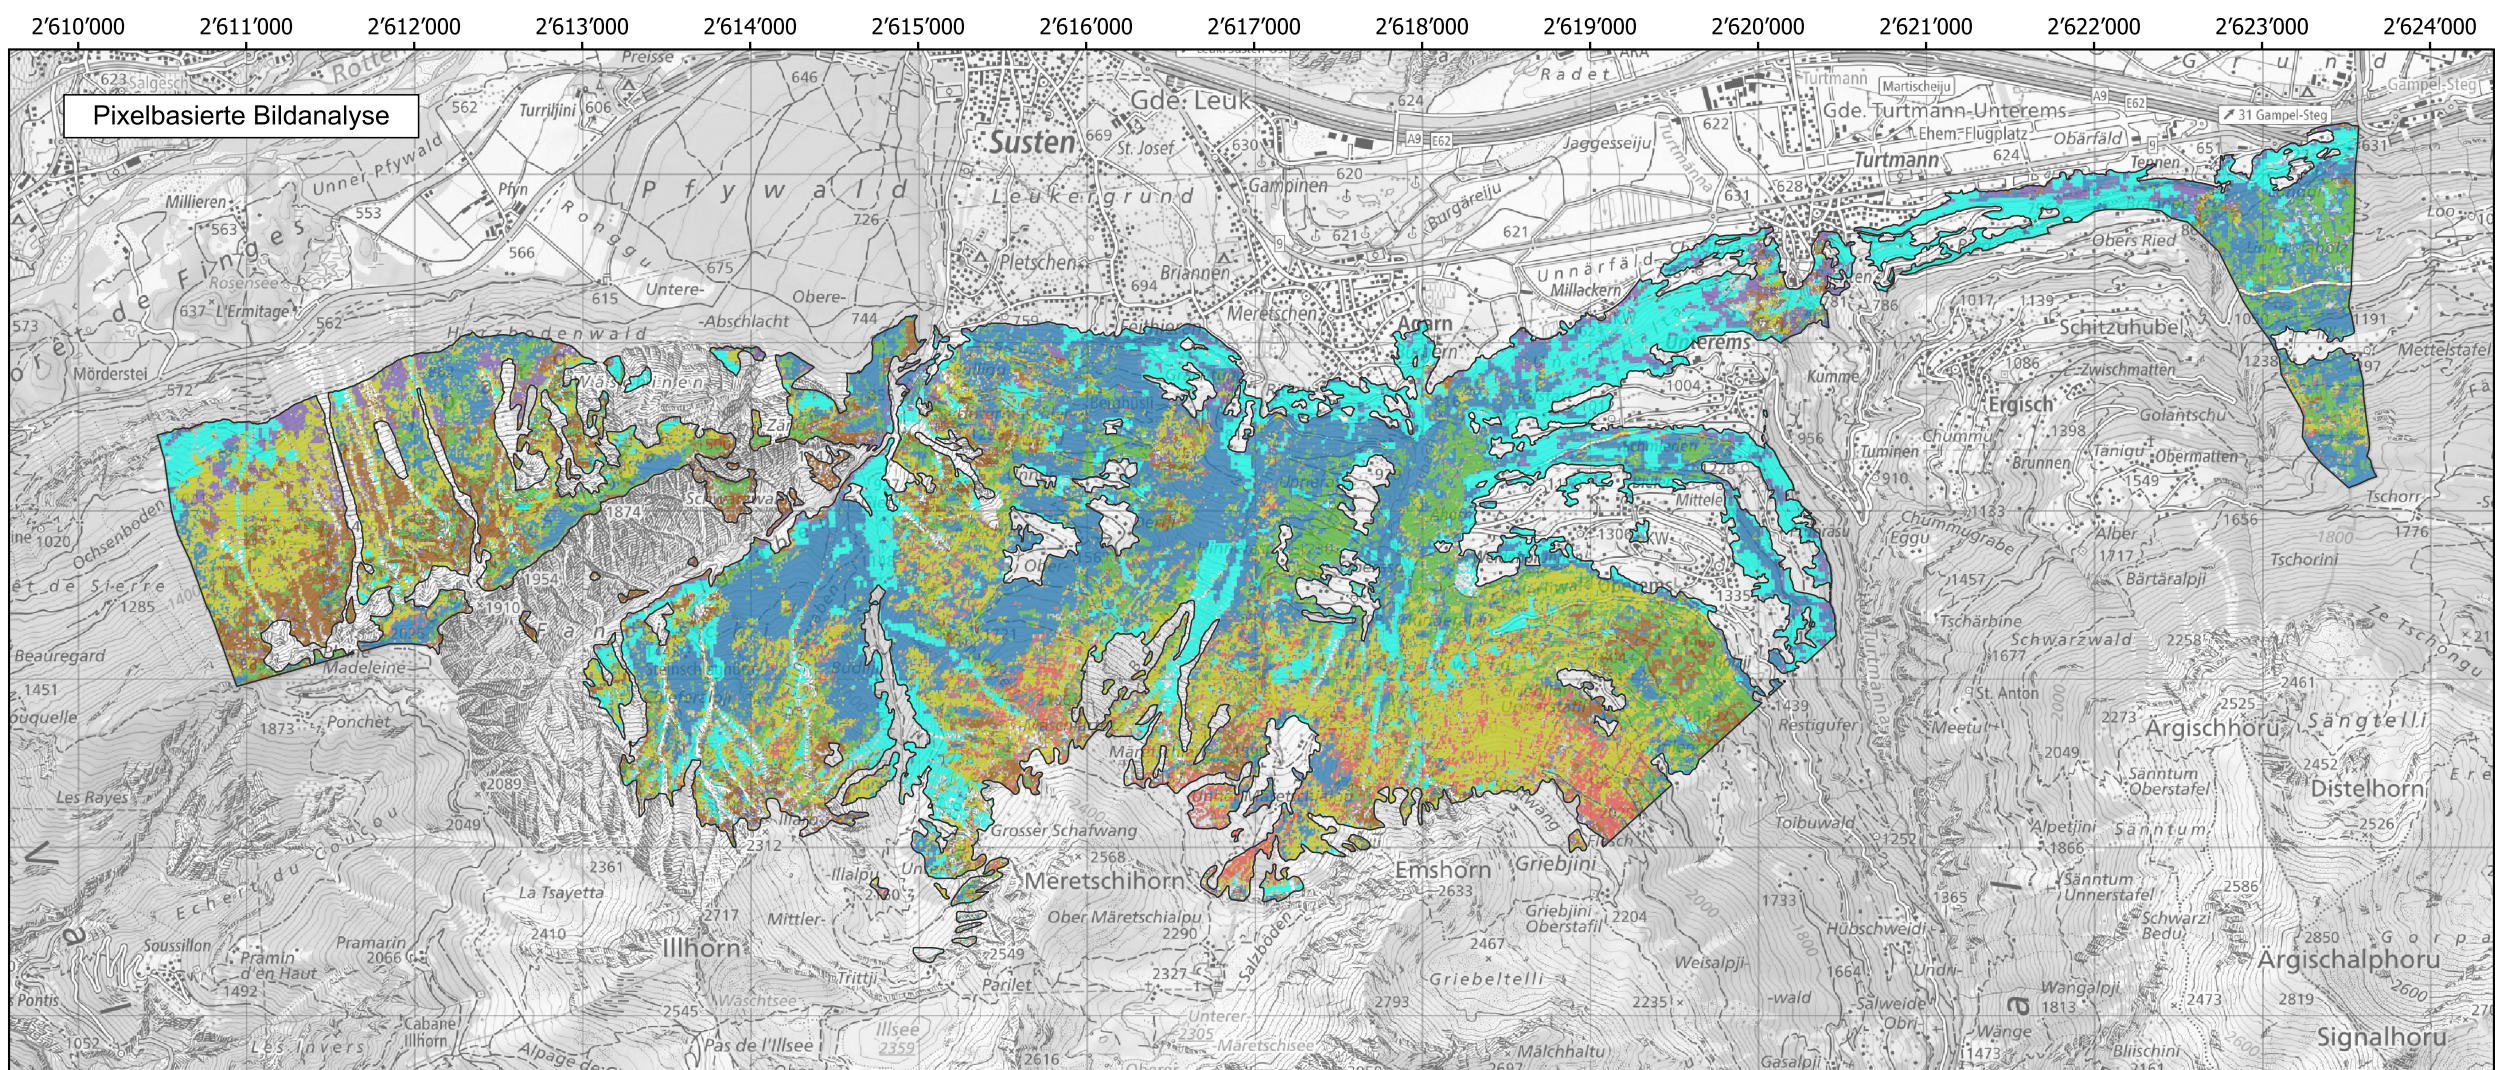
Objekt- und pixelbasierte
Baumartenklassifikation

Testgebiet 3

Baumart

- Arve
- Fichte
- Flaumeiche
- Lärche
- übriges Laubholz
- Waldföhre
- Weisstanne

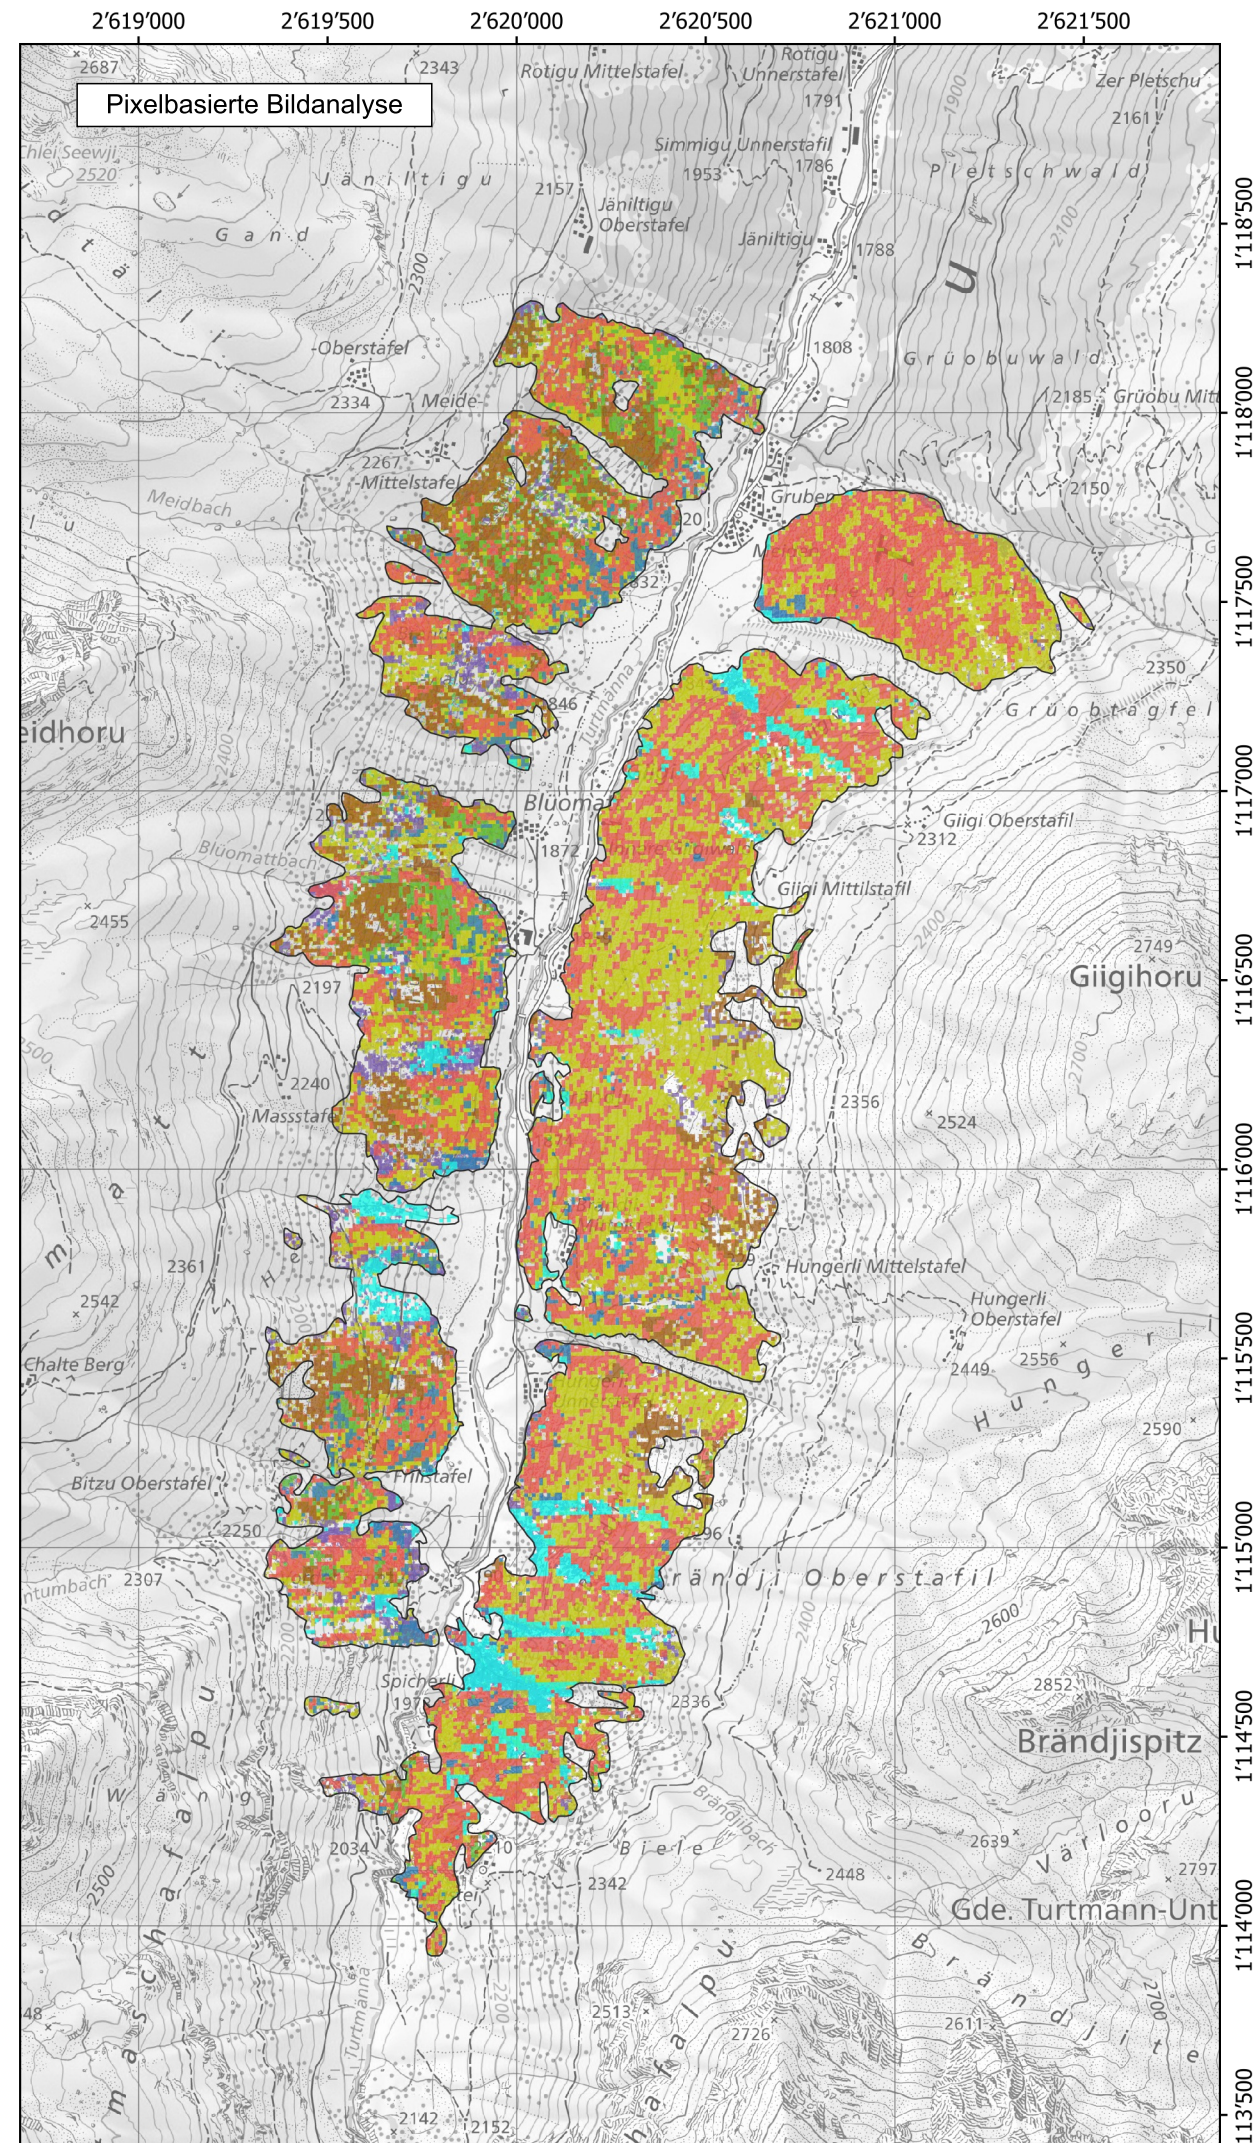
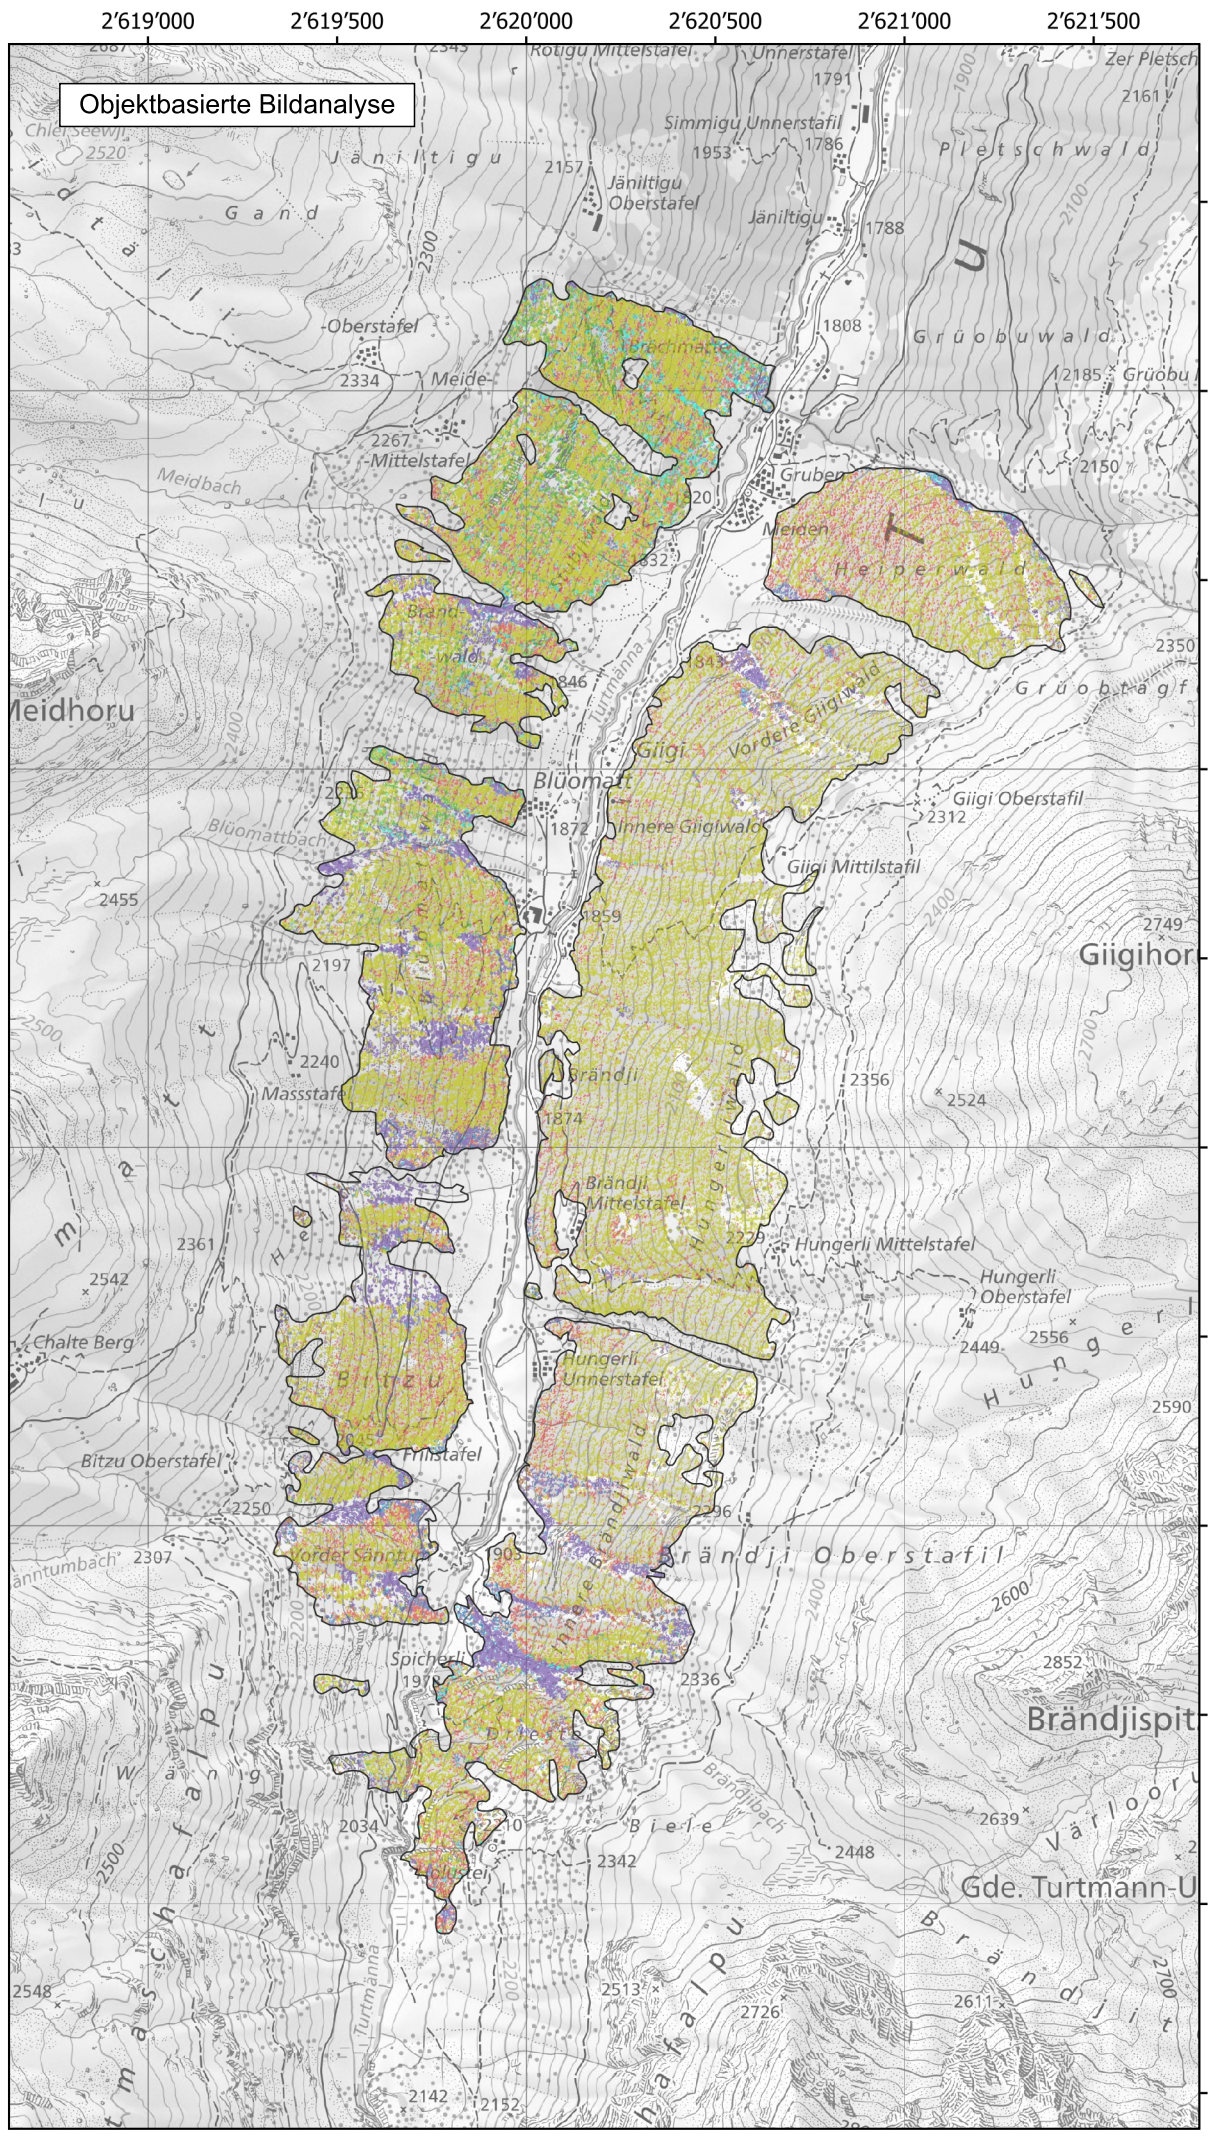
Grenze Testgebiet



Geodatenquellen:
© swisstopo

Masstab 1:45'000

gezeichnet	Datum	Planformat
Mario Werlen	31.08.2023	A3



Anhang B.4

Objekt- und pixelbasierte Baumartenklassifikation

Testgebiet 4

Baumart

- Arve
- Fichte
- Flaumeiche
- Lärche
- übriges Laubholz
- Waldföhre
- Weisstanne

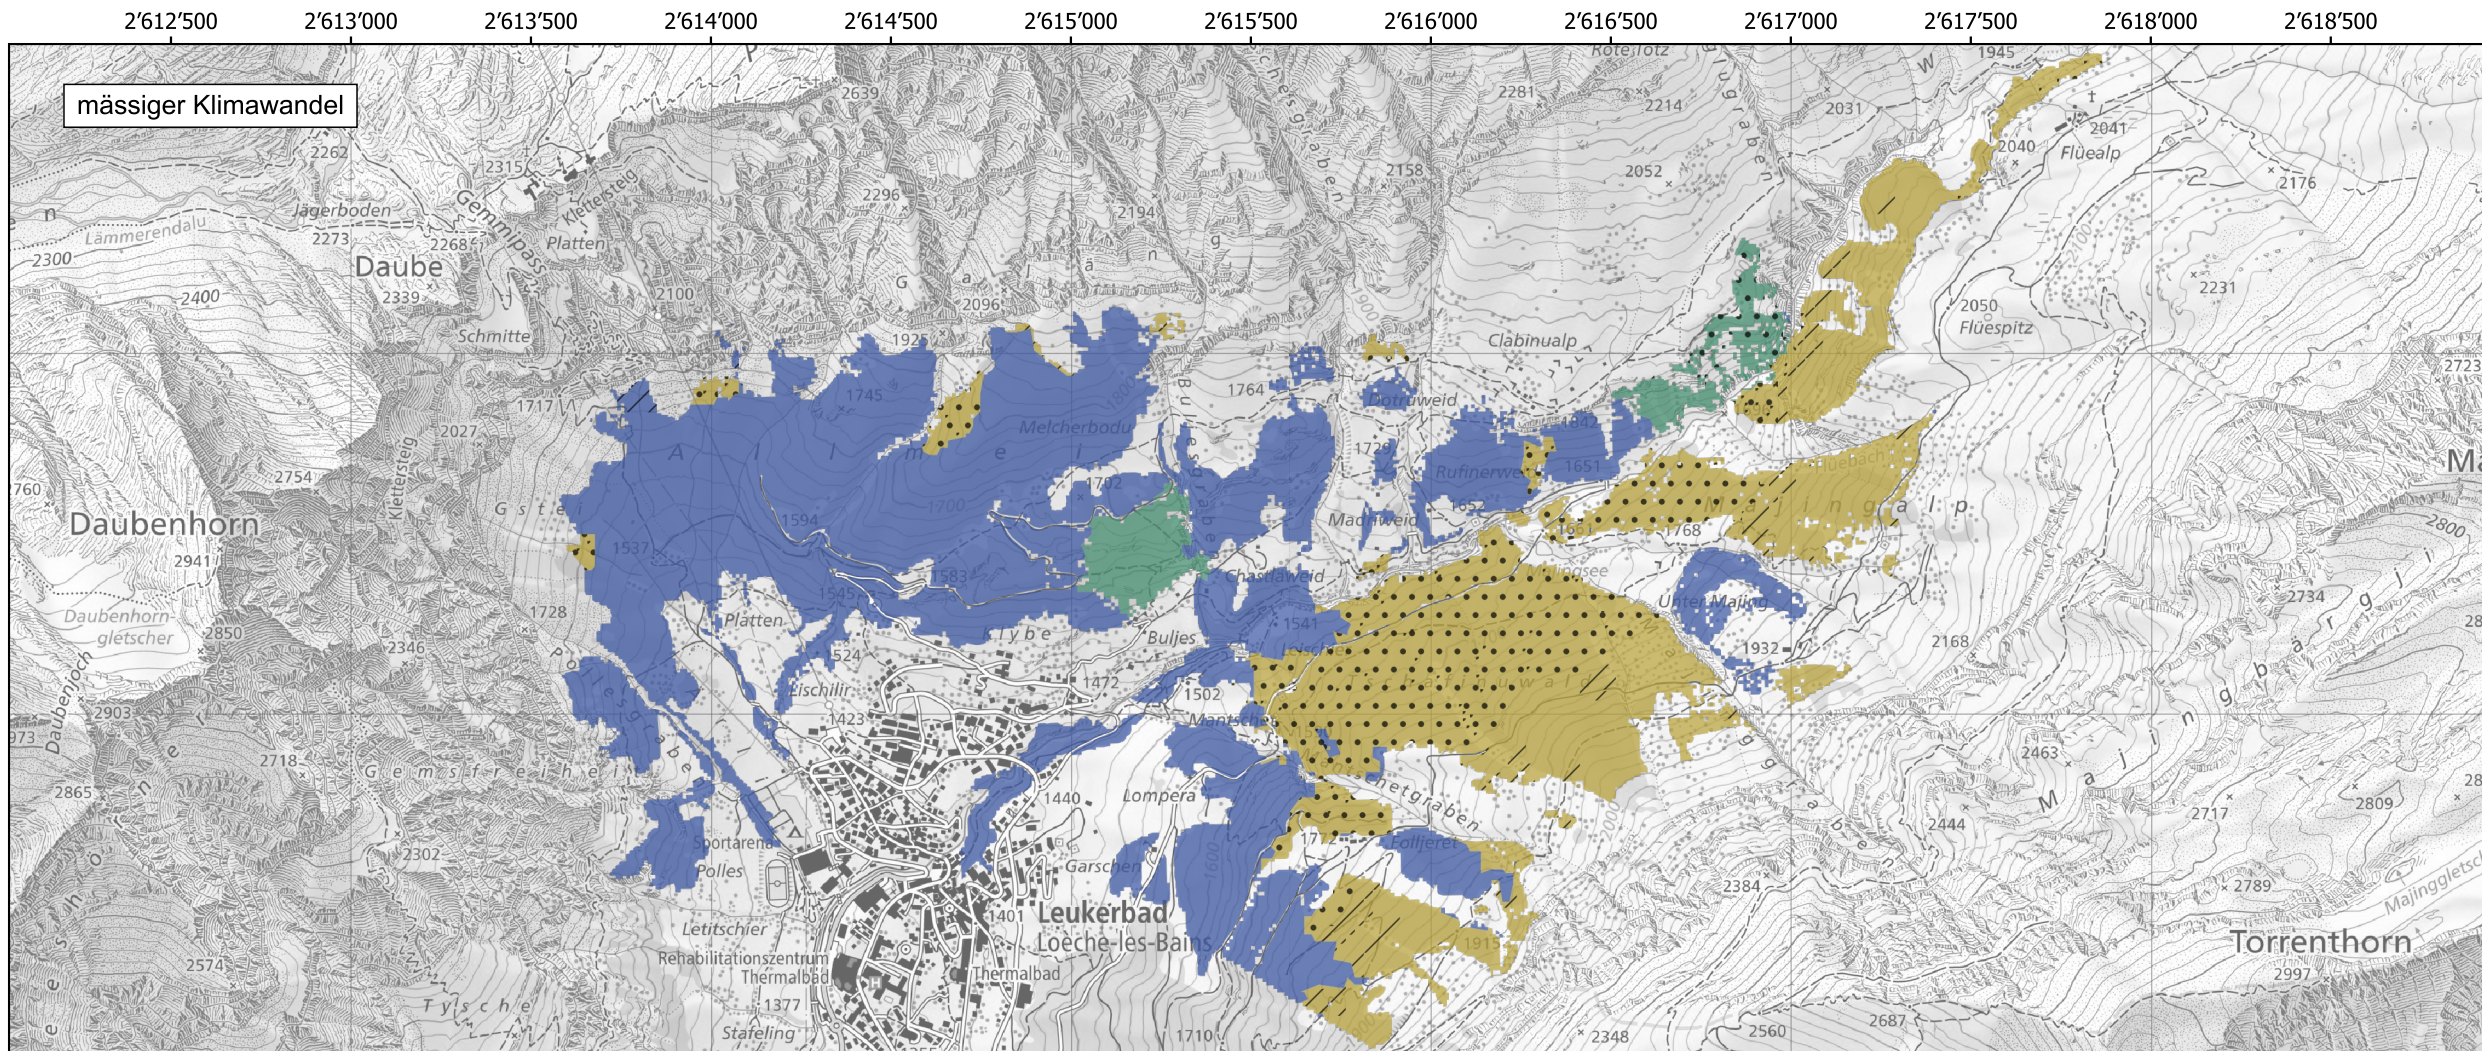
Grenze Testgebiet

Geodatenquellen:
© swisstopo

Massstab 1:20'000		
gezeichnet	Datum	Planformat
Mario Werlen	31.08.2023	A3

Anhang C

Ist-Zustand und Handlungsempfehlung



Anhang C.1

Ist-Zustand und Handlungsempfehlung

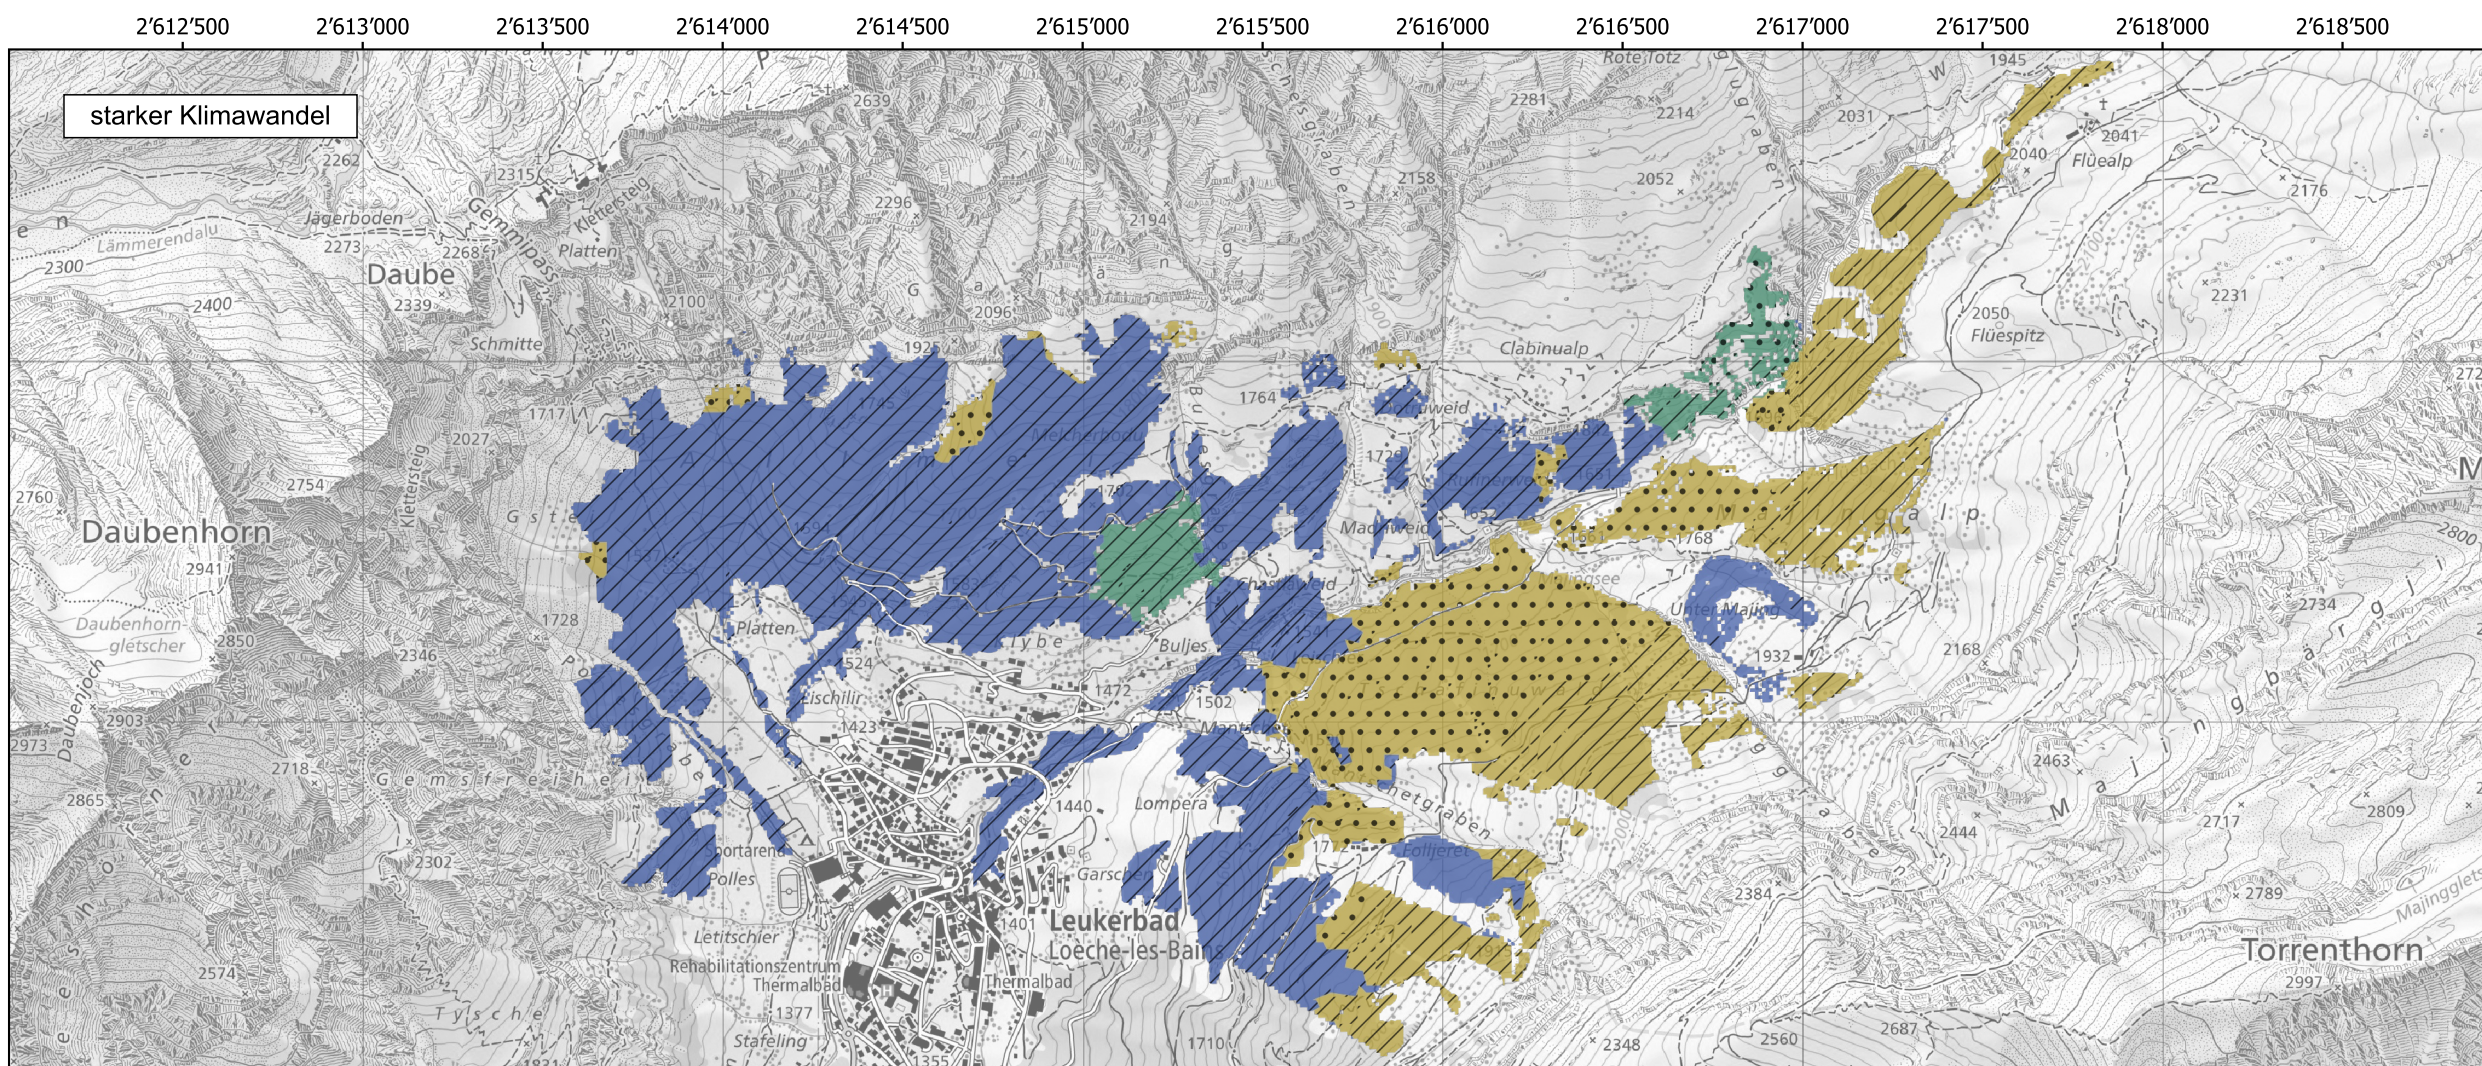
Testgebiet 1

Standortstyp-Gruppe

- Arvenwald
- Fichtenwald
- Föhrenwald

Handlungsempfehlung

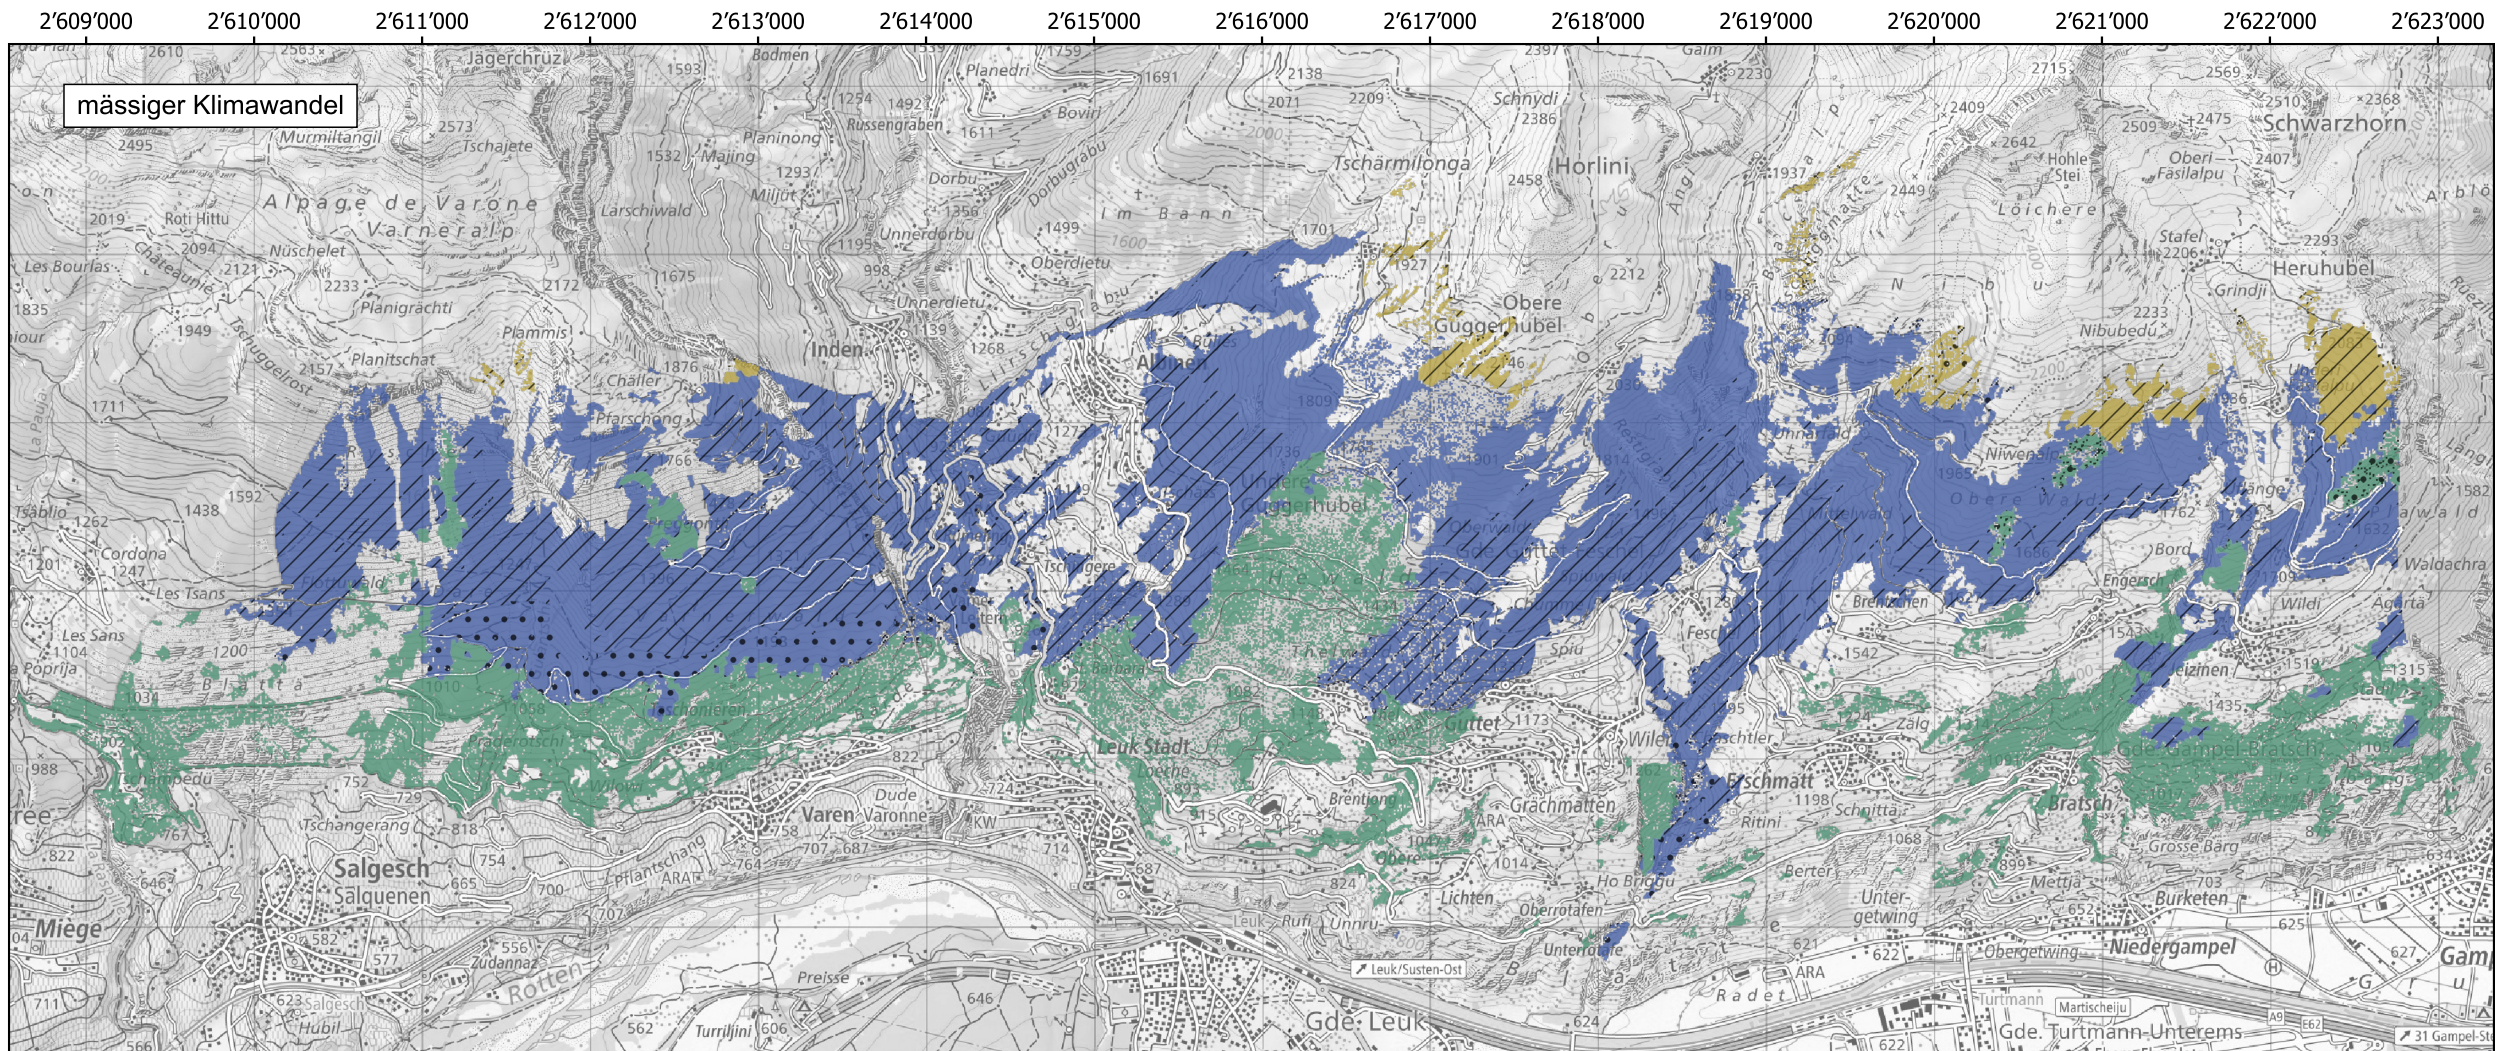
- Waldumbau nötig
- keine Empfehlung möglich



Geodatenquellen:
© swisstopo

Masstab 1:21'000

gezeichnet	Datum	Planformat
Mario Werlen	31.08.2023	A3



Anhang C.2

Ist-Zustand und
Handlungsempfehlung

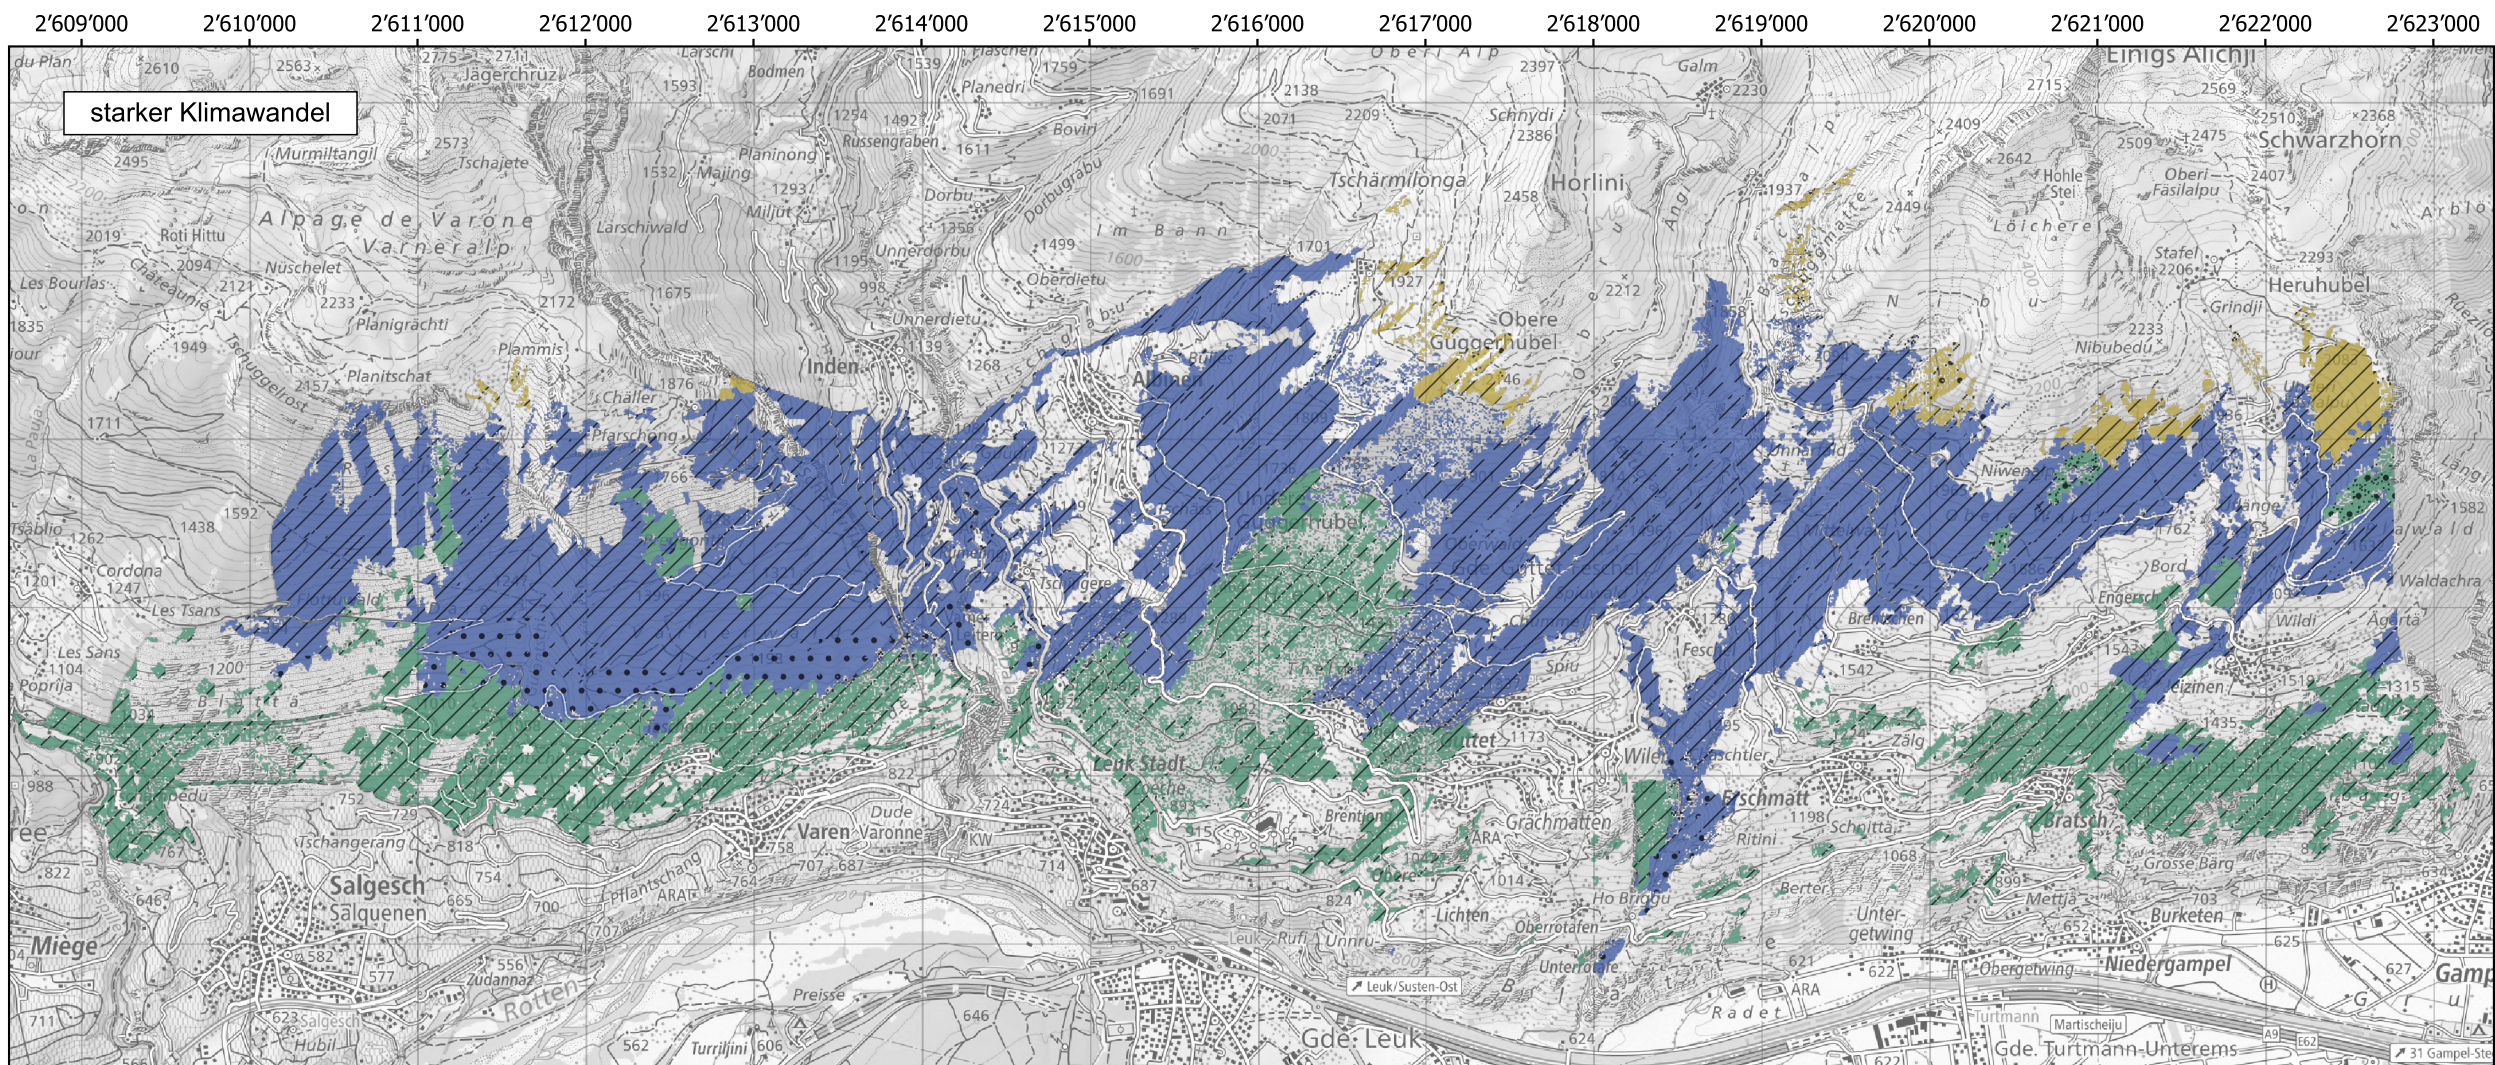
Testgebiet 2

Standortstyp-Gruppe

- Arvenwald
- Fichtenwald
- Föhrenwald

Handlungsempfehlung

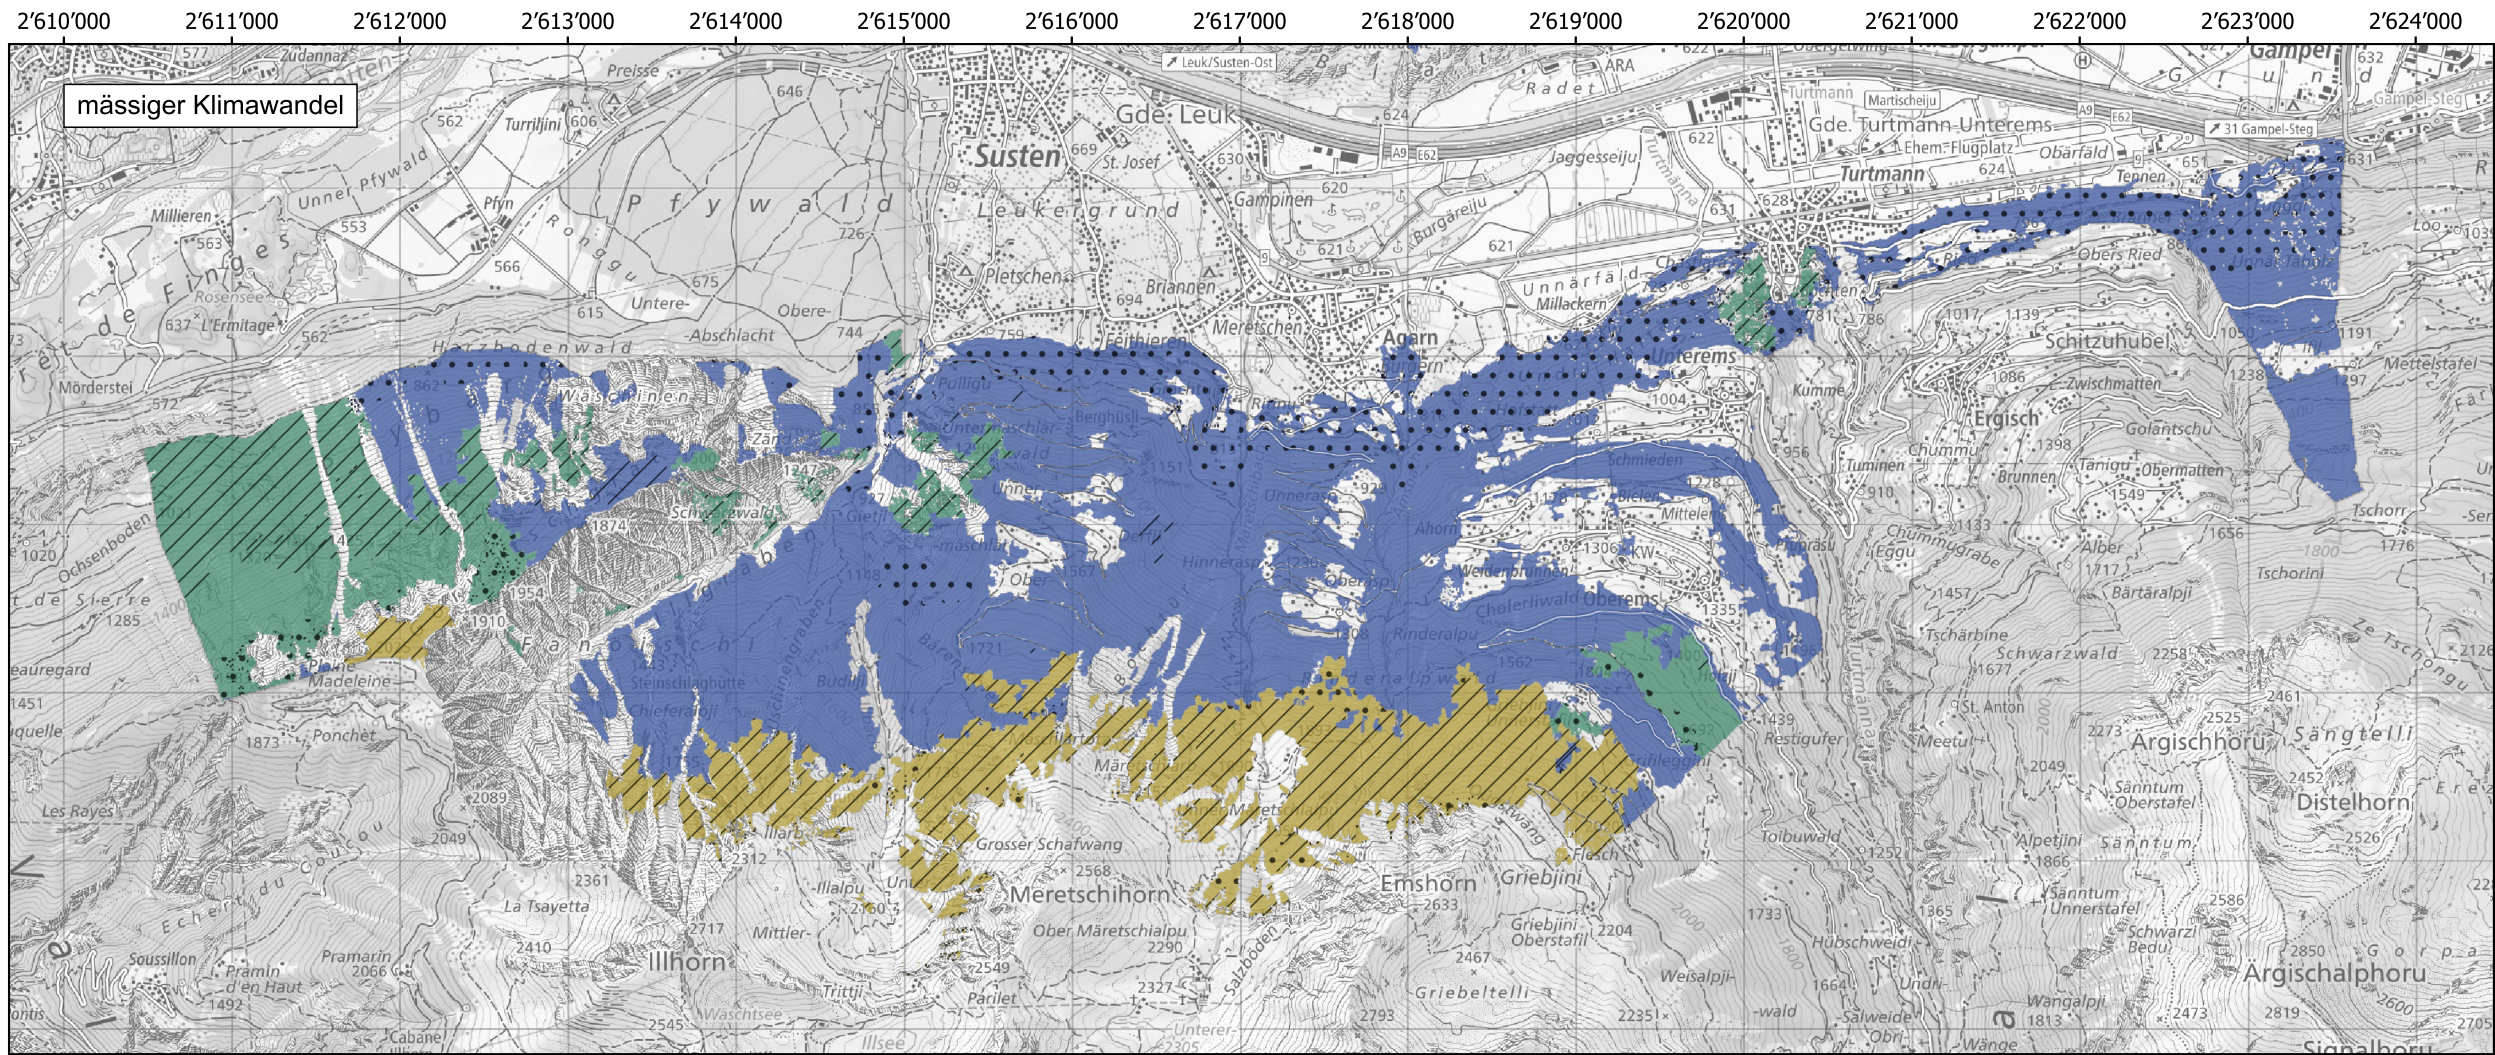
- Waldumbau nötig
- keine Empfehlung möglich



Geodatenquellen:
© swisstopo

Masstab 1:45'000

gezeichnet	Datum	Planformat
Mario Werlen	31.08.2023	A3



Anhang C.3

Ist-Zustand und Handlungsempfehlung

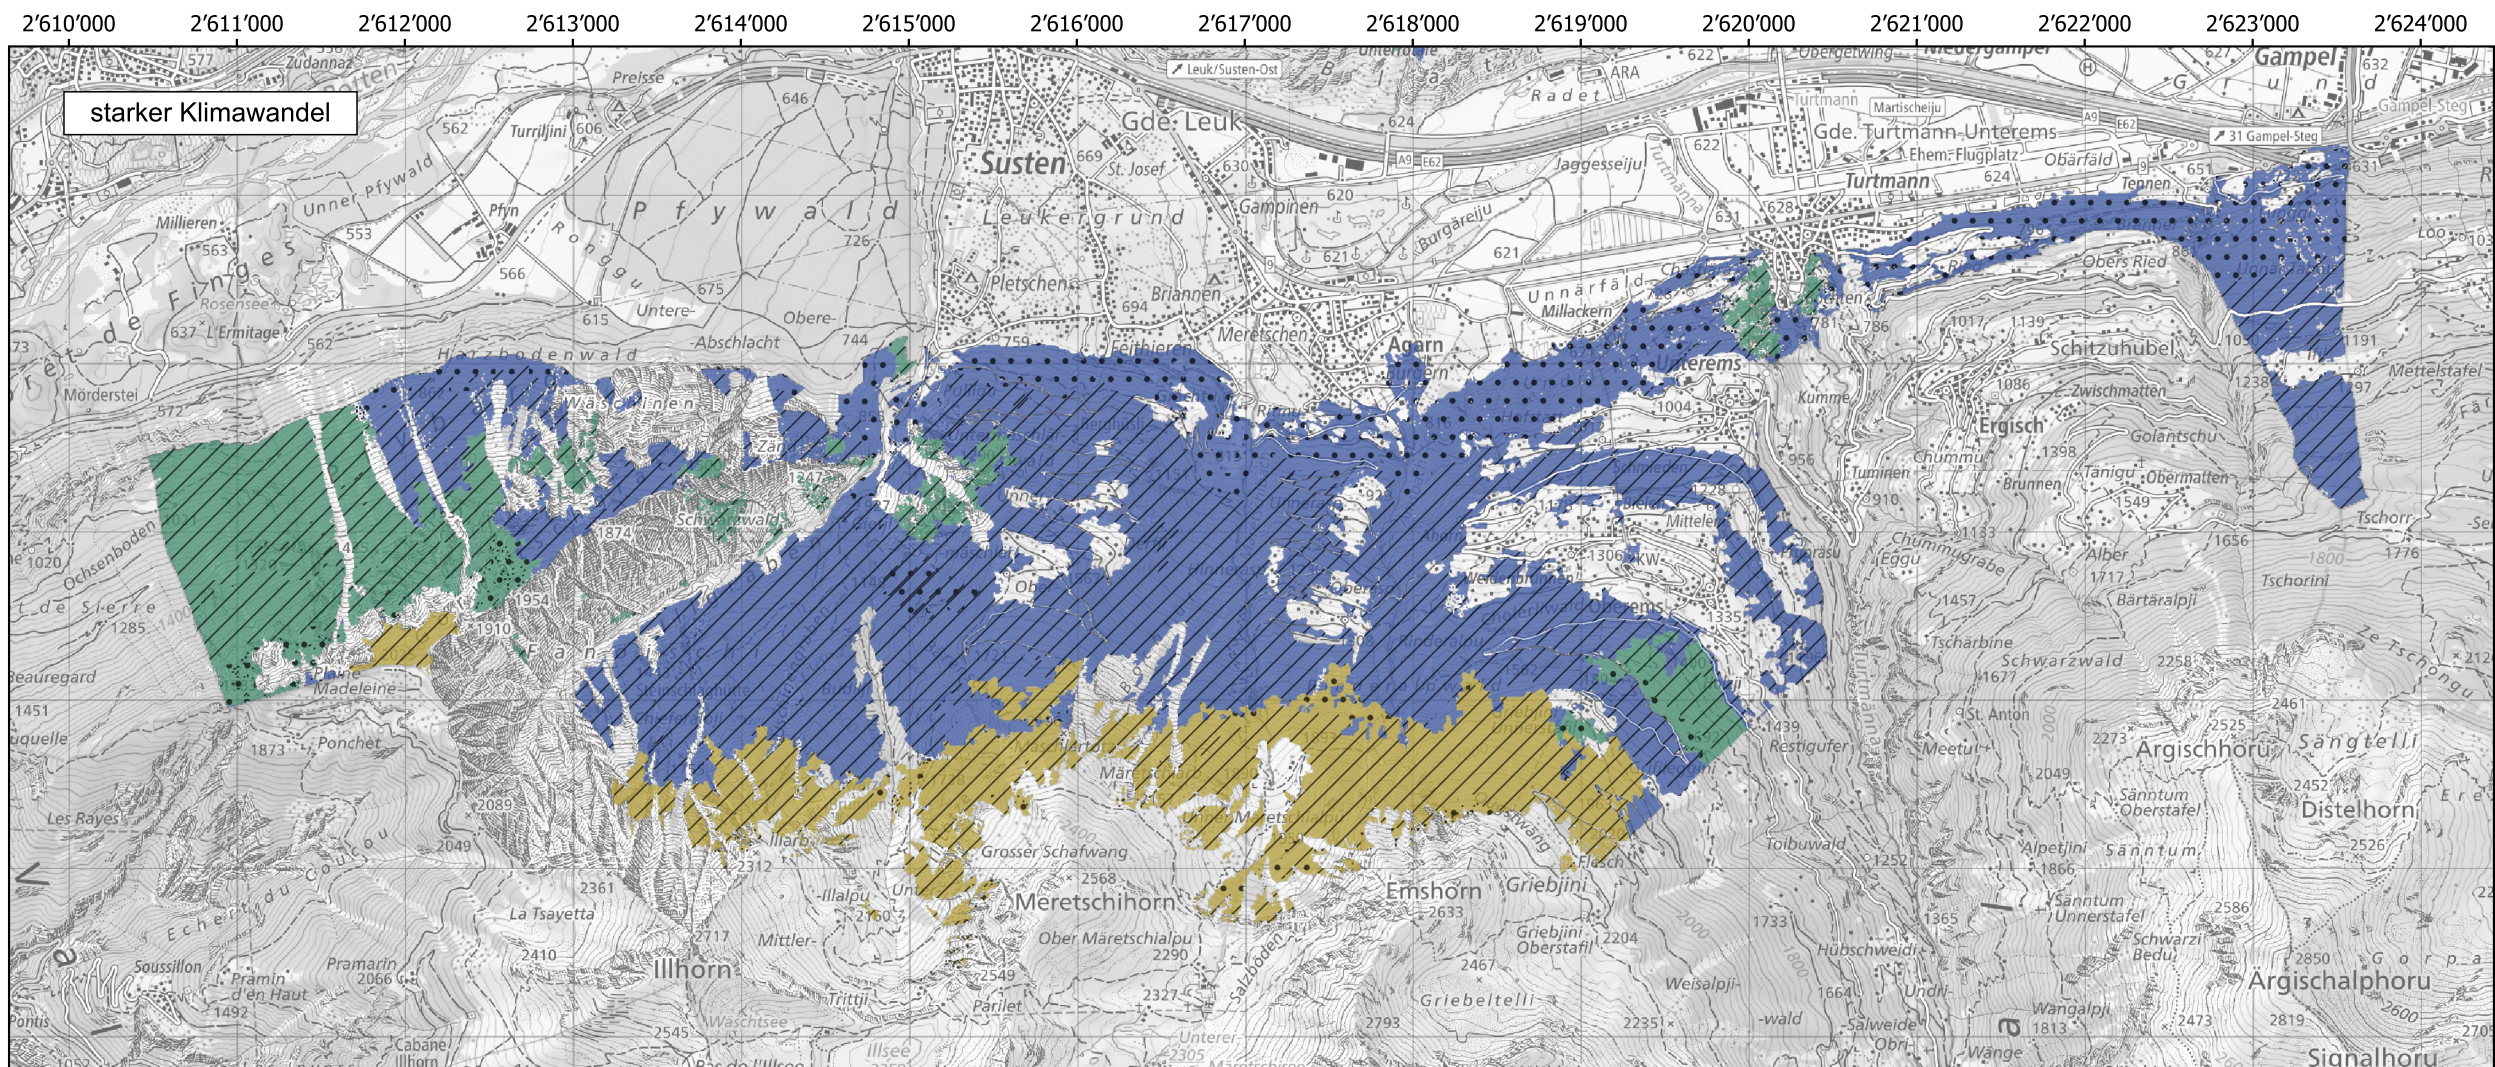
Testgebiet 3

Standortstyp-Gruppe

- Arvenwald
- Fichtenwald
- Föhrenwald

Handlungsempfehlung

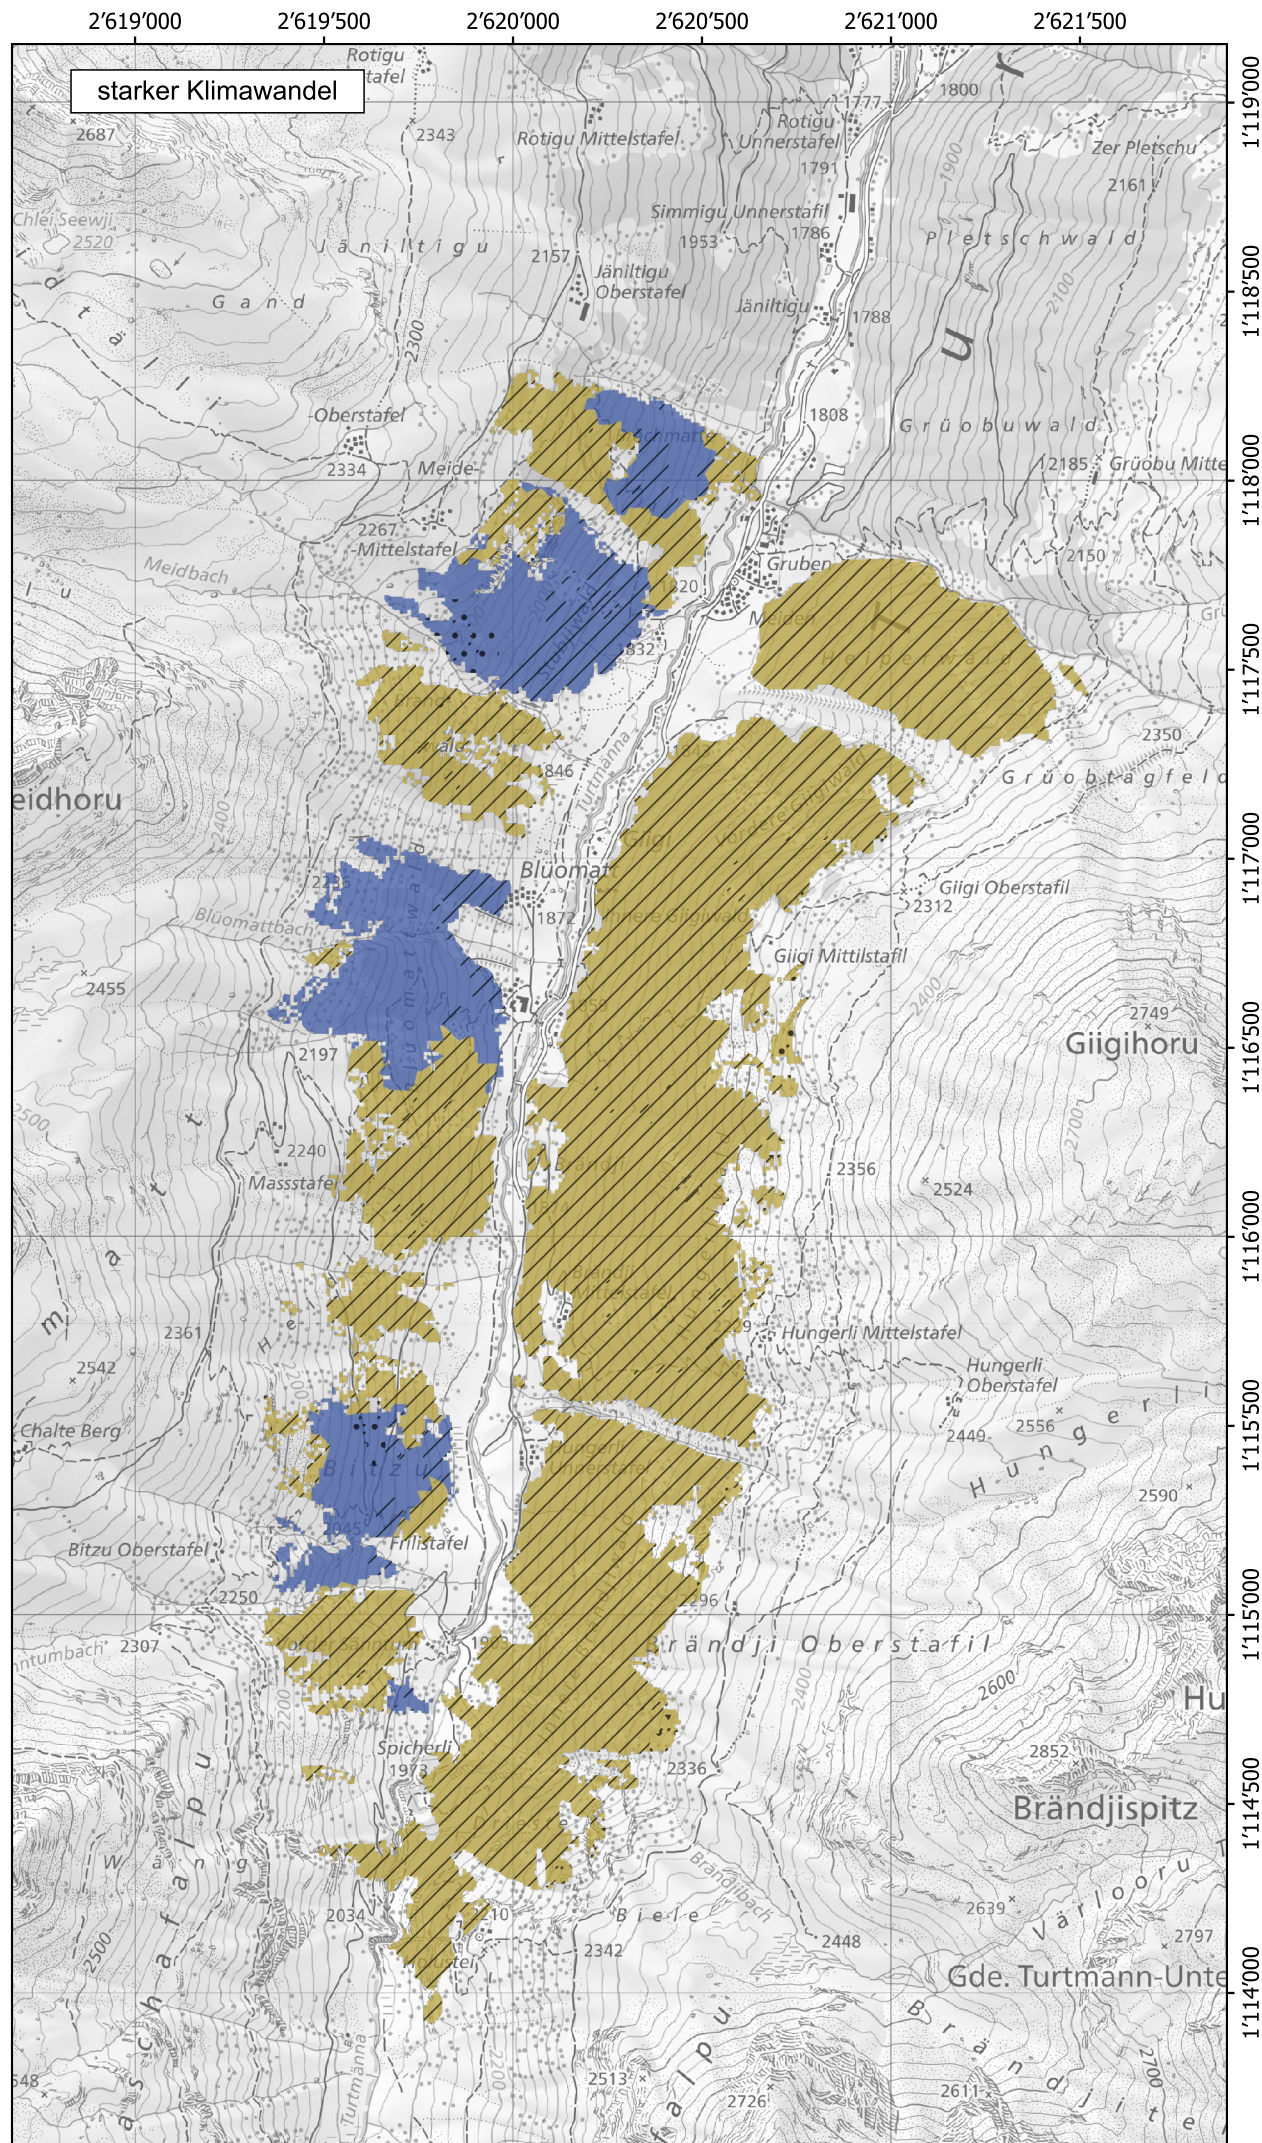
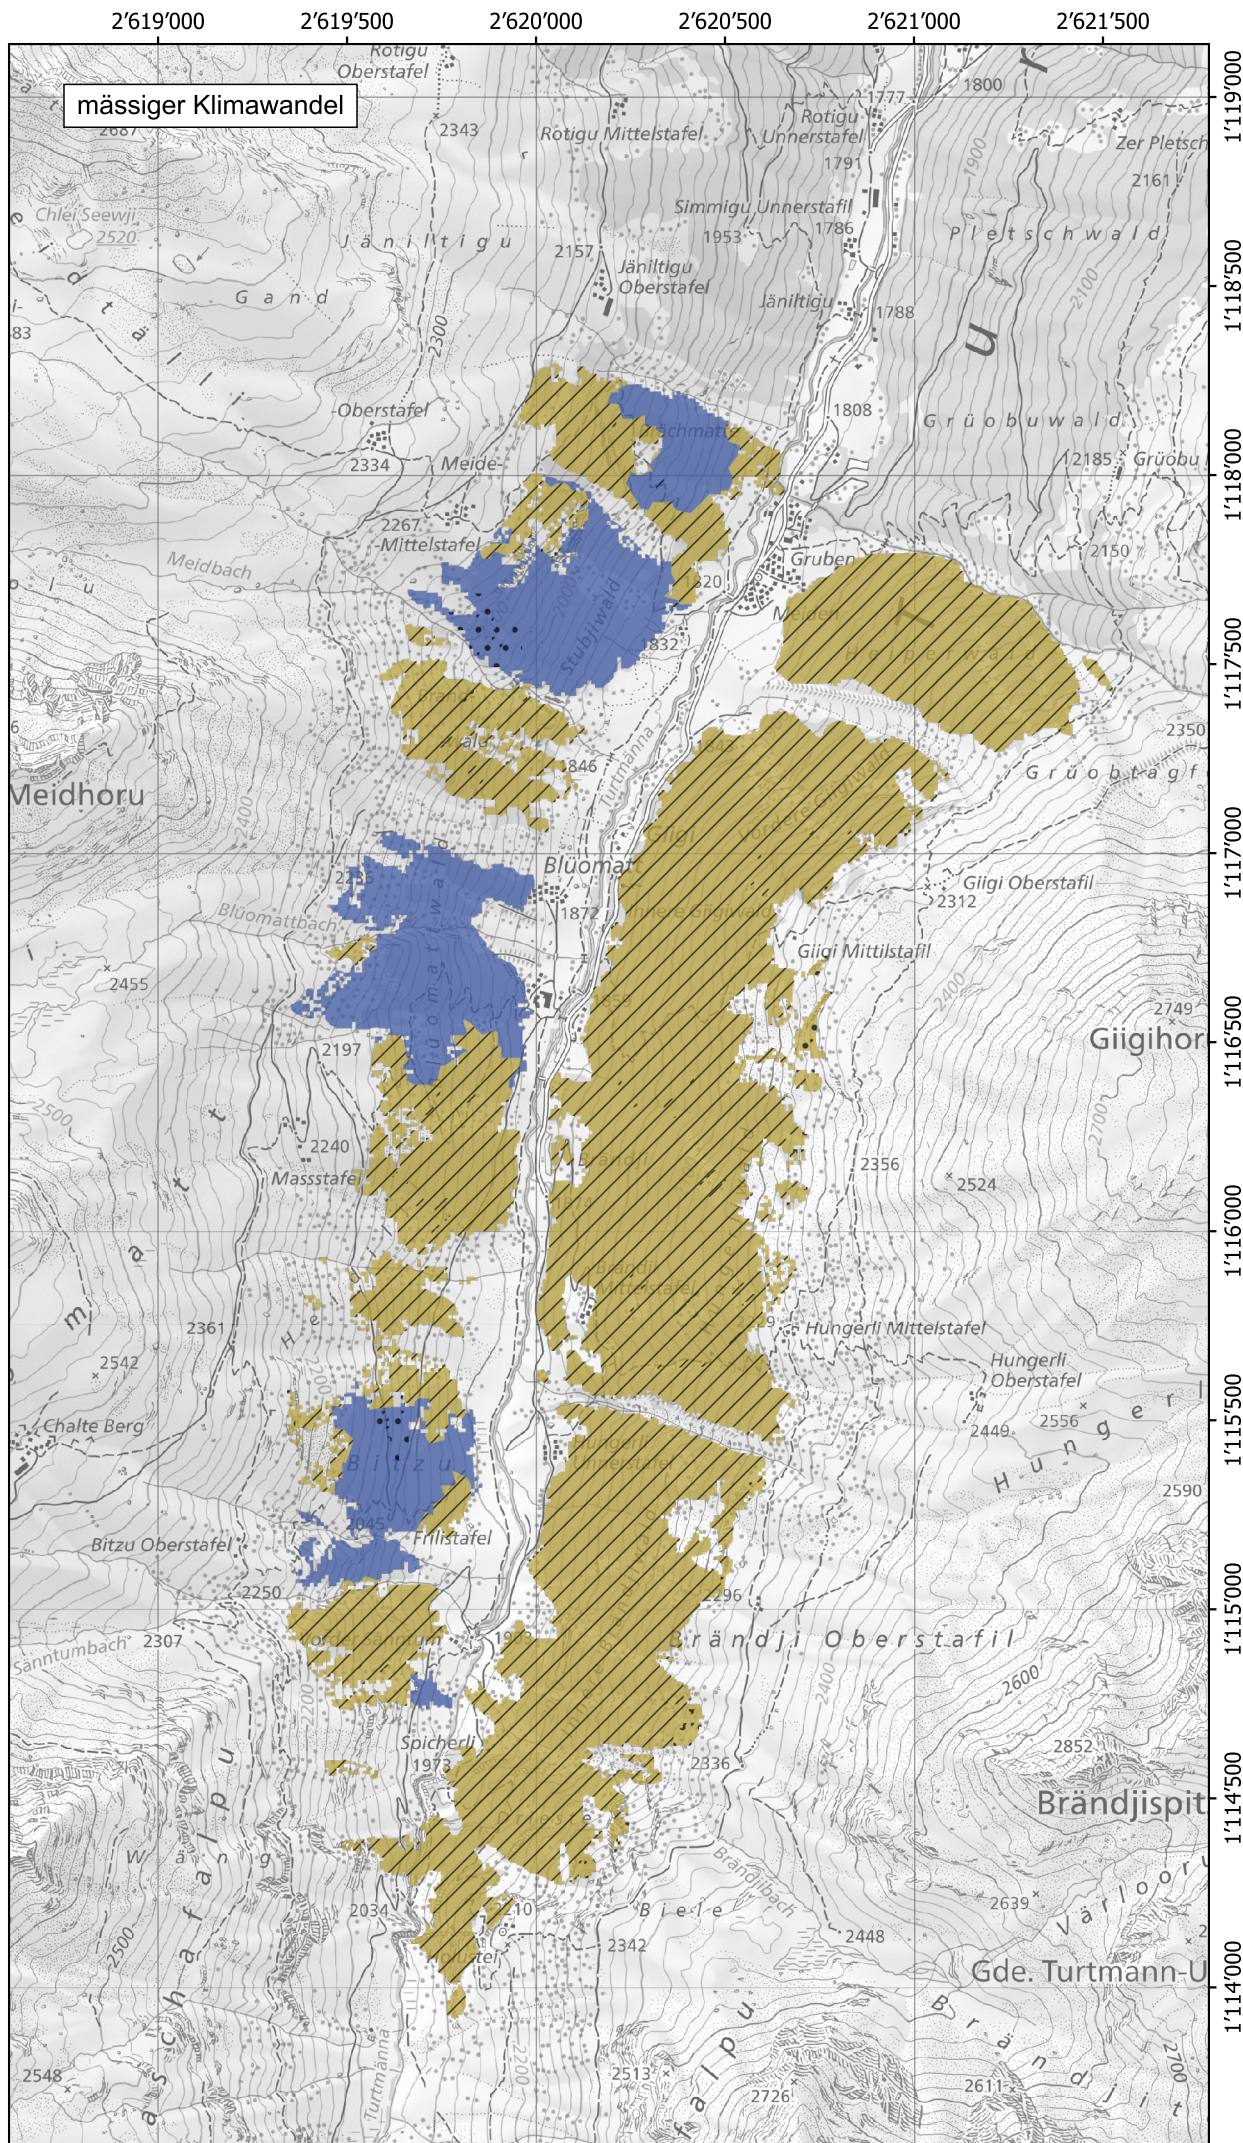
- Waldumbau nötig
- keine Empfehlung möglich



Geodatenquellen:
© swisstopo

Masstab 1:45'000

gezeichnet	Datum	Planformat
Mario Werlen	31.08.2023	A3



Anhang C.4

Ist-Zustand und Handlungsempfehlung

Testgebiet 4

Standortstyp-Gruppe

- Arvenwald
- Fichtenwald
- Föhrenwald

Handlungsempfehlung

- Waldumbau nötig
- keine Empfehlung möglich



Geodatenquellen:
© swisstopo

Masstab 1:20'000

gezeichnet	Datum	Planformat
Mario Werlen	31.08.2023	A3

Anhang D

Mögliche Standortstypen und Empfehlung der künftigen Baumartenzusammensetzung

Standortstypen NaiS gemäss Särl (2011)

Arvenwälder

Nr.	Name
59	Lärchen-Arvenwald mit Alpenrose
59C	Steinmispel-Arvenwald
59E	Lärchen-Arvenwald mit Erika
59L	Lärchen-Arvenwald mit Laserkraut
59V	Lärchen-Arvenwald mit Heidelbeere

Fichtenwälder

Nr.	Name
47H	Zypressenschlafmoos-Fichtenwald
53	Zwergbuchs-Fichtenwald
53*	Erika-Fichtenwald
55	Ehrenpreis-Fichtenwald
55*	Schneesimsen-Fichtenwald
56	Moorrand-Fichtenwald
57BL	Alpenlattich-Fichtenwald, Blockausbildung
57C	Alpenlattich-Fichtenwald mit Wollreitgras
57M	Alpenlattich-Fichtenwald mit Waldwachtelweizen
57S	Alpenlattich-Fichtenwald mit Torfmoos
57V	Alpenlattich-Fichtenwald mit Heidelbeere
58	Typischer Preiselbeer-Fichtenwald
58C	Preiselbeer-Fichtenwald mit Wollreitgras
58L	Preiselbeer-Fichtenwald mit Laserkraut
60	Typischer Hochstauden-Fichtenwald
60*	Buntreitgras-Fichtenwald
60A	Hochstauden-Fichtenwald mit Alpenwaldfarn
60E	Hochstauden-Fichtenwald mit Schachtelhalm

Föhrenwälder

Nr.	Name
65	Erika-/ Strauchwicken-Föhrenwald
65*	Hauhechel-Föhrenwald
68	Besenheide-Föhrenwald

Abkürzungsverzeichnis

Av	Arve
Bah	Bergahorn
Bfö	Bergföhre
Bu	Buche
Es	Esche
Fah	Feldahorn
Fei	Flaumeiche
Fi	Fichte
Ful	Feldulme
Hbi	Hängebirke
Ki	Kirschbaum
Mb	Mehlbeere
Rei	Roteiche
Sah	Spitzahorn
Sei	Stieleiche
Ser	Schwarzerle
Sii	Sommerlinde
Tei	Traubeneiche
Wfö	Waldföhre
Wli	Winterlinde
Wta	Weisstanne

keine Empfehlung möglich

Baumartenempfehlungen der verschiedenen Klimaszenarien gemäss Tree App

Testgebiet 1

Arvenwälder		Standortstyp	59	59E						mögliche Baumarten
Klimaszenario		Höhenstufe	Baumarten							
Szenario 1	Klima aktuell	obersubalpin								
	mässiger Klimawandel	hochmontan								
	starker Klimawandel	hochmontan								
Szenario 2	Klima aktuell	subalpin	Av							Av
	mässiger Klimawandel	hochmontan	Av							Av
	starker Klimawandel	hochmontan	Fi							Fi
Szenario 3	Klima aktuell	subalpin	Av							Av
	mässiger Klimawandel	hochmontan	Fi							Fi
	starker Klimawandel	collin	Bah, Wli, Sli, Ful							Bah, Wli, Sli, Ful
Szenario 4	Klima aktuell	hochmontan								
	mässiger Klimawandel	hochmontan								
	starker Klimawandel	hochmontan								
Szenario 5	Klima aktuell	hochmontan								
	mässiger Klimawandel	hochmontan								
	starker Klimawandel	collin								
Szenario 6	Klima aktuell	hochmontan								
	mässiger Klimawandel	collin								
	starker Klimawandel	collin								
Szenario 6	Klima aktuell	hochmontan								
	mässiger Klimawandel	obermontan								
	starker Klimawandel	collin								

Fichtenwälder Teil 1		Standortstyp	53	53*	57BL	57C	57S	57V	58	58L					
Klimaszenario		Höhenstufe	Baumarten												
Szenario 1	Klima aktuell	subalpin	Fi	IFi		Fi	IFi	IFi	IFi	IFi					
	mässiger Klimawandel	hochmontan	Fi	Fi		Fi	Fi	Fi	Fi	Fi					
	starker Klimawandel	hochmontan	Fi	Fi, Wfö		Fi	Fi	Fi	Fi	Fi					
Szenario 2	Klima aktuell	subalpin	Fi	Fi		Fi	Fi	Fi	Fi	Fi					
	mässiger Klimawandel	hochmontan	Fi	Fi, Wfö		Fi	Fi	Fi	Fi	Fi					
	starker Klimawandel	collin	Tei, Wli	Tei, Wli		Tei	Hbi	Ki, Tei, Sei	Tei	Tei					
Szenario 3	Klima aktuell	hochmontan		Fi	Fi										
	mässiger Klimawandel	hochmontan		Fi, Wfö	Fi										
	starker Klimawandel	hochmontan		Fi, Wfö	Fi										
Szenario 4	Klima aktuell	hochmontan		Fi	Fi										
	mässiger Klimawandel	hochmontan		Fi, Wfö	Fi										
	starker Klimawandel	collin		Tei, Wli	Bah, Wli, Sli, Ful										
Szenario 5	Klima aktuell	hochmontan		Fi	Fi										
	mässiger Klimawandel	collin		Fi, Wfö	Fi										
	starker Klimawandel	collin		Tei, Wli	Bah, Wli, Sli, Ful										
Szenario 6	Klima aktuell	hochmontan		Fi											
	mässiger Klimawandel	obermontan		Fi											
	starker Klimawandel	collin		Tei, Wli											

Fichtenwälder Teil 2		Standortstyp	60	60*	60A	60E	47H	55	55*	56	mögliche Baumarten	
Klimaszenario		Höhenstufe	Baumarten									
Szenario 1	Klima aktuell	subalpin	Fi	Fi	Fi	Fi					Fi	
	mässiger Klimawandel	hochmontan	Fi	Fi	Fi	Fi					Fi	
	starker Klimawandel	hochmontan	Fi	Fi	Wta, Fi	Fi					Fi, Wfö, Wta	
Szenario 2	Klima aktuell	subalpin	Fi	Fi	Fi	Fi					Fi	
	mässiger Klimawandel	hochmontan	Fi	Fi	Wta, Fi	Fi					Fi, Wfö, Wta	
	starker Klimawandel	collin	Fah, Sah, Es, Ki, Sei	Wli	Fah, Sah, Es, Ki, Sei	Ser					Tei, Wli, Hbi, Ki, Sei, Fah, Sah, Es, Ser	
Szenario 3	Klima aktuell	hochmontan	Fi	Fi			Fi	Fi	Fi	Fi	Fi	
	mässiger Klimawandel	hochmontan	Fi	Fi			Fi	Fi	Fi	Fi	Fi, Wfö	
	starker Klimawandel	hochmontan	Fi	Fi			Fi	Fi	Fi	Fi	Fi, Wfö	
Szenario 4	Klima aktuell	hochmontan	Fi	Fi			Fi	Fi	Fi	Fi	Fi	
	mässiger Klimawandel	hochmontan	Fi	Fi			Fi	Fi	Fi	Fi	Fi, Wfö	
	starker Klimawandel	collin	Fah, Sah, Es, Ki, Sei	Es, Ki, Tei, Mb, Wli			Tei	Tei	Tei	Hbi	Tei, Bah, Wli, Sli, Ful, Fah, Sah, Es, Ki, Sei, Mb, Hbi	
Szenario 5	Klima aktuell	hochmontan	Fi	Fi			Fi	Fi	Fi	Fi	Fi	
	mässiger Klimawandel	collin	Fi	Fi			Fi	Fi	Fi	Fi	Fi, Wfö	
	starker Klimawandel	collin	Fah, Sah, Es, Ki, Sei	Es, Ki, Tei, Mb, Wli			Tei	Tei	Tei	Hbi	Tei, Bah, Wli, Sli, Ful, Fah, Sah, Es, Ki, Sei, Mb, Hbi	
Szenario 6	Klima aktuell	hochmontan	Fi				Fi	Fi	Fi	Fi	Fi	
	mässiger Klimawandel	obermontan	Wta, Bu				Fi	Wta, Bu	Wta, Bu	Fi	Wta, Bu, Fi	
	starker Klimawandel	collin	Fah, Sah, Es, Ki, Sei				Tei	Tei	Tei	Hbi	Fah, Sah, Es, Ki, Sei, Tei, Wli, Hbi	

Föhrenwälder		Standortstyp	65	65*	68						mögliche Baumarten	
Klimaszenario		Höhenstufe	Baumarten									
Szenario 1	Klima aktuell	subalpin										
	mässiger Klimawandel	hochmontan										
	starker Klimawandel	hochmontan										
Szenario 2	Klima aktuell	subalpin										
	mässiger Klimawandel	hochmontan										
	starker Klimawandel	collin										
Szenario 3	Klima aktuell	hochmontan	Wfö	Wfö	Wfö						Wfö	
	mässiger Klimawandel	hochmontan	Wfö	Wfö	Wfö						Wfö	
	starker Klimawandel	collin	Fei	Fei	Tei						Fei, Tei	
Szenario 4	Klima aktuell	hochmontan	Wfö	Wfö	Wfö						Wfö	
	mässiger Klimawandel	collin	Wfö	Wfö	Wfö						Wfö	
	starker Klimawandel	collin	Fei	Fei	Tei						Fei, Tei	

Testgebiet 2

Arvenwälder		Standortstyp	59	59E							mögliche Baumarten	
Klimaszenario		Höhenstufe	Baumarten									
Szenario 1	Klima aktuell	obersubalpin										
	mässiger Klimawandel	hochmontan										
	starker Klimawandel	hochmontan										
Szenario 2	Klima aktuell	obersubalpin	Av									Av
	mässiger Klimawandel	hochmontan	Fi									Fi
	starker Klimawandel	collin	Bah, Wli, Sli, Ful									Bah, Wli, Sli, Ful
Szenario 3	Klima aktuell	subalpin	Av									Av
	mässiger Klimawandel	hochmontan	Fi									Fi
	starker Klimawandel	hochmontan	Fi									Fi
Szenario 4	Klima aktuell	subalpin	Av									Av
	mässiger Klimawandel	hochmontan	Fi									Fi
	starker Klimawandel	collin	Bah, Wli, Sli, Ful									Bah, Wli, Sli, Ful
Szenario 5	Klima aktuell	hochmontan										
	mässiger Klimawandel	hochmontan										
	starker Klimawandel	hochmontan										
Szenario 6	Klima aktuell	hochmontan										
	mässiger Klimawandel	hochmontan										
	starker Klimawandel	collin										

Fichtenwälder Teil 1		Standortstyp	53	53*	57BL	57C	57S	57V	58	58L										
Klimaszenario		Höhenstufe	Baumarten																	
Szenario 1	Klima aktuell	obersubalpin																		
	mässiger Klimawandel	hochmontan																		
	starker Klimawandel	hochmontan																		
Szenario 2	Klima aktuell	obersubalpin																		
	mässiger Klimawandel	hochmontan																		
	starker Klimawandel	collin																		
Szenario 3	Klima aktuell	subalpin	Fi	Fi		Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi
	mässiger Klimawandel	hochmontan	Fi	Fi		Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi
	starker Klimawandel	hochmontan	Fi	Fi, Wfö		Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi
Szenario 4	Klima aktuell	subalpin	Fi			Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi
	mässiger Klimawandel	hochmontan	Fi			Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi
	starker Klimawandel	collin	Tei, Wli				Tei	Hbi	Ki, Tei, Sei	Tei	Tei									
Szenario 5	Klima aktuell	subalpin	Fi	Fi		Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi
	mässiger Klimawandel	collin	Tei, Wli	Tei, Wli		Tei	Hbi	Ki, Tei, Sei	Tei	Tei										
	starker Klimawandel	collin	Tei, Wli	Tei, Wli		Tei	Hbi	Ki, Tei, Sei	Tei	Tei										
Szenario 6	Klima aktuell	hochmontan		Fi	Fi															
	mässiger Klimawandel	hochmontan		Fi, Wfö	Fi															
	starker Klimawandel	hochmontan		Fi, Wfö	Fi															
Szenario 7	Klima aktuell	hochmontan		Fi	Fi															
	mässiger Klimawandel	hochmontan		Fi, Wfö	Fi															
	starker Klimawandel	collin		Tei, Wli	Bah, Wli, Sli, Ful															
Szenario 8	Klima aktuell	hochmontan		Fi	Fi															
	mässiger Klimawandel	collin		Tei, Wli	Fi															
	starker Klimawandel	collin		Tei, Wli	Bah, Wli, Sli, Ful															
Szenario 9	Klima aktuell	collin																		
	mässiger Klimawandel	collin																		
	starker Klimawandel	collin																		

Fichtenwälder Teil 2		Standortstyp	60	60*	60A	60E	47H	55	55*	56	mögliche Baumarten	
Klimaszenario	Höhenstufe	Baumarten										
Szenario 1	Klima aktuell	obersubalpin										
	mässiger Klimawandel	hochmontan										
	starker Klimawandel	hochmontan										
Szenario 2	Klima aktuell	obersubalpin										
	mässiger Klimawandel	hochmontan										
	starker Klimawandel	collin										
Szenario 3	Klima aktuell	subalpin	Fi	Fi	Fi	Fi						Fi
	mässiger Klimawandel	hochmontan	Fi	Fi	Wta, Fi	Fi						Fi, Wta
	starker Klimawandel	hochmontan	Fi	Fi	Wta, Fi	Fi						Fi, Wfö, Wta
Szenario 4	Klima aktuell	subalpin	Fi	Fi	Fi	Fi						Fi
	mässiger Klimawandel	hochmontan	Fi	Fi	Wta, Fi	Fi						Wta, Fi
	starker Klimawandel	collin	Fah, Sah, Es, Ki, Sei	Wli	Fah, Sah, Es, Ki, Sei	Ser						Tei, Wli, Hbi, Ki, Sei, Fah, Sah, Es, Ki, Ser
Szenario 5	Klima aktuell	subalpin	Fi	Fi	Fi	Fi						Fi
	mässiger Klimawandel	collin	Fah, Sah, Es, Ki, Sei	Wli	Fah, Sah, Es, Ki, Sei	Ser						Tei, Wli, Hbi, Ki, Sei, Fah, Sah, Es, Ki, Ser
	starker Klimawandel	collin	Fah, Sah, Es, Ki, Sei	Wli	Fah, Sah, Es, Ki, Sei	Ser						Tei, Wli, Hbi, Ki, Sei, Fah, Sah, Es, Ki, Ser
Szenario 6	Klima aktuell	hochmontan	Fi	Fi			Fi	Fi	Fi	Fi	Fi	Fi
	mässiger Klimawandel	hochmontan	Fi	Fi			Fi	Fi	Fi	Fi	Fi	Fi, Wfö
	starker Klimawandel	hochmontan	Fi	Fi			Fi	Fi	Fi	Fi	Fi	Fi, Wfö
Szenario 7	Klima aktuell	hochmontan	Fi	Fi			Fi	Fi	Fi	Fi	Fi	Fi
	mässiger Klimawandel	hochmontan	Fi	Fi			Fi	Wta, Fi	Fi	Fi	Fi	Fi, Wfö, Wta
	starker Klimawandel	collin	Fah, Sah, Es, Ki, Sei	Es, Ki, Tei, Mb, Wli			Tei	Tei	Tei	Hbi		Tei, Wli, Bah, Sli, Ful, Fah, Sah, Es, Ki, Sei, Mb, Hbi
Szenario 8	Klima aktuell	hochmontan	Fi	Fi			Fi	Fi	Fi	Fi	Fi	Fi
	mässiger Klimawandel	collin	Fi	Fi			Fi	Fi	Fi	Fi	Fi	Tei, Wli
	starker Klimawandel	collin	Fah, Sah, Es, Ki, Sei	Es, Ki, Tei, Mb, Wli			Tei	Tei	Tei	Hbi		Tei, Wli, Bah, Sli, Ful, Fah, Sah, Es, Ki, Sei, Mb, Hbi
Szenario 9	Klima aktuell	collin										
	mässiger Klimawandel	collin										
	starker Klimawandel	collin										

Föhrenwälder		Standortstyp	65	65*	68							mögliche Baumarten
Klimaszenario	Höhenstufe	Baumarten										
Szenario 2	Klima aktuell	subalpin										
	mässiger Klimawandel	hochmontan										
	starker Klimawandel	hochmontan										
Szenario 3	Klima aktuell	subalpin										
	mässiger Klimawandel	hochmontan										
	starker Klimawandel	collin										
Szenario 4	Klima aktuell	subalpin										
	mässiger Klimawandel	collin										
	starker Klimawandel	collin										
Szenario 5	Klima aktuell	hochmontan	Wfö	Wfö	Wfö							Wfö
	mässiger Klimawandel	hochmontan	Bfö	Wfö	Wfö							Bfö, Wfö
	starker Klimawandel	collin	Fei	Fei	Tei							Fei, Tei
Szenario 6	Klima aktuell	hochmontan	Wfö	Wfö	Wfö							Wfö
	mässiger Klimawandel	collin	Wfö	Wfö	Wfö							Wfö
	starker Klimawandel	collin	Fei	Fei	Tei							Fei, Tei
Szenario 7	Klima aktuell	collin		Wfö								Wfö
	mässiger Klimawandel	collin		Wfö								Wfö
	starker Klimawandel	collin		Fei								Fei

Testgebiet 3

Arvenwälder		Standortstyp	59	59E							mögliche Baumarten
Klimaszenario	Höhenstufe	Baumarten									
Szenario 1	Klima aktuell	obersubalpin									
	mässiger Klimawandel	obersubalpin									
	starker Klimawandel	hochmontan									
Szenario 2	Klima aktuell	obersubalpin									
	mässiger Klimawandel	subalpin									
	starker Klimawandel	hochmontan									
Szenario 3	Klima aktuell	obersubalpin									
	mässiger Klimawandel	subalpin									
	starker Klimawandel	collin									
Szenario 4	Klima aktuell	obersubalpin		Av							Av
	mässiger Klimawandel	hochmontan		Fi, Wfö							Fi, Wfö
	starker Klimawandel	hochmontan		Fi, Wfö							Fi, Wfö
Szenario 5	Klima aktuell	obersubalpin									
	mässiger Klimawandel	hochmontan									
	starker Klimawandel	collin									
Szenario 6	Klima aktuell	subalpin	Av								Av
	mässiger Klimawandel	hochmontan	Fi								Fi
	starker Klimawandel	hochmontan	Fi								Fi
Szenario 7	Klima aktuell	subalpin	Av								Av
	mässiger Klimawandel	hochmontan	Fi								Fi
	starker Klimawandel	collin	Bah, Wli, Sli, Ful								Bah, Wli, Sli, Ful
Szenario 8	Klima aktuell	subalpin	Av								Av
	mässiger Klimawandel	collin	Bah, Wli, Sli, Ful								Bah, Wli, Sli, Ful
	starker Klimawandel	collin	Bah, Wli, Sli, Ful								Bah, Wli, Sli, Ful
Szenario 9	Klima aktuell	hochmontan									
	mässiger Klimawandel	hochmontan									
	starker Klimawandel	collin									
Szenario 10	Klima aktuell	hochmontan									
	mässiger Klimawandel	collin									
	starker Klimawandel	collin									

Fichtenwälder Teil 1		Standortstyp	53	53*	57BL	57C	57S	57V	58	58L	
Klimaszenario	Höhenstufe	Baumarten									
Szenario 1	Klima aktuell	obersubalpin									
	mässiger Klimawandel	hochmontan									
	starker Klimawandel	hochmontan									
Szenario 2	Klima aktuell	obersubalpin									
	mässiger Klimawandel	hochmontan									
	starker Klimawandel	collin									
Szenario 3	Klima aktuell	subalpin	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi
	mässiger Klimawandel	hochmontan	Fi	Fi, Wfö	Wta, Fi	Wta, Fi	Wta, Fi	Wta, Fi	Wta, Fi	Wta, Fi	Fi
	starker Klimawandel	hochmontan	Fi	Fi, Wfö	Wta, Fi	Wta, Fi	Wta, Fi	Wta, Fi	Wta, Fi	Wta, Fi	Fi
Szenario 4	Klima aktuell	subalpin	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi
	mässiger Klimawandel	hochmontan	Fi	Fi, Wfö	Fi	Wta, Fi	Wta, Fi	Wta, Fi	Wta, Fi	Fi	Fi
	starker Klimawandel	collin	Tei, Wli	Tei, Wli	Bah, Wli, Sli, Ful	Tei	Hbi	Ki, Tei, Sei	Tei	Tei	Tei
Szenario 5	Klima aktuell	subalpin	Fi	Fi		Fi	Fi	Fi	Fi	Fi	Fi
	mässiger Klimawandel	collin	Tei, Wli	Tei, Wli		Tei	Hbi	Fi	Fi	Fi	Fi
	starker Klimawandel	collin	Tei, Wli	Tei, Wli		Tei	Hbi	Ki, Tei, Sei	Tei	Tei	Tei
Szenario 6	Klima aktuell	subalpin	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi
	mässiger Klimawandel	collin	Tei, Wli	Tei, Wli	Bah, Wli, Sli, Ful	Tei	Hbi	Ki, Tei, Sei	Tei	Tei	Tei
	starker Klimawandel	hochmontan	Fi	Fi, Wfö	Wta, Fi	Wta, Fi	Wta, Fi	Wta, Fi	Wta, Fi	Fi	Fi
Szenario 7	Klima aktuell	hochmontan		Fi	Fi						
	mässiger Klimawandel	hochmontan		Fi, Wfö	Fi						
	starker Klimawandel	hochmontan		Fi, Wfö	Fi						
Szenario 8	Klima aktuell	hochmontan		Fi	Fi						
	mässiger Klimawandel	hochmontan		Fi, Wfö	Fi						
	starker Klimawandel	collin		Tei, Wli	Bah, Wli, Sli, Ful						
Szenario 9	Klima aktuell	hochmontan		Fi	Fi						
	mässiger Klimawandel	collin		Fi, Wfö	Fi						
	starker Klimawandel	collin		Tei, Wli	Bah, Wli, Sli, Ful						
Szenario 10	Klima aktuell	collin									
	mässiger Klimawandel	collin									
	starker Klimawandel	collin									

Fichtenwälder Teil 2		Standortstyp	60	60*	60A	60E	47H	55	55*	56	mögliche Baumarten
Klimaszenario	Höhenstufe	Baumarten									
Szenario 1	Klima aktuell	obersubalpin									
	mässiger Klimawandel	hochmontan									
	starker Klimawandel	hochmontan									
Szenario 2	Klima aktuell	obersubalpin									
	mässiger Klimawandel	hochmontan									
	starker Klimawandel	collin									
Szenario 3	Klima aktuell	subalpin	Fi	Fi	Fi	Fi					Fi
	mässiger Klimawandel	hochmontan	Wta, Fi	Wta, Fi	Wta, Fi	Fi					Fi, Wfö, Wta
	starker Klimawandel	hochmontan	Wta, Fi	Wta, Fi	Wta, Fi	Fi					Fi, Wfö, Wta
Szenario 4	Klima aktuell	subalpin	Fi	Fi	Fi	Fi					Fi
	mässiger Klimawandel	hochmontan	Wta, Fi	Wta, Fi	Wta, Fi	Fi					Fi, Wta, Wfö
	starker Klimawandel	collin	Fah, Sah, Es, Ki, Sei	Wli	Fah, Sah, Es, Ki, Sei	Ser					Tei, Bah, Wli, Sli, Ful, Hbi, Ki, Sei, Fah, Sah, Es, Ser
Szenario 5	Klima aktuell	subalpin	Fi	Fi	Fi	Fi					Fi
	mässiger Klimawandel	collin	Fi	Fi	Fi	Fi					Tei, Wli, Hbi, Fi
	starker Klimawandel	collin	Fah, Sah, Es, Ki, Sei	Wli	Fah, Sah, Es, Ki, Sei	Ser					Tei, Wli, Hbi, Ki, Sei, Fah, Sah, Es, Ser
Szenario 6	Klima aktuell	subalpin	Fi	Fi	Fi	Fi					Fi
	mässiger Klimawandel	collin	Fah, Sah, Es, Ki, Sei	Wli	Fah, Sah, Es, Ki, Sei	Ser					Tei, Wli, Bah, Sli, Ful, Hbi, Ki, Tei, Sei, Fah, Sah, Es, Ser
	starker Klimawandel	hochmontan	Wta, Fi	Wta, Fi	Wta, Fi	Fi					Fi, Wta, Wfö
Szenario 7	Klima aktuell	hochmontan	Fi	Fi			Fi	Fi	Fi	Fi	Fi
	mässiger Klimawandel	hochmontan	Fi	Fi			Fi	Wta, Fi	Fi	Fi	Fi, Wfö, Wta
	starker Klimawandel	hochmontan	Fi	Fi			Fi	Wta, Fi	Fi	Fi	Fi, Wfö, Wta
Szenario 8	Klima aktuell	hochmontan	Fi	Fi			Fi	Fi	Fi	Fi	Fi
	mässiger Klimawandel	hochmontan	Fi	Fi			Fi	Wta, Fi	Fi	Fi	Fi, Wfö, Wta
	starker Klimawandel	collin	Fah, Sah, Es, Ki, Sei	Es, Ki, Tei, Mb, Wli			Tei	Tei	Tei	Tei	Tei, Wli, Bah, Sli, Ful, Fah, Sah, Es, Ki, Sei, Mb
Szenario 9	Klima aktuell	hochmontan	Fi	Fi			Fi	Fi	Fi	Fi	Fi
	mässiger Klimawandel	collin	Fi	Fi			Fi	Wta, Fi	Fi	Fi	Fi, Wfö, Wta
	starker Klimawandel	collin	Fah, Sah, Es, Ki, Sei	Es, Ki, Tei, Mb, Wli			Tei	Tei	Tei	Tei	Tei, Wli, Sli, Ful, Fah, Sah, Es, Ki, Sei, Mb
Szenario 10	Klima aktuell	collin									
	mässiger Klimawandel	collin									
	starker Klimawandel	collin									

Föhrenwälder		Standortstyp	65	65*	68	mögliche Baumarten						
Klimaszenario	Höhenstufe	Baumarten										
Szenario 1	Klima aktuell	obersubalpin										
	mässiger Klimawandel	hochmontan										
	starker Klimawandel	hochmontan										
Szenario 2	Klima aktuell	obersubalpin										
	mässiger Klimawandel	hochmontan										
	starker Klimawandel	collin										
Szenario 3	Klima aktuell	subalpin										
	mässiger Klimawandel	hochmontan										
	starker Klimawandel	hochmontan										
Szenario 4	Klima aktuell	subalpin										
	mässiger Klimawandel	hochmontan										
	starker Klimawandel	collin										
Szenario 5	Klima aktuell	subalpin										
	mässiger Klimawandel	collin										
	starker Klimawandel	collin										
Szenario 6	Klima aktuell	hochmontan	Wfö	Wfö	Wfö							Wfö
	mässiger Klimawandel	hochmontan	Bfö	Wfö	Wfö							Bfö, Wfö
	starker Klimawandel	hochmontan	Bfö	Wfö	Wfö							Bfö, Wfö
Szenario 7	Klima aktuell	hochmontan	Wfö	Wfö	Wfö							Wfö
	mässiger Klimawandel	hochmontan	Bfö	Wfö	Wfö							Bfö, Wfö
	starker Klimawandel	collin	Fei	Fei	Tei							Fei, Tei
Szenario 8	Klima aktuell	hochmontan	Wfö	Wfö	Wfö							Wfö
	mässiger Klimawandel	collin	Fei	Fei	Tei							Fei, Tei
	starker Klimawandel	collin	Fei	Fei	Tei							Fei, Tei
Szenario 9	Klima aktuell	collin		Wfö								Wfö
	mässiger Klimawandel	collin		Fei								Fei
	starker Klimawandel	collin		Fei								Fei

Testgebiet 4

Arvenwälder		Standortstyp	59	59C	59E	59L	59V	mögliche Baumarten			
Klimaszenario	Höhenstufe	Baumarten									
Szenario 1	Klima aktuell	obersubalpin		Av	Av	Av	Av				Av
	mässiger Klimawandel	hochmontan		Fi	Fi	Fi	Fi				Fi
	starker Klimawandel	hochmontan		Fi	Fi	Fi	Fi				Fi
Szenario 2	Klima aktuell	obersubalpin		Av	Av	Av	Av				Av
	mässiger Klimawandel	hochmontan		Fi	Fi, Wfö	Fi	Fi				Fi, Wfö
	starker Klimawandel	collin		Bah, Wli, Sli, Ful	Tei, Wli	Tei	Tei				Bah, Wli, Sli, Ful, Tei
Szenario 3	Klima aktuell	obersubalpin									
	mässiger Klimawandel	subalpin									
	starker Klimawandel	hochmontan									
Szenario 4	Klima aktuell	subalpin	Av								Av
	mässiger Klimawandel	hochmontan	Fi								Fi
	starker Klimawandel	hochmontan	Fi								Fi
Szenario 5	Klima aktuell	subalpin	Av								Av
	mässiger Klimawandel	hochmontan	Fi								Fi
	starker Klimawandel	collin	Bah, Wli, Sli, Ful								Bah, Wli, Sli, Ful
Szenario 6	Klima aktuell	subalpin	Av								Av
	mässiger Klimawandel	collin	Bah, Wli, Sli, Ful								Bah, Wli, Sli, Ful
	starker Klimawandel	collin	Bah, Wli, Sli, Ful								Bah, Wli, Sli, Ful

Fichtenwälder Teil 1		Standortstyp	53*	57BL	57C	57M	57V	58	58C	58L	mögliche Baumarten			
Klimaszenario	Höhenstufe	Baumarten												
Szenario 1	Klima aktuell	obersubalpin		Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi			
	mässiger Klimawandel	hochmontan		Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi			
	starker Klimawandel	hochmontan		Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi			
Szenario 2	Klima aktuell	obersubalpin												
	mässiger Klimawandel	hochmontan												
	starker Klimawandel	collin												
Szenario 3	Klima aktuell	subalpin	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi			
	mässiger Klimawandel	hochmontan	Fi, Wfö	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi			
	starker Klimawandel	hochmontan	Fi, Wfö	Fi	Fi	Fi	Fi	Fi	Fi	Fi	Fi			
Szenario 4	Klima aktuell	subalpin	Fi											
	mässiger Klimawandel	hochmontan	Fi, Wfö											
	starker Klimawandel	collin	Tei, Wli		Tei	Tei	Tei, Ki, Rei	Tei	Tei	Tei	Tei			
Szenario 5	Klima aktuell	subalpin	Fi		Fi	Fi	Fi	Fi	Fi	Fi	Fi			
	mässiger Klimawandel	collin	Tei, Wli		Tei	Tei	Ki, Tei, Sei	Tei	Tei	Tei	Tei			
	starker Klimawandel	collin	Tei, Wli		Tei	Tei	Ki, Tei, Sei	Tei	Tei	Tei	Tei			

Fichtenwälder Teil 2		Standortstyp	60	60A	60E	mögliche Baumarten					
Klimaszenario	Höhenstufe	Baumarten									
Szenario 1	Klima aktuell	obersubalpin	Fi	Fi	Fi						Fi
	mässiger Klimawandel	hochmontan	Fi	Fi, Wta	Fi						Fi, Wta
	starker Klimawandel	hochmontan	Fi	Fi, Wta	Fi						Fi, Wta
Szenario 2	Klima aktuell	obersubalpin									
	mässiger Klimawandel	hochmontan									
	starker Klimawandel	collin									
Szenario 3	Klima aktuell	subalpin	Fi	Fi	Fi						Fi
	mässiger Klimawandel	hochmontan	Fi	Fi, Wta	Fi						Fi, Wfö, Wta
	starker Klimawandel	hochmontan	Fi	Fi, Wta	Fi						Fi, Wfö, Wta
Szenario 4	Klima aktuell	subalpin	Fi	Fi	Fi						Fi
	mässiger Klimawandel	hochmontan	Fi	Fi, Wta	Fi						Fi, Wfö, Wta
	starker Klimawandel	collin	Fah, Sah, Es, Ki, Sei	Fah, Sah, Es, Ki, Sei	Ser						Tei, Wli, Ki, Rei, Fah, Sah, Es, Sei, Ser
Szenario 5	Klima aktuell	subalpin	Fi	Fi	Fi						Fi
	mässiger Klimawandel	collin	Fah, Sah, Es, Ki, Sei	Fah, Sah, Es, Ki, Sei	Ser						Tei, Wli, Ki, Sei, Fah, Sah, Es, Ser
	starker Klimawandel	collin	Fah, Sah, Es, Ki, Sei	Fah, Sah, Es, Ki, Sei	Ser						Tei, Wli, Ki, Sei, Fah, Sah, Es, Ser

Anhang E

Validation mit ausgeführten Holzschlägen

[Baumartenverteilung in Prozent]

Übereinstimmung	objektbasierte Klassifikation							ID [Bildanalyse]	pixelbasierte Klassifikation							Übereinstimmung
	Arve	Fichte	Flaumeiche	Lärche	übriges Laubholz	Waldföhre	Weisstanne		Arve	Fichte	Flaumeiche	Lärche	übriges Laubholz	Waldföhre	Weisstanne	
75%	0	7	12	1	19	56	0	IST-59	7	24		27	56		50%	
60%	7	65	3	31	3	61	1	IST-61	65	0	31	3	74	1	60%	
100%	2	29	4	5	8	39	1	IST-62	29	3	14	55		4	50%	
80%	0	75	0	20	2	3	6	IST-63	75	0	20	2	3	3	67%	
60%	0	40	0	2	37	41	0	IST-315	40	4	18	3	2	62	80%	
60%	0	40	0	4	14	43	0	IST-316	40	4	10	0	0	41	60%	
100%	0	20	0	20	35	25	0	IST-317	20	0	15	1	71	13	33%	
60%	2	60	1	7	14	15	11	IST-318	60	1	2	4	1	52	75%	
60%	10	50	0	40	0	0	9	IST-319	10	50	0	40	0	1	60%	
75%	5	70	0	25	3	0	6	IST-321	5	70	0	25	3	14	10	60%
100%	0	29	4	1	11	75	0	IST-687	29	0	11	4	16	55	1	50%
100%	2	85	0	10	5	0	0	IST-711	85	0	10	5	0	0	24	60%
80%	50	10	0	35	5	0	11	IST-792	50	10	4	25	0	26	16	50%
100%	4	80	0	5	5	0	13	IST-794	17	12	4	25	0	26	16	50%
75%	1	10	0	80	10	0	5	IST-804	17	11	0	35	2	1	35	80%
100%	1	63	0	27	3	0	5	IST-805	2	27	1	53	4	0	13	75%
100%	1	80	1	5	5	5	5	IST-1030	80	18	0	5	5	5	5	83%
75%	0	50	1	15	5	20	3	IST-1037	50	4	8	1	40	1	47	50%
80%	1	30	17	8	9	32	2	IST-1255	5	10	13	1	3	64	8	67%
100%	0	29	4	1	9	81	0	IST-1261	0	29	4	1	16	55	0	33%
25%	1	85	1	10	5	0	2	IST-1265	85	0	10	5	0	95	0	60%
80%	1	5	1	5	20	70	1	IST-1266	9	30	0	21	7	1	32	60%
80%	40	19	10	4	15	50	1	IST-1270	40	5	15	0	0	79	0	40%
100%	1	7	21	1	45	14	11	IST-1272	13	10	0	37	21	5	15	67%
100%	1	85	0	8	5	0	1	IST-1635	1	85	0	8	5	0	1	83%
80%	1	60	1	5	10	7	27	IST-1659	2	32	0	27	6	22	12	83%
100%	0	40	0	5	55	82	1	IST-1693	0	60	3	5	10	1	25	100%
67%	2	80	1	15	5	0	1	IST-1709	0	26	3	7	15	1	48	67%
50%	6	50	2	45	7	6	4	IST-1718	40	18	0	15	5	2	23	60%
100%	2	53	1	13	9	1	22	IST-1857	3	50	2	45	1	27	31	75%
100%	0	48	0	17	12	4	19	IST-2278	7	23	1	16	7	3	43	80%
75%	1	80	0	20	5	0	7	IST-2280	1	60	2	5	10	2	49	100%
50%	3	45	1	50	5	0	7	IST-2282	1	43	1	16	2	28	8	60%
100%	35	10	3	53	9	1	2	IST-2284	5	45	2	34	6	8	27	50%
80%	0	41	0	3	6	25	25	IST-2389	35	10	1	50	5	0	0	60%
100%	0	33	0	5	35	26	0	IST-2405	34	16	1	27	6	20	3	60%
100%	0	20	0	50	10	20	20	IST-2553	41	0	3	6	25	25	0	83%
67%	2	45	0	50	5	0	1	IST-2696	1	9	5	10	6	2	66	80%
57%	6	30	6	60	1	10	9	IST-2733	20	10	7	3	30	1	41	60%
67%	8	55	1	21	9	7	2	IST-2853	13	45	0	50	5	2	28	60%
60%	45	51	1	50	5	0	1	IST-2859	16	30	2	60	1	63	9	50%
50%	16	7	9	65	1	0	1	IST-2917	13	10	1	10	5	20	26	50%
50%	8	30	4	60	1	9	0	IST-2925	45	22	2	18	1	24	9	50%
100%	0	10	2	1	8	79	1	IST-2929	2	38	1	6	1	13	40	60%
60%	0	56	0	7	12	20	5	IST-2941	2	37	0	61	2	0	0	50%
100%	1	32	0	62	1	0	4	IST-2951	9	24	1	14	1	11	41	50%
100%	0	20	0	50	25	0	5	IST-3199	0	50	0	10	5	20	15	67%
100%	0	47	0	10	39	2	3	IST-3200	0	3	5	2	32	57	0	50%
100%	3	75	1	20	5	0	3	IST-3234	3	1	3	0	10	85	1	50%
75%	0	93	1	5	2	0	2	IST-3237	0	93	0	2	5	95	0	75%
60%	5	37	1	61	2	47	2	IST-3238	4	38	0	3	60	0	43	60%
80%	0	58	1	14	7	12	3	IST-3244	19	3	0	25	9	0	43	60%
80%	0	50	0	10	5	20	15	IST-3253	2	38	1	6	1	13	40	60%
75%	3	37	2	2	10	85	0	IST-3259	2	37	0	61	2	0	0	50%
50%	7	38	1	38	2	3	0	IST-2951	9	24	1	14	1	11	41	50%
60%	40	1	1	59	6	0	9	IST-2951	0	50	0	10	5	20	15	67%
50%	25	1	0	73	1	0	0	IST-3199	0	3	5	2	32	57	0	50%
100%	0	6	2	0	2	90	0	IST-3199	3	1	3	0	10	85	1	50%
60%	8	78	3	16	11	6	3	IST-3199	4	38	0	3	60	0	43	60%
								IST-3200	40	1	1	59	2	6	25	60%
								IST-3234	23	4	1	38	1	7	1	40%
								IST-3237	25	1	1	73	1	50	0	75%
								IST-3238	36	0	1	55	0	7	1	40%
								IST-3238	40	5	0	5	50	0	4	75%
								IST-3238	27	2	0	0	67	4	40%	
								IST-3238	78	21	1	1	1	9	44	40%