



MASTERARBEIT | MASTER'S THESIS

Titel | Title

Klassifikation von Geröll- und Felsformationen im Hochgebirge
mittels Fernerkundung und Machine learning

verfasst von | submitted by

Mina Sjerobabin BSc

angestrebter akademischer Grad | in partial fulfilment of the requirements for the degree of
Master of Science (MSc)

Wien | Vienna, 2026

Studienkennzahl lt. Studienblatt | Degree
programme code as it appears on the
student record sheet:

UA 066 856

Studienrichtung lt. Studienblatt | Degree
programme as it appears on the student
record sheet:

Masterstudium Kartographie und Geoinformation

Betreut von | Supervisor:

Ass.-Prof. Mag. Dr. Andreas Riedl

Inhalt

Abstract	1
1 Einleitung.....	2
1.1 Problemstellung	2
1.2 Motivation.....	3
1.3 Relevanz der Thematik.....	4
1.4 Forschungsstand	6
1.5 Zielsetzung und Aufbau der Arbeit	10
2 Theoretische Grundlagen	10
2.1 Fernerkundung und Landbedeckungsklassifikation	10
2.2 Definition und Charakterisierung von Fels - und Geröllflächen	12
2.2.1 Felsflächen	13
2.2.2 Geröllflächen	13
2.2.3 Abgrenzung und Relevanz für die Klassifikation	14
2.3 Bisherige Ansätze zur Identifikation von Fels - und Geröllflächen	15
2.4 Auswahl und Begründung der verwendeten Fernerkundungsdaten	18
2.4.1 Auswahlkriterien.....	18
2.4.2 Vergleich potenzieller Datenquellen	19
2.4.3 Begründung der Datenauswahl für diese Arbeit	20
2.5 Topographische Einflussfaktoren.....	21
2.5.1. Schatteneffekte	21
2.5.2. Hangneigung und Exposition	22
2.5.3. Schneebedeckung und saisonale Einflüsse	23
2.6 Machine Learning in der Fernerkundung	24
2.6.1 Klassische Verfahren (Random Forest, SVM)	24
2.6.2 Erweiterte Lernverfahren (Deep Learning - theoretischer Überblick)	25
2.6.3 Vergleich von Random Forest und Convolutional Neural Networks für die Klassifikation alpiner Oberflächen.....	26
2.7 Bewertungsmethoden (Kappa, Precision, Recall).....	28
3 Methodik	30
3.1 Softwaregrundlage und methodische Rahmenbedingungen.....	30
3.2 Datenquellen und Datenauswahl	31
3.2.1 Untersuchungsgebiet und Begründung der Gebietsauswahl	32

3.2.2 Begründung der räumlichen Auflösung (10 m)	33
3.3 Vorverarbeitung in ArcGIS Pro	34
3.3.1 Vorverarbeitung der Sentinel -2 -Daten	34
3.3.2 Topographische Vorverarbeitung des digitalen Höhenmodells (DHM)	35
3.3.3 Ableitung topographischer Variablen (Slope und Aspect)	36
3.4 Feature Engineering	37
3.4.1 Erstellung der Trainingsdaten aus OpenStreetMap (Overpass Turbo)	37
3.4.2 Ableitung von Trainingspunkten innerhalb der OSM -Polygone	39
3.4.3 Extraktion spektraler und topographischer Werte	40
3.4.4 Zusammenführung und räumliche Trennung der Trainings - und Testdaten	40
3.5 Modelltraining mit dem Random -Forest -Klassifikator	41
3.5.1 Vorbereitung der Trainingsdaten	42
3.5.2 Auswahl und Begründung des Klassifikationsverfahrens	42
3.5.3 Konfiguration und Training des Random -Forest -Modells	43
3.5.4 Technische Umsetzung (ArcGIS Pro und arcpy)	44
3.5.5 Ergebnis des Trainingsschrittes	45
3.6 Anwendung des Random -Forest -Modells auf die Sentinel -2 -Daten	45
4. Ergebnisse	47
4.1 Räumliche Verteilung der Klassifikationsergebnisse	47
4.2 Validierung der Klassifikation	48
4.3 Einordnung der Klassifikationsergebnisse	49
5. Diskussion	50
5.1 Interpretation der Ergebnisse	50
5.2 Methodische Herausforderungen und Unsicherheiten	51
5.2.1 Einfluss der Datenbasis und Referenzdaten	51
5.2.2 Einfluss der räumlichen Auflösung und Topographie	52
5.2.3 Grenzen der Klassendefinition und Modellübertragbarkeit	53
5.3 Vergleich mit bestehenden Studien und Literatur	53
5.4 Relevanz für Praxis und Forschung	54
6 Fazit und Ausblick	55
6.1 Zusammenfassung der Erkenntnisse	55
6.2 Empfehlungen für künftige Forschung	56
6.3 Praktische Anwendungsmöglichkeiten	57
Literaturverzeichnis	58

Abbildungsverzeichnis

Abbildung 1: Übersicht der von Thomas et al. (2023) untersuchten Hochgebirgsregionen Hunza (Karakorum), Manaslu und Khumbu (Zentralhimalaya). Die Sentinel -2 - Falschfarbenkomposite (NIR -Rot -Blau) verdeutlichen die typischen Relief -, Schnee - und Geröllmuster des Hochgebirges, deren spektrale und topographische Variabilität die automatisierte Klassifikation von Fels - und Geröllflächen erschwert (nach Thomas et al., 2023).....	3
Abbildung 2: Schematische Darstellung des integrierten Workflows von Thomas et al. (2023) zur Kombination von Convolutional Neural Networks (CNN) und objektbasierter Bildanalyse (OBIA) für die Klassifikation hochalpiner Oberflächen. Der Ansatz nutzt multispektrale und topographische Eingabedaten (z. B. Sentinel -2, Landsat -8, AW3D DEM) und kombiniert spektrale, räumliche und texturale Merkmale zur präzisen Abgrenzung von Oberflächenklassen (nach Thomas et al., 2023).	6
Abbildung 3: Workflow zur Kombination von Convolutional Neural Networks (CNN) und objektbasierter Bildanalyse (OBIA) für die Klassifikation alpiner Oberflächen unter Verwendung multisensoraler Daten (nach Robson et al., 2020).....	7
Abbildung 4: Globale Verteilung der in Maslov et al. (2025) untersuchten Gletscherregionen. Die Karte verdeutlicht die Skalierbarkeit tief lernender Modelle für die automatisierte Erfassung und Klassifikation geomorphologischer Oberflächenstrukturen weltweit (nach Maslov et al., 2025).	8
Abbildung 5: Übersicht verschiedener topographischer Korrekturverfahren (Lambertian, Non -Lambertian und empirische Ansätze) sowie ihrer Anwendung in der Fernerkundung gebirgiger Regionen (nach Singh & Sood, 2018).....	9
Abbildung 6: Beispiele alpiner Untersuchungsgebiete, an denen Fernerkundung und geologische Feldanalysen kombiniert eingesetzt wurden. Die Aufnahmen zeigen verschiedene Fels - und Hangbereiche in Kanada (1 -4) und Italien (5), die zur Untersuchung geomorphologischer Prozesse dienen (nach Stead et al., 2019).	11
Abbildung 7: Radargramme (100 MHz) typischer Lockergesteins - und Felsstrukturen im Hochgebirge. a -b: rockfall -talus; c: debris -flow -talus; d: fluviale Ablagerungen; e: Moräne (Younger Dryas); f: Fels (Dolomit). Die unterschiedlichen Reflexionsmuster zeigen die ausgeprägte interne Heterogenität von Geröllkörpern und verdeutlichen die Abgrenzung zu kompakteren Felsstrukturen (nach Sass, 2007, Fig. 3).	14
Abbildung 8 Lage des Untersuchungsgebiets und der von Rowbotham et al. (2005) analysierten Einzugsgebiete. Die Darstellung zeigt typische topographische Einheiten und morphometrisch abgegrenzte Becken, wie sie in früheren Studien zur Identifikation und Charakterisierung von Schutt - und Geröllflächen herangezogen wurden.	16
Abbildung 9: Übersicht der in Alifu et al. (2020) untersuchten Hochgebirgsregionen (Test 1 und Test 2) mit Sentinel -2 -Bändern 4, 8 und 11. Die Karte zeigt die räumliche Verteilung von Gletscher - und Schuttflächen sowie topographische Variabilität, die Grundlage für multisensorische Klassifikationsanalysen bildet (nach Alifu et al., 2020).	20
Abbildung 10: Vergleich zwischen spektraler Landbedeckungsklassifikation (Level L1) und objektbasierter Landformklassifikation (Level L2) im Reintal (Bayerische Alpen). Durch die Integration topographischer Parameter wie Hangneigung und Exposition konnte die Differenzierung geomorphologischer Einheiten wie Fels -, Geröll - und Vegetationsflächen verbessert werden (nach Schneevoigt et al., 2007).....	23

Abbildung 11: Schematischer Ablauf des überwachten Lernens (Supervised Learning Workflow). Trainings - und Testdaten werden zur Modellbildung, Evaluation und Optimierung verwendet (nach Batta, 2020).	25
Abbildung 12: Beispiel einer Konfusionsmatrix mit Berechnung der Producer's und User's Accuracy (nach de Lange, 2020, S. 493).	29
Abbildung 13: Untersuchungsgebiet Rettenbachferner (Ötztaler Alpen) mit Ausschnitt des verwendeten digitalen Höhenmodells (10 m) und abgeleitetem Hillshade. Quelle: eigene Darstellung auf Basis von data.gv.at (2024).	32
Abbildung 14: Schummerungsdarstellung (Hillshade) des digitalen Höhenmodells (10 m) im Bereich des Rettenbachferners. Die Darstellung simuliert die Geländebeleuchtung und verdeutlicht die morphologische Struktur des stark reliefierten Untersuchungsgebiets.	36
Abbildung 15: Aus OpenStreetMap extrahierte Polygone der Klassen scree (blau) und bare_rock (magenta) im Untersuchungsgebiet des Rettenbachferners, überlagert auf dem Hillshade des digitalen Höhenmodells (10 m). Die Daten wurden über Overpass Turbo mittels einer gezielten Query abgerufen und anschließend in ArcGIS Pro zugeschnitten und als Trainingsdaten für die Klassifikation aufbereitet.	38
Abbildung 16: Darstellung des räumlichen Trainings -/Test -Splits der Stichprobenpunkte im Untersuchungsgebiet. Die westlich der Split -Grenze liegenden Punkte wurden für das Modelltraining verwendet (n = 1.490), die östlichen Punkte dienten der unabhängigen Validierung (n = 758).	41
Abbildung 17: Konfiguration des Random -Forest -Modells im Werkzeug „Train Random Trees Classifier“ (ArcGIS Pro).	44
Abbildung 18: Methodischer Workflow der dreiklassigen Random -Forest -Klassifikation von Fels -, Geröll - und weiteren Oberflächenformen im Untersuchungsgebiet.	46
Abbildung 19: Ergebnis der dreiklassigen Random -Forest -Klassifikation im Untersuchungsgebiet des Rettenbachferners (räumliche Auflösung 10 m). Dargestellt sind die Klassen Bare Rock, Scree und Other Surface.	48
Abbildung 20: Konfusionsmatrix der Validierung mit Overall Accuracy von 62,8 % und Kappa von 0,38.	49

Abkürzungsverzeichnis

CNN - Convolutional Neural Network

DL - Deep Learning

DTM - Digitales Terrainmodell

ESA - European Space Agency

GIS - Geographisches Informationssystem

L2A - Level -2A

ML - Machine Learning

OSM - OpenStreetMap

PA - Producer's Accuracy

RF - Random Forest

UA - User's Accuracy

UAV - Unmanned Aerial Vehicle

Abstract

Diese Masterarbeit untersucht die automatisierte Differenzierung von Geröll- und Felsformationen im Hochgebirge mittels Fernerkundung und maschinellem Lernen. Als Datenbasis dienen frei verfügbare multispektrale Sentinel-2-Aufnahmen sowie digitale Geländemodelle und Orthofotos aus Österreich. Ziel ist es, durch die Anwendung und Evaluierung klassischer Klassifikationsverfahren – insbesondere Random Forest – die Eignung maschineller Lernmethoden für eine präzise Trennung von Geröll- und Felsflächen zu bewerten.

Ein besonderer Schwerpunkt liegt auf der Berücksichtigung topographischer Einflussfaktoren wie Schattenwurf, Hangneigung und Schnee, um die Klassifikationsergebnisse in steilen Gebirgslagen zu verbessern. Die Verarbeitung und Analyse der Daten erfolgt in ArcGIS Pro unter Nutzung der Python-Bibliothek `arcpy`. Die Modelle werden mithilfe etablierter Genauigkeitsmaße (Precision, Recall, Kappa) validiert.

Die Ergebnisse leisten einen Beitrag zur Weiterentwicklung objekt- und datengetriebener Klassifikationsansätze in komplexem alpinen Gelände und liefern praxisrelevante Erkenntnisse für geomorphologische Analysen sowie die naturgefahrenbezogene Forschung im Kontext des Klimawandels.

This master's thesis investigates the automated differentiation of debris and rock formations in high-mountain environments using remote sensing and machine learning. The study is based on freely available multispectral Sentinel-2 imagery, digital elevation models, and orthophotos from Austria. The objective is to evaluate the suitability of classical machine-learning algorithms - particularly Random Forest - for accurately distinguishing between debris and rock surfaces.

Special attention is given to topographic factors such as shading, slope, and snow cover in order to improve classification accuracy in steep alpine terrain. Data processing and analysis are carried out in ArcGIS Pro using the Python library `arcpy`. Model performance is assessed through established accuracy metrics, including Precision, Recall, and the Kappa coefficient. The results contribute to the advancement of object- and data-driven classification approaches in complex alpine landscapes and provide practical insights for geomorphological studies and natural-hazard research in the context of climate change.

1 Einleitung

1.1 Problemstellung

Die automatisierte Differenzierung von Fels - und Geröllformationen im Hochgebirge stellt eine zentrale Herausforderung der modernen Fernerkundung dar. Diese beiden Oberflächentypen besitzen ähnliche spektrale Eigenschaften und treten oft in enger räumlicher Verzahnung auf, was ihre eindeutige Abgrenzung auf Satellitenbildern erheblich erschwert (Schneevoigt et al., 2008; Stead et al., 2019). Hinzu kommt, dass hochalpine Landschaften durch extreme Reliefunterschiede und komplexe topographische Strukturen geprägt sind. Hangneigung, Exposition und Schattenwurf führen zu spektralen Verzerrungen, die eine verlässliche Klassifikation zusätzlich erschweren (Singh & Sood, 2018). Zudem unterliegen Gebirgsregionen starken saisonalen und mikroklimatischen Schwankungen, die das Reflexionsverhalten der Oberflächen dynamisch verändern. Feuchtigkeit, Schneebedeckung oder spärliche Vegetation beeinflussen die spektrale Signatur von Fels - und Geröllflächen und führen zu einer Überlagerung der spektralen Klassen. Dadurch sinkt die Trennschärfe konventioneller Klassifikationsverfahren deutlich, insbesondere bei pixelbasierten Ansätzen, die den räumlichen Kontext nur unzureichend erfassen (Thomas et al., 2023; Robson et al., 2020). Frühere Studien zeigen, dass klassische Verfahren der digitalen Bildklassifikation - etwa Maximum -Likelihood - oder Minimum -Distance -Algorithmen - in komplexem Gebirgsterrain häufig an ihre Grenzen stoßen (Stead et al., 2019). In solchen Umgebungen führen topographische Effekte nicht nur zu Schattenbildung, sondern auch zu variablen Reflexionswinkeln, die das Verhältnis zwischen einfallender und reflektierter Strahlung verändern. Ohne geeignete Korrekturen werden dadurch Hänge mit unterschiedlicher Ausrichtung oder Neigung unterschiedlich hell dargestellt, obwohl sie die gleiche Materialzusammensetzung besitzen (Singh & Sood, 2018). Parallel dazu wird in der Forschung zunehmend auf datengetriebene Ansätze gesetzt, die spektrale, texturale und topographische Merkmale kombinieren, um komplexe Landschaftsmuster robuster zu erfassen (Sharda et al., 2022; Alifu et al., 2020). Insbesondere Verfahren des maschinellen Lernens ermöglichen es, nichtlineare Beziehungen zwischen Prädiktoren und Klassen besser zu modellieren und dadurch die Trennschärfe zu erhöhen. Auch wenn Deep -Learning -Methoden - wie Convolutional Neural Networks (CNNs) - in Studien zur Gletscher - und Geröllklassifikation bereits vielversprechende Ergebnisse zeigen (Thomas et al., 2023; Maslov et al., 2025), sind deren Implementierung und Trainingsaufwand in der praktischen GIS -

Anwendung oft erheblich. Vor diesem Hintergrund ergibt sich die Notwendigkeit, effiziente, reproduzierbare und zugleich praxistaugliche Klassifikationsansätze zu entwickeln, die die komplexen spektralen und topographischen Rahmenbedingungen des Hochgebirges berücksichtigen. Ziel ist es, Verfahren zu identifizieren, die mit frei verfügbaren Daten - insbesondere Sentinel -2 -Aufnahmen und digitalen Geländemodellen - in gängigen GIS -Umgebungen eine robuste Trennung von Fels - und Geröllflächen ermöglichen.




Abbildung 1: Übersicht der von Thomas et al. (2023) untersuchten Hochgebirgsregionen Hunza (Karakorum), Manaslu und Khumbu (Zentralhimalaya). Die Sentinel -2 -Falschfarbenkomposite (NIR -Rot -Blau) verdeutlichen die typischen Relief-, Schnee - und Geröllmuster des Hochgebirges, deren spektrale und topographische Variabilität die automatisierte Klassifikation von Fels - und Geröllflächen erschwert (nach Thomas et al., 2023).

1.2 Motivation

Die alpine Landoberfläche ist nicht nur ein prägendes Element des Hochgebirges, sondern auch ein zentraler Indikator für geomorphologische Prozesse wie Erosion, Massenbewegungen oder Gletscherrückgang. Eine differenzierte Erfassung dieser Prozesse setzt jedoch voraus, dass ihre sichtbaren Oberflächenformen - wie Geröll und Fels - zuverlässig kartiert werden können. Gerade in schwer zugänglichen Regionen, in denen bodengestützte Erhebungen nur eingeschränkt möglich sind, bieten satellitengestützte Fernerkundungsdaten einen vielversprechenden Zugang zur Landschaftsanalyse. Die Motivation dieser Arbeit ergibt sich aus dem Bestreben, die Qualität automatisierter Klassifikationsverfahren in komplexem Gelände zu verbessern. Dabei geht es nicht nur um die theoretische Weiterentwicklung von Methoden, sondern auch um deren konkrete Anwendungsmöglichkeiten in praktischen Kontexten wie der Naturgefareneinschätzung oder dem Umweltmonitoring. Die bisherigen methodischen Ansätze sind in vielen Fällen nicht in der Lage, zwischen spektral ähnlichen Flächen wie Fels und Geröll ausreichend zu unterscheiden - obwohl gerade diese Differenzierung wichtige Informationen über die Stabilität oder Dynamik von Gebieten liefern kann. Mit der geplanten Umsetzung in ArcGIS Pro ergibt sich zudem die Möglichkeit, Machine Learning direkt in eine weit verbreitete GIS-Umgebung zu integrieren. Dadurch wird ein praxisnaher Zugang geschaffen, der sowohl für die wissenschaftliche Forschung als auch für die Anwendung in Verwaltungen oder Planungsbüros relevant sein kann.

1.3 Relevanz der Thematik

Die präzise Unterscheidung von Geröll - und Felsformationen ist nicht nur ein methodisches, sondern auch ein anwendungsbezogenes Schlüsselthema in der Fernerkundung alpiner Räume. Während Fels häufig stabile, geologisch verankerte Strukturen repräsentiert, weist Geröll in vielen Fällen auf rezente geomorphologische Prozesse wie Muren, Hangrutschungen oder den Rückzug von Gletschern hin. Eine getrennte Erfassung dieser Oberflächentypen ermöglicht daher Rückschlüsse auf die Dynamik alpiner Landschaften und liefert wertvolle Informationen zur Bewertung potenzieller Naturgefahren, insbesondere im Kontext klimabedingter Veränderungen (Robson et al., 2020; Stead et al., 2019). Mit dem fortschreitenden Klimawandel nehmen sowohl die Häufigkeit geomorphologischer Prozesse als auch der Bedarf an verlässlichen Monitoringmethoden zu. Fernerkundung bietet dabei die Möglichkeit, großräumige, wiederholbare und objektive Datenerhebungen in schwer zugänglichen Hochgebirgsregionen durchzuführen (de Lange, 2020). Die Herausforderung liegt jedoch weniger in

der Datenverfügbarkeit als in der Wahl geeigneter Klassifikationsmethoden, um spektral ähnliche Oberflächen zuverlässig zu differenzieren. Gerade in alpinen Gebieten wirken topographische Einflüsse und saisonale Veränderungen erheblich auf die Bildauswertung ein. Während diese Problematik in der allgemeinen Fernerkundung vielfach untersucht wurde, bleibt die spezifische Anwendung auf die Trennung von Fels und Geröll bislang unterrepräsentiert (Singh & Sood, 2018; Schneevoigt et al., 2008). Die Einbindung von Machine -Learning -Verfahren, insbesondere in Kombination mit objektbasierter Bildanalyse (OBIA), eröffnet neue Möglichkeiten für die Landbedeckungsklassifikation. Solche Ansätze erlauben es, neben spektralen auch räumliche und texturale Informationen in die Modellbildung einzubeziehen (Thomas et al., 2023; Sharda et al., 2022). Bisher wurde diese Methodenkombination vor allem im Kontext von Gletscherflächen oder Schuttbedeckungen eingesetzt (Robson et al., 2020; Alifu et al., 2020); eine gezielte Anwendung auf die Unterscheidung von Fels - und Geröllformationen steht jedoch noch aus. Die Relevanz dieser Arbeit ergibt sich somit aus einer klaren Forschungslücke an der Schnittstelle zwischen Fernerkundung, Machine Learning und Georisikoanalyse. Sie leistet einen Beitrag zur methodischen Weiterentwicklung der automatisierten Landbedeckungsklassifikation in alpinen Regionen und untersucht gleichzeitig die praktische Umsetzbarkeit solcher Ansätze in einer anwendungsorientierten GIS -Umgebung wie ArcGIS Pro, unter Nutzung frei verfügbarer Datengrundlagen und reproduzierbarer Workflows.

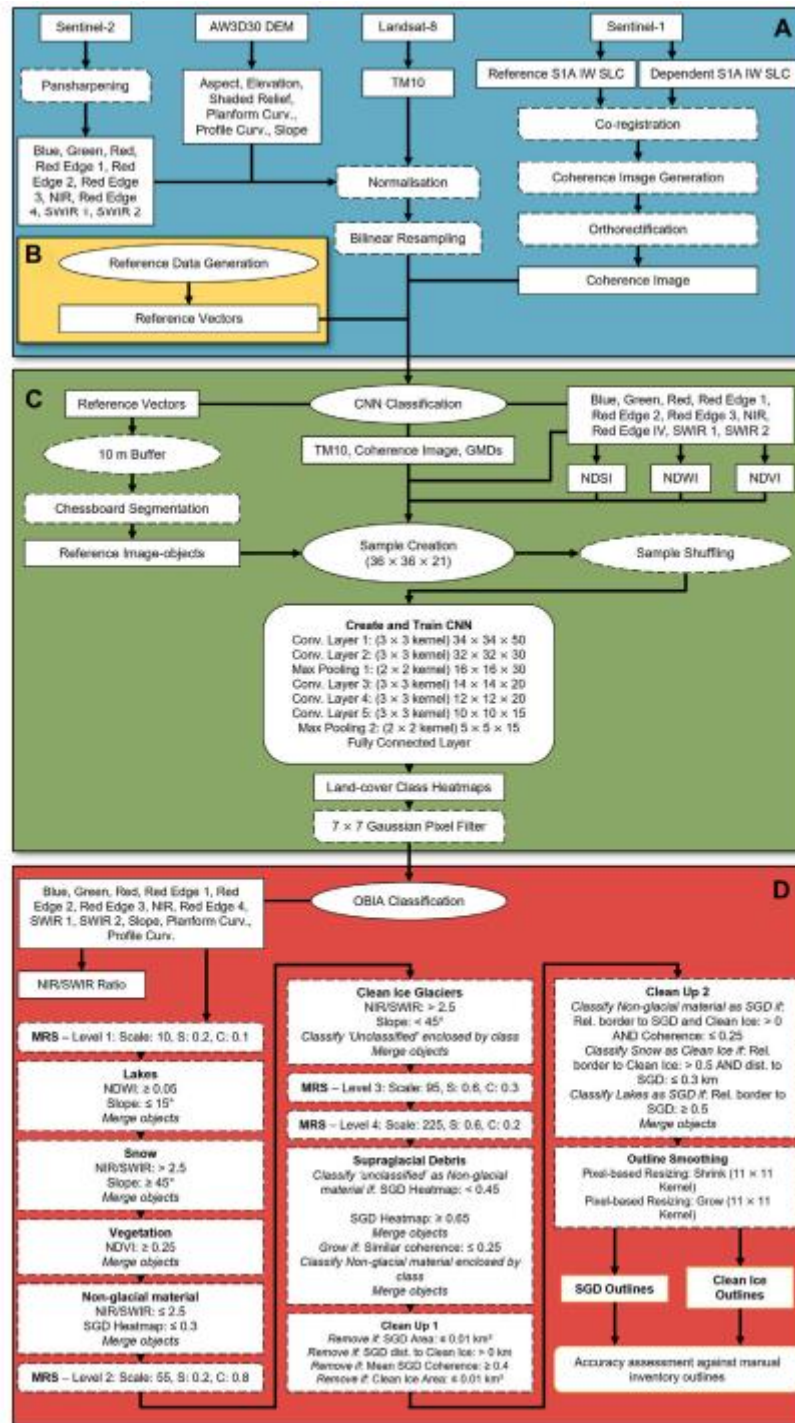


Abbildung 2: Schematische Darstellung des integrierten Workflows von Thomas et al. (2023) zur Kombination von Convolutional Neural Networks (CNN) und objektbasierter Bildanalyse (OBIA) für die Klassifikation hochalpiner Oberflächen. Der Ansatz nutzt multispektrale und topographische Eingabedaten (z. B. Sentinel -2, Landsat -8, AW3D DEM) und kombiniert spektrale, räumliche und texturale Merkmale zur präzisen Abgrenzung von Oberflächenklassen (nach Thomas et al., 2023).

1.4 Forschungsstand

Multispektrale Satellitenbilddaten wie Sentinel -2 und Landsat gehören seit vielen Jahren zu den zentralen Datenquellen in der alpinen Fernerkundung. Ihre Anwendung in GIS -gestützten

Klassifikationsverfahren hat sich besonders bei der Kartierung von Gletschern, Felsformationen und Vegetationsflächen bewährt (Delalay et al., 2019; Zhang et al., 2019; Alifu et al., 2020). Die hohe spektrale Auflösung dieser Sensoren ermöglicht eine grundlegende Unterscheidung unterschiedlicher Landbedeckungstypen, stößt jedoch bei ähnlichen Oberflächenmerkmalen - wie sie bei Fels- und Geröllflächen vorkommen - an ihre Grenzen. Vor diesem Hintergrund gewinnen datengetriebene Verfahren zunehmend an Bedeutung. Insbesondere Machine-Learning-Algorithmen wie Random Forest, Support Vector Machines und tiefe neuronale Netze (CNNs) haben sich in den letzten Jahren als leistungsfähige Alternativen zu klassischen Klassifikatoren etabliert (Robson et al., 2020; Maslov et al., 2025; Alifu et al., 2020). Ihre Stärke liegt in der Fähigkeit, nicht nur spektrale, sondern auch räumliche und texturale Merkmale in die Analyse einzubeziehen. Die Studien von Robson et al. (2020) und Thomas et al. (2023) zeigen, dass insbesondere die Kombination von CNNs mit objektbasierter Bildanalyse (OBIA) zu einer deutlichen Steigerung der Klassifikationsgenauigkeit führen kann.




Abbildung 3: Workflow zur Kombination von Convolutional Neural Networks (CNN) und objektbasierter Bildanalyse (OBIA) für die Klassifikation alpiner Oberflächen unter Verwendung multisensoraler Daten (nach Robson et al., 2020).

Maslov et al. (2025) demonstrieren in einer globalen Studie zur Gletscherkartierung, dass Deep-Learning-Modelle in der Lage sind, manuelle Expertenabgrenzungen nahezu zu

reproduzieren. Diese Ergebnisse verdeutlichen das Potenzial skalierbarer Deep -Learning -Ansätze, auch wenn die spezifische Trennung von Fels - und Geröllflächen bislang kaum untersucht wurde. Weitere Arbeiten befassen sich mit der Optimierung von Klassifikationsmodellen durch gezieltes Feature Engineering (Sharda et al., 2022) oder der Integration multisensoraler Datensätze. So kombinieren Alifu et al. (2020) Daten aus Sentinel -1 (SAR), Sentinel -2 (MSI), Landsat -8 (OLI) sowie digitale Geländemodelle, um mithilfe von Random Forest eine robuste Klassifikation supraglazialer Flächen zu erreichen. Yang et al. (2024) nutzen hochauflösende GF -2 -Aufnahmen und ein Attention -U -Net -Modell, um supraglaziale Geröllflächen mit einer Genauigkeit von über 94 % zu identifizieren. Obwohl sich diese Ansätze nicht direkt auf die Unterscheidung von Fels und Geröll beziehen, zeigen sie die wachsende Leistungsfähigkeit tief lernender Modelle zur Erfassung komplexer geomorphologischer Strukturen.




Abbildung 4: Globale Verteilung der in Maslov et al. (2025) untersuchten Gletscherregionen. Die Karte verdeutlicht die Skalierbarkeit tief lernender Modelle für die automatisierte Erfassung und Klassifikation geomorphologischer Oberflächenstrukturen weltweit (nach Maslov et al., 2025).

Trotz dieser Fortschritte bestehen in hochalpinen Gebieten weiterhin erhebliche Herausforderungen. Topographisch bedingte Effekte wie Schattenwurf, Hangneigung und Exposition beeinflussen die spektrale Signatur der Oberflächen und erschweren eine saubere Trennung spektral ähnlicher Klassen (Singh & Sood, 2018; Stead et al., 2019; Whalley, 2024).

Technique	Category	Characteristic	Outcomes	Examples
Cosine (Teillet <i>et al.</i> 1982)	Lambertian	It is based on the assumption that total irradiance received at a pixel is directly proportional to cosine angle.	The cosine correction shows the higher level of difference with increasing its value, especially at higher slopes.	LULC ¹ (Civco 1989).
SCS (Sun Canopy Sensor) (Gu & Gillespie 1998)	Lambertian	It normalizes the sunlit area within a pixel without varying the sun sensor orientation, geometry and structure of the canopy.	It delivers more appropriate output over forest region. It overestimates the radiance that do not characterized the diffuse radiance effectively.	Forest terrain (Soenen & Peddle 2005); Landsat ETM+ ² (Gao & Zhang 2009); IKONOS (Fan <i>et al.</i> 2014).
SCS+C (Soenen <i>et al.</i> 2005)	Lambertian	A semi-empirical coefficient 'C' is introduced in SCS for better characterization of diffused irradiance.	It represented better diffuse irradiance for the entire range of slope-aspect combinations.	Forest terrain (Soenen & Peddle 2005); ETM+ ² (Gao & Zhang 2009).
Minnaert Costant (Minnaert 1941; Smith <i>et al.</i> 1980; Colby 1991)	Non-Lambertian	It depends on the type of surface and spectral wavelength bands involved. It mainly used for photometric analysis of lunar surface.	Minnaert correction is found to be less effective over snow-covered regions (Mishra <i>et al.</i> 2009b)	ETM+ ² (Gao & Zhang 2009); Land covered with AWiFS ³ (Mishra <i>et al.</i> 2009b);
C-Correction (Teillet <i>et al.</i> 1982)	Non-Lambertian	It is analogous to the influence of diffused sky irradiance.	It compensates the low levels of direct illumination more effectively across all slope-aspect combinations.	Forest cover with TM ⁴ (Raino <i>et al.</i> 2003); AWiFS ³ (Mishra <i>et al.</i> 2009b, Singh <i>et al.</i> 2011).
Minnaert-SCS (Reeder 2002)	Non-Lambertian	It includes the features of Minnaert constant and SCS correction.	It shows the greater decrease in the three-dimensional relief effect.	Hardwood forest regions with ETM+ ² (Gao & Zhang 2009); Shrub forest leaf biomass with ZY-3 ⁴ (Gao <i>et al.</i> 2014).
Single-stage normalization (Civco 1989)	Empirical	It retains the mean spectral response of the imagery while reducing the variance in similar land cover classes.	Results are less effective under low illumination area. (Nichole <i>et al.</i> 2009).	Snow covered with AWiFS ³ (Mishra <i>et al.</i> 2009b)
Two-stage normalization (Civco 1989)	Empirical	It normalizes the radiance by introducing an empirically estimated calibration coefficient 'C'	It does not equalize the radiance values with respect to south/north aspect.	Forest terrain with IKONOS (Nichol <i>et al.</i> 2006); Land cover with AWiFS ³ (Mishra <i>et al.</i> 2009b)
Slope Match (SM) (Nichol <i>et al.</i> 2006)	Empirical	It normalizes the radiance to the mean values of the bright slope instead of overall mean as in two stage normalization (Civco 1989).	It delivers the flat surface representation of the original imagery and 3D relief effects is lost.	LULC with IKONOS; AWiFS ³ (Mishra <i>et al.</i> 2009); MODIS ⁵ (Mishra <i>et al.</i> 2010).
Variable Empirical Coefficient Algorithm (VECA) (Gao & Zhang 2009)	Empirical	It includes an adjustment factor (λ). It decreases with increase in $\cos i$ and increases with decrease in $\cos i$.	The visual effect on slopes towards Sun and opposite from Sun (with same class type) appear to have similar brightness.	Forest region with ETM+ ²

¹ LULC : Land-use and land-cover (LULC)

² ETM+ : Enhanced Thematic Mapper Plus

³ AWiFS : Advanced WideField Sensor

⁴ ZY-3 : Zi-Yuan 3

⁵ TM : Thematic Mapper

⁶ MODIS : Moderate Resolution Imaging Spectroradiometer

Abbildung 5: Übersicht verschiedener topographischer Korrekturverfahren (Lambertian, Non -Lambertian und empirische Ansätze) sowie ihrer Anwendung in der Fernerkundung gebirgiger Regionen (nach Singh & Sood, 2018).

Viele Studien erkennen diese Problematik an, behandeln sie jedoch nur am Rande. Eine konsequente Integration topographischer Parameter in maschinelle Lernverfahren ist bislang nur vereinzelt umgesetzt worden (Mulders *et al.*, 2001; Alifu *et al.*, 2020).

Auch multitemporale Datensätze, die saisonale Veränderungen in Schneebedeckung oder Oberflächenfeuchte abbilden könnten, werden bisher nur selten in ML -Modelle eingebunden. Dabei zeigen Studien, dass die Kombination aus zeitlich variablen Daten und topographischen Informationen das Potenzial besitzt, typische Fehlklassifikationen zwischen Fels und Geröll signifikant zu reduzieren (Maslov *et al.*, 2025; Zhang *et al.*, 2019). Die bisherige Forschung liefert somit wesentliche methodische Grundlagen für die automatisierte Klassifikation alpiner Oberflächen. Gleichzeitig zeigt sich eine deutliche Forschungslücke hinsichtlich der gezielten Anwendung und Evaluierung maschineller Lernverfahren zur Differenzierung von Fels - und Geröllformationen im Hochgebirge.

1.5 Zielsetzung und Aufbau der Arbeit

Ziel dieser Arbeit ist es, einen datenbasierten Ansatz zur automatisierten Differenzierung von Geröll - und Felsformationen im Hochgebirge zu entwickeln und dessen Potenzial anhand eines konkreten Anwendungsbeispiels zu untersuchen. Im Mittelpunkt steht die Frage, inwieweit sich durch den Einsatz klassischer maschineller Lernverfahren - insbesondere Random Forest und Support Vector Machines - die Trennschärfe zwischen diesen beiden, spektral ähnlich reflektierenden Landbedeckungstypen verbessern lässt. Ein besonderes Augenmerk liegt auf der Integration topographischer Zusatzinformationen in das Klassifikationsmodell. Dazu zählen digitale Geländemodelle (DTM/DSM) sowie optische Indizes, die zur Reduktion von Störeinflüssen wie Schattenwurf oder saisonalen Veränderungen beitragen. Die Umsetzung erfolgt vollständig in ArcGIS Pro, wobei die in der Software integrierten Machine -Learning - Funktionalitäten und die Python -Bibliothek arcpy genutzt werden. Als primäre Datenquelle dienen Sentinel -2 -Aufnahmen, die aufgrund ihrer hohen räumlichen und spektralen Auflösung sowie freien Verfügbarkeit besonders geeignet sind. Der Aufbau der Arbeit gliedert sich in sechs Kapitel. Kapitel 1 führt in das Thema ein, formuliert die Problemstellung, Motivation, Relevanz und Zielsetzung. Kapitel 2 behandelt die theoretischen Grundlagen zu Fernerkundung, Satellitendaten, topographischen Einflussfaktoren sowie maschinellen Lernverfahren. In Kapitel 3 wird die methodische Umsetzung beschrieben - von der Datenauswahl und Vorverarbeitung über das Feature Engineering bis hin zur Modellierung, Validierung und Bewertung. Kapitel 4 präsentiert die Ergebnisse der Klassifikation, während Kapitel 5 diese kritisch diskutiert und methodisch einordnet. Den Abschluss bildet Kapitel 6 mit einer Zusammenfassung der zentralen Erkenntnisse und einem Ausblick auf zukünftige Forschungs - und Anwendungsperspektiven.

2 Theoretische Grundlagen

2.1 Fernerkundung und Landbedeckungsklassifikation

Die Fernerkundung bildet eine der zentralen Grundlagen für die Analyse und Kartierung von Landoberflächen, insbesondere in schwer zugänglichen Gebirgsregionen. Sie ermöglicht die Erfassung großräumiger Daten über Sensoren auf Satelliten oder Flugplattformen, ohne direkten Kontakt zur Erdoberfläche (de Lange, 2020). Dabei werden Strahlungsinformationen in

unterschiedlichen Spektralbändern aufgezeichnet, die Rückschlüsse auf physikalische Eigenschaften von Gestein, Vegetation, Schnee oder Wasser erlauben. Durch die stetige Verbesserung räumlicher, spektraler und radiometrischer Auflösungen haben Fernerkundungsdaten in den letzten Jahrzehnten erheblich an Bedeutung für die Geomorphologie und Landbedeckungsanalyse gewonnen (Stead et al., 2019).




Abbildung 6: Beispiele alpiner Untersuchungsgebiete, an denen Fernerkundung und geologische Feldanalysen kombiniert eingesetzt wurden. Die Aufnahmen zeigen verschiedene Fels- und Hangbereiche in Kanada (1 -4) und Italien (5), die zur Untersuchung geomorphologischer Prozesse dienen (nach Stead et al., 2019).

Ein wesentlicher Anwendungsbereich ist die Klassifikation von Landbedeckungstypen, also die Zuordnung einzelner Pixel oder Objekte zu vordefinierten Kategorien wie Fels, Geröll, Vegetation oder Eis. Diese Landbedeckungsklassifikation bildet die Grundlage vieler geomorphologischer und glaziologischer Untersuchungen, da sie Veränderungen in der Landschaft quantitativ erfassbar macht (Tiwari et al., 2019). Klassifikationsverfahren können prinzipiell in überwachte und unüberwachte Methoden unterteilt werden. Während unüberwachte Ansätze (z. B. K-Means oder ISODATA) Daten nach spektraler Ähnlichkeit gruppieren, verwenden überwachte Verfahren (z. B. Random Forest oder Support Vector Machines) Trainingsdaten bekannter Klassen, um unbekannte Pixel zuzuordnen (de Lange, 2020; Sharda et al., 2022).

In Gebirgsregionen stellt die Klassifikation jedoch eine besondere Herausforderung dar. Faktoren wie starke topographische Reliefenergie, Schattenwurf, variable Beleuchtungsbedingungen und die Überlagerung verschiedener Materialien (z. B. Fels, Schnee und Vegetation)

führen zu spektraler Ähnlichkeit zwischen Klassen, was die Trennschärfe klassischer pixelbasierter Verfahren reduziert (Singh & Sood, 2018). Um diese Einschränkungen zu überwinden, wird zunehmend auf objektbasierte Bildanalyse (OBIA) und Machine -Learning -Ansätze zurückgegriffen. Diese Verfahren kombinieren spektrale, texturale und topographische Informationen und ermöglichen so eine deutlich robustere Klassifikation komplexer Landformen (Robson et al., 2020; Thomas et al., 2023). Fernerkundungsdaten wie Sentinel -2 oder Landsat -8 bieten aufgrund ihrer multispektralen Eigenschaften eine ideale Datengrundlage für solche Analysen. Sentinel -2 liefert mit einer Auflösung von 10 -20 m multispektrale Informationen, die besonders für großflächige Kartierungen von Fels - und Geröllflächen geeignet sind (Alifu et al., 2020; Tiwari et al., 2019). Durch die Kombination optischer und topographischer Parameter (z. B. Hangneigung oder Höhenlage aus digitalen Geländemodellen) können auch feine Unterschiede zwischen geomorphologischen Klassen erkannt werden (Schneevoigt et al., 2007). In den letzten Jahren hat der Einsatz von Deep -Learning -Verfahren in der Fernerkundung neue Möglichkeiten eröffnet. Convolutional Neural Networks (CNNs) können komplexe Muster in hochauflösenden Bilddaten automatisch erkennen und ermöglichen dadurch eine präzisere Klassifikation auch in heterogenen Gebirgslandschaften (Maslov et al., 2025; Robson et al., 2020). Studien zeigen, dass durch die Kombination von Deep -Learning -Modellen mit objektbasierten Methoden (OBIA) die Genauigkeit bei der Erkennung von Fels - und Geröllflächen deutlich gesteigert werden kann (Thomas et al., 2023).

Insgesamt stellt die Fernerkundung damit ein leistungsfähiges Werkzeug zur Erfassung, Analyse und Klassifikation von Landbedeckung im Hochgebirge dar. Die Kombination klassischer multispektraler Verfahren mit modernen Machine -Learning - und Deep -Learning -Ansätzen bietet dabei das Potenzial, sowohl räumliche Genauigkeit als auch inhaltliche Aussagekraft geomorphologischer Karten erheblich zu verbessern.

2.2 Definition und Charakterisierung von Fels - und Geröllflächen

Die Unterscheidung zwischen Fels - und Geröllflächen bildet einen zentralen Bestandteil der geomorphologischen Analyse alpiner Landschaften. Beide Flächentypen sind eng mit den dominierenden Prozessen des Hochgebirges verknüpft und weisen klar unterscheidbare geologische und morphologische Eigenschaften auf, die für eine automatisierte Erfassung mittels Fernerkundung von besonderer Bedeutung sind.

2.2.1 Felsflächen

Felsflächen umfassen oberflächlich freiliegende Gesteinsformationen, die durch eine hohe strukturelle Geschlossenheit gekennzeichnet sind. Die Gesteinsmasse ist fest miteinander verbunden, wodurch kompakte Einheiten wie Wände, Grate oder massive Hangabschnitte entstehen. Ihre Erscheinungsform wird durch lithologische Eigenschaften, tektonische Vorgaben sowie Verwitterungs- und Erosionsprozesse bestimmt (Stead et al., 2019; Schneevoigt et al., 2007). In hochalpinen Regionen treten Felsbereiche häufig dort zutage, wo Gletscher oder Schuttkörper Material entfernen und neue Oberflächen exponieren.

Die physikalischen Eigenschaften von Fels - etwa eine hohe Dichte und geringe Porosität - führen zu klar unterscheidbaren geophysikalischen Signaturen, die in seismischen oder elektrischen Messungen gut erkennbar sind (Sass, 2007). Auch in der Fernerkundung zeigt sich ein relativ stabiles Reflexionsverhalten, das vor allem von der Mineralzusammensetzung und der Oberflächenverwitterung beeinflusst wird. Schattenwurf und mikroskalige Rauigkeitsunterschiede können die spektrale Variabilität zwar erhöhen, insgesamt bleibt sie jedoch deutlich geringer als bei locker aufgebauten Oberflächen (Thomas et al., 2023; Singh & Sood, 2018).

2.2.2 Geröllflächen

Geröllflächen bestehen aus lockeren Gesteinsfragmenten, die durch mechanische Verwitterung und gravitative Umlagerung entstehen. Die Korngrößen reichen von feinem Schutt bis zu groben Blöcken, die sich in Schuttfächern, Rinnen oder ausgedehnten Hangschuttdecken ansammeln (Rowbotham et al., 2005; Lucas et al., 2017). Da die einzelnen Partikel keine feste Bindung aufweisen, verändern sich Geröllkörper durch Nachlieferung, Umlagerung und interne Setzungsprozesse fortlaufend. Ihre interne Struktur ist oft unregelmäßig aufgebaut: Unterschiede in Materialgröße, Schichtung oder Hohlräumen führen zu stark variierenden physikalischen Eigenschaften, die auch in geophysikalischen Messungen sichtbar werden (Sass, 2007). Die Oberflächenrauigkeit ist ausgeprägt, und kleinskalige Unterschiede in der Orientierung der Blockoberflächen erzeugen deutliche Helligkeits- und Schattenmuster. Fernerkundungsdaten reflektieren diese Heterogenität durch ein stark variierendes spektrales Verhalten, das zusätzlich durch Vegetation oder Feuchteanteile beeinflusst werden kann (Singh & Sood, 2018; Robson et al., 2020; Sharda et al., 2022).




Abbildung 7: Radargramme (100 MHz) typischer Lockergesteins- und Felsstrukturen im Hochgebirge. a -b: rockfall -talus; c: debris -flow -talus; d: fluviale Ablagerungen; e: Moräne (Younger Dryas); f: Fels (Dolomit). Die unterschiedlichen Reflexionsmuster zeigen die ausgeprägte interne Heterogenität von Geröllkörpern und verdeutlichen die Abgrenzung zu kompakteren Felsstrukturen (nach Sass, 2007, Fig. 3).

2.2.3 Abgrenzung und Relevanz für die Klassifikation

Fels - und Geröllflächen unterscheiden sich grundlegend in ihrem inneren Aufbau, ihrer Stabilität und den Prozessen, die zu ihrer Entstehung beitragen. Fels stellt ein dauerhaftes Strukturelement der Gebirgslandschaft dar, während Geröllkörper sensibel auf aktuelle geomorphodynamische Entwicklungen reagieren und häufig als Hinweis auf aktive Materialverlagerung dienen (Stead et al., 2019; Rowbotham et al., 2005). Diese Gegensätze spiegeln sich in mehreren Eigenschaften wider, die für die Klassifikation von Bedeutung sind:

- Strukturelle Kohärenz: fest verbundene Gesteinsmassen versus lockere, ungebundene Ablagerungen
- Oberflächencharakter: vergleichsweise glatte und einheitliche Felsoberflächen versus stark strukturiertes, heterogenes Schuttmaterial
- Spektrales Verhalten: eher stabile Reflexionseigenschaften bei Fels, hohe Variabilität bei Geröll
- Lagetypen im Relief: Fels überwiegend in exponierten Hangbereichen, Geröll in akkumulierenden Lagen wie Rinnen und Hangfüßen

Studien zeigen, dass die rein spektrale Trennung beider Klassen häufig unzureichend ist und erst die Einbeziehung topographischer und texturaler Merkmale robuste Ergebnisse

ermöglicht (Schneevoigt et al., 2007; Sharda et al., 2022; Thomas et al., 2023). Diese Merkmalskombination bildet die Grundlage für die später angewandte Klassifikationsmethode.

2.3 Bisherige Ansätze zur Identifikation von Fels - und Geröllflächen

Die Erfassung von Fels - und Geröllflächen hat in der geomorphologischen Forschung eine lange Tradition und umfasst unterschiedliche methodische Ansätze. Diese reichen von klassischen Geländeaufnahmen über geophysikalische Verfahren bis hin zu zunehmend automatisierten Auswertungen von Fernerkundungsdaten. Die Methoden unterscheiden sich hinsichtlich ihres räumlichen Maßstabs, der Erfassbarkeit interner Strukturen sowie ihrer Übertragbarkeit auf größere Untersuchungsgebiete. Frühere Arbeiten basieren häufig auf direkten geologischen und geomorphologischen Kartierungen, bei denen Geländeformen auf Basis ihrer äußeren Erscheinung, ihrer Materialeigenschaften und ihrer Position im Hangsystem beschrieben wurden. Solche Untersuchungen bieten eine hohe Detailtiefe, sind jedoch zeit - und arbeitsintensiv und nur bedingt auf größere Regionen übertragbar (Rowbotham et al., 2005). Die Abbildung verdeutlicht den typischen methodischen Ansatz dieser Studien, bei dem geomorphologisch relevante Einheiten zunächst über DEM -basierte morphometrische Analysen abgegrenzt und anschließend hinsichtlich ihrer Materialeigenschaften sowie Prozessdynamiken untersucht wurden.




Abbildung 8 Lage des Untersuchungsgebiets und der von Rowbotham et al. (2005) analysierten Einzugsgebiete. Die Darstellung zeigt typische topographische Einheiten und morphometrisch abgegrenzte Becken, wie sie in früheren Studien zur Identifikation und Charakterisierung von Schutt- und Geröllflächen herangezogen wurden.

Geophysikalische Methoden wie elektrische Widerstandsmessungen oder seismische Verfahren dienen dazu, die Mächtigkeit und interne Struktur von Schuttkörpern zu bestimmen und sie von kompakten Felskörpern abzugrenzen (Sass, 2007; Lucas et al., 2017). Diese Ansätze liefern detaillierte Informationen zu Tiefe, Porosität und Blockanteil, sind jedoch primär für punktuelle oder profilartige Untersuchungen geeignet und nur eingeschränkt auf größere Gebirgsregionen übertragbar. Mit dem verstärkten Einsatz von Satelliten- und Luftbilddaten verlagerte sich die Forschung zunehmend in Richtung fernerkundungsbasierter Kartierung. Frühere Anwendungen basierten auf visueller Interpretation von Luftbildern oder Orthofotos, bei der Fels- und Geröllflächen anhand von Textur, Farbe und Reliefposition unterschieden wurden (Stead et al., 2019). Diese Verfahren sind nachvollziehbar, beinhalten jedoch subjektive Elemente und erfordern erfahrene Interpret*innen. Automatisierte Klassifikationen wurden zunächst vor allem im Rahmen allgemeiner Landbedeckungs- und Gletscherstudien entwickelt. Pixelbasierte Verfahren auf Grundlage multispektraler Satellitendaten zeigten jedoch Einschränkungen bei der Erfassung heterogener Schuttflächen, da diese starke spektrale Schwankungen aufweisen und Schatteneffekte zu hoher intra-klassen Variabilität führen können (Singh & Sood, 2018). In Studien zu debris-covered glaciers wurde wiederholt betont,

dass spektrale Merkmale allein häufig nicht ausreichen, um blockiges Material zuverlässig von freiliegendem Fels zu unterscheiden (Robson et al., 2020; Alifu et al., 2020).

Zur Überwindung dieser Einschränkungen wurden objektbasierte und texturorientierte Ansätze entwickelt, bei denen zusätzlich Formparameter, Segmentgrößen und Texturmerkmale berücksichtigt werden (Thomas et al., 2023). Auch Reliefparameter wie Hangneigung, Exposition oder Geländeform wurden integriert, da bestimmte Lagen im Hangsystem eng mit der Entstehung von Fels - oder Geröllkörpern verknüpft sind (Schneevoigt et al., 2007). In jüngerer Zeit kommen vermehrt Machine -Learning -Verfahren zum Einsatz, die spektrale und topographische Variablen simultan verarbeiten können. Random -Forest -Modelle haben sich als robust gegenüber Rauschen und komplexen Merkmalskombinationen erwiesen (Tiwari et al., 2019; Sharda et al., 2022). Auch Deep -Learning -Ansätze wie Convolutional Neural Networks zeigen vielversprechende Ergebnisse, insbesondere bei hochauflösenden Bilddaten (Robson et al., 2020; Maslov et al., 2025), erfordern jedoch große Trainingsdatensätze und eine intensive Modelloptimierung. Trotz dieser methodischen Fortschritte treten in der automatisierten Erfassung von Fels - und Geröllflächen wiederkehrende Fehlklassifikationen auf. Besonders problematisch sind Übergangsbereiche sowie spektral ähnliche Oberflächen. Blockreiche Geröllflächen weisen häufig hohe Reflexionswerte auf und werden daher mit freiliegendem Fels verwechselt, insbesondere bei geringer Vegetationsbedeckung. Umgekehrt können stark zerklüftete oder teilweise mit Lockermaterial überdeckte Felsbereiche spektrale Eigenschaften von Geröllfeldern annehmen. Ein weiteres zentrales Problem stellen Mischpixel bei mittlerer räumlicher Auflösung dar. Bei 10 -m -Satellitendaten können innerhalb eines Pixels mehrere Materialtypen auftreten, was die eindeutige Klassenzuweisung erschwert (Singh & Sood, 2018). Zusätzlich führen topographisch bedingte Beleuchtungsunterschiede und Schatteneffekte zu variierenden spektralen Signaturen identischer Materialien. Diese Faktoren erhöhen die Verwechslungswahrscheinlichkeit zwischen Fels - und Geröllflächen und gelten als zentrale Herausforderung pixelbasierter Klassifikationen im Hochgebirge.

Trotz zahlreicher geomorphologischer, geophysikalischer und fernerkundungsbasierter Studien wurde die gezielte, systematische Unterscheidung zwischen freiliegendem Fels und ungebundenem Geröll als eigenständige Zielklassen bislang nur selten untersucht. Viele Arbeiten konzentrieren sich auf Gletscherflächen oder allgemeine Landbedeckungskategorien, in denen Fels und Geröll gemeinsam oder nur grob differenziert auftreten.

Insbesondere bei multispektralen Satellitendaten mittlerer räumlicher Auflösung wie Sentinel-2 fehlt bislang ein klar strukturierter und reproduzierbarer Ansatz zur differenzierten Trennung dieser Oberflächentypen. Hier setzt die vorliegende Arbeit an, indem spektrale und topographische Informationen in einem Random-Forest-Modell kombiniert werden, um Fels-, Geröll- und weitere Oberflächenformen systematisch zu differenzieren.

2.4 Auswahl und Begründung der verwendeten Fernerkundungsdaten

Die Wahl geeigneter Fernerkundungsdaten stellt eine zentrale methodische Entscheidung für die automatisierte Klassifikation alpiner Oberflächenformen dar. Für die Differenzierung von bare_rock, scree und other_surface sind insbesondere räumliche Auflösung, spektrale Abdeckung, zeitliche Verfügbarkeit sowie Datenzugänglichkeit und Reproduzierbarkeit von Bedeutung. Ziel dieser Arbeit ist die flächenhafte und reproduzierbare Klassifikation dominanter Oberflächentypen im Hochgebirge unter Verwendung frei verfügbarer Datensätze. Vor diesem Hintergrund wurde die Datenauswahl systematisch anhand definierter Kriterien vorgenommen.

2.4.1 Auswahlkriterien

Für die vorliegende Fragestellung waren folgende Anforderungen maßgeblich:

- **Räumliche Auflösung:** Fels- und Geröllflächen treten im Hochgebirge häufig mosaikartig und kleinräumig strukturiert auf. Eine Pixelgröße von 30 m kann diese Heterogenität nur eingeschränkt erfassen. Eine höhere räumliche Auflösung erhöht daher die Differenzierbarkeit spektral ähnlicher Oberflächen.
- **Spektrale Abdeckung:** Zur Unterscheidung mineralischer Oberflächen sind insbesondere Bänder im sichtbaren (VIS), nahinfraroten (NIR) und kurzwelligen infraroten Bereich (SWIR) relevant.
- **Atmosphärische Korrektur:** Für eine vergleichbare und robuste Klassifikation sind Oberflächenreflexionswerte erforderlich.
- **Freie Verfügbarkeit und Reproduzierbarkeit:** Die Arbeit verfolgt einen transparenten und methodisch nachvollziehbaren Ansatz. Daher sollten die verwendeten Daten frei zugänglich sein.

- Zeitliche Verfügbarkeit: Mehrere aufeinanderfolgende Aufnahmen ermöglichen die Auswahl schneefreier Szenen und reduzieren saisonale Störeinflüsse.

2.4.2 Vergleich potenzieller Datenquellen

Landsat -8

Landsat -8 bietet eine lange und konsistente Zeitreihe mit 30 m räumlicher Auflösung sowie multispektrale und thermale Bänder. Die historische Kontinuität ist insbesondere für langfristige Prozessanalysen von Bedeutung. Für die vorliegende Arbeit stellt jedoch die räumliche Auflösung eine Einschränkung dar. Mit 30 m Pixelgröße können kleinräumige Übergangsbereiche zwischen Fels und Geröll nur eingeschränkt differenziert werden. Insbesondere in stark reliefierten Hochgebirgslandschaften erhöht dies die Wahrscheinlichkeit von Mischpixeln.

Kommerzielle hochauflösende Satellitendaten

Sensoren wie WorldView oder GF -2 liefern Bilddaten im Meter - oder Submeterbereich und ermöglichen eine sehr detaillierte Abbildung geomorphologischer Strukturen. Für großräumige Untersuchungsgebiete sind diese Daten jedoch kostenintensiv und unterliegen Nutzungsbeschränkungen. Zudem ist die langfristige Reproduzierbarkeit der Analyse bei kommerziellen Datensätzen eingeschränkt.

Sentinel -2

Die Sentinel -2 -Mission der ESA stellt multispektrale Daten mit 13 Bändern im VIS -, NIR - und SWIR -Bereich bereit. Die räumliche Auflösung beträgt in den zentralen Bändern 10 m und ermöglicht damit eine deutlich feinere Differenzierung alpiner Oberflächen als Landsat -8. Für die vorliegende Arbeit wurden Level -2A -Produkte verwendet, die atmosphärisch korrigierte Oberflächenreflexionswerte enthalten und somit direkt für Klassifikationszwecke geeignet sind.

Ein weiterer Vorteil ist die hohe zeitliche Wiederholrate von etwa fünf Tagen in Mitteleuropa. Dadurch können schneefreie und atmosphärisch günstige Szenen ausgewählt werden, was insbesondere in hochalpinen Regionen mit stark variierenden Bedingungen relevant ist. Die freie Verfügbarkeit der Daten gewährleistet zudem Transparenz und Reproduzierbarkeit der gesamten Methodik.




Abbildung 9: Übersicht der in Alifu et al. (2020) untersuchten Hochgebirgsregionen (Test 1 und Test 2) mit Sentinel -2 -Bändern 4, 8 und 11. Die Karte zeigt die räumliche Verteilung von Gletscher - und Schuttflächen sowie topographische Variabilität, die Grundlage für multisensorische Klassifikationsanalysen bildet (nach Alifu et al., 2020).

2.4.3 Begründung der Datenauswahl für diese Arbeit

Auf Grundlage der definierten Kriterien wurde Sentinel -2 als primäre Datengrundlage für die Klassifikation gewählt. Die 10 -m -Auflösung stellt einen methodisch sinnvollen Kompromiss zwischen Detailgenauigkeit und großräumiger Abdeckung dar. Sie erlaubt die Erfassung dominanter Oberflächenstrukturen, ohne die Analyse auf punktuelle oder kleinräumige Untersuchungsbereiche zu beschränken.

Im Vergleich zu Landsat -8 bietet Sentinel -2 eine höhere räumliche Differenzierung, was für die Unterscheidung spektral ähnlicher Klassen wie bare_rock und scree entscheidend ist. Kommerzielle hochauflösende Daten wurden nicht verwendet, da die Arbeit einen reproduzierbaren und frei zugänglichen Workflow verfolgt.

Orthofotos wurden ergänzend zur visuellen Plausibilitätsprüfung einzelner Klassifikationsergebnisse eingesetzt, jedoch nicht als Trainingsgrundlage verwendet. Aufgrund ihrer hohen Detailgenauigkeit eignen sie sich zur qualitativen Kontrolle, stellen jedoch keine konsistente multispektrale Datengrundlage für eine flächendeckende automatisierte Klassifikation dar.

Zusammenfassend bietet Sentinel -2 unter Berücksichtigung von räumlicher Auflösung, spektraler Bandbreite, Datenverfügbarkeit und Reproduzierbarkeit die geeignetste Datengrundlage für die automatisierte Differenzierung alpiner Oberflächenformen im Rahmen dieser Arbeit.

2.5 Topographische Einflussfaktoren

Die topographischen Bedingungen des Hochgebirges stellen eine besondere Herausforderung für die Klassifikation von Landbedeckungen dar. Faktoren wie Schatten, Hangneigung und Schnee beeinflussen die spektrale Signatur der Oberflächen und führen zu einer erhöhten Variabilität innerhalb einer Klasse. Dies wirkt sich unmittelbar auf die Trennschärfe von Klassifikationsmodellen aus und kann die Genauigkeit insbesondere in felsdominierten Landschaften erheblich reduzieren (Singh & Sood, 2018; Stead et al., 2019).

2.5.1. Schatteneffekte

Schatten gehören zu den dominierenden Störgrößen in optischen Fernerkundungsdaten des Hochgebirges. Durch steile Hanglagen und starke Reliefenergie werden weite Flächen während der Aufnahme teilweise oder vollständig verschattet. In diesen Bereichen sinkt die Reflexionsintensität deutlich, wodurch sich die spektrale Signatur verändert. Schatten können dazu führen, dass helle Oberflächen (z. B. Fels oder Geröll) spektral ähnlich erscheinen wie dunkle, vegetationsbedeckte Flächen (Singh & Sood, 2018).

Zur Minimierung solcher Effekte werden topographische Korrekturverfahren eingesetzt, die auf der Kombination von Reflexionswerten mit topographischen Parametern basieren. Diese Methoden, wie die *Cosine -Correction* oder die *Minnaert -Korrektur*, nutzen Informationen aus digitalen Geländemodellen, um Unterschiede in der Beleuchtung auszugleichen (de Lange, 2020). Moderne Machine -Learning -Modelle können diese Korrektur auch indirekt umsetzen, indem sie topographische Variablen (z. B. Hangneigung oder Exposition) als zusätzliche Eingangsmerkmale verwenden. Dadurch wird der Einfluss von Schatten auf die Klassifikation reduziert, ohne dass eine explizite radiometrische Korrektur erforderlich ist (Tiwari et al., 2019).

2.5.2. Hangneigung und Exposition

Die Hangneigung beeinflusst maßgeblich die spektrale Reflexion, da sie die Einfallswinkel des Sonnenlichts und damit die Helligkeit der reflektierten Strahlung verändert. Steile Hänge reflektieren das Licht in flachen Winkeln, wodurch geringere Strahlungswerte gemessen werden, während flachere Flächen eine höhere Reflexion aufweisen. Die Exposition (Ausrichtung des Hangs) bestimmt zudem, wie lange eine Fläche während des Tages beleuchtet ist, was sich besonders in multispektralen Indizes wie NDVI oder NDSI bemerkbar macht (Stead et al., 2019). Topographische Parameter aus digitalen Geländemodellen (DTM) oder digitalen Oberflächenmodellen (DOM) werden häufig als Zusatzdaten in Klassifikationen integriert, um diese Effekte zu kompensieren. Schneevoigt et al. (2007) zeigten, dass durch die Einbeziehung von Hangneigung und Exposition in objektbasierten Verfahren (OBIA) die Trennung zwischen Fels-, Geröll- und Vegetationsflächen signifikant verbessert werden kann. Auch in aktuellen Machine-Learning-Ansätzen werden topographische Variablen routinemäßig genutzt, um Kontextinformationen über das Relief zu berücksichtigen und Fehlklassifikationen in schattigen Bereichen zu verringern (Tiwari et al., 2019; Whalley, 2024).




Abbildung 10: Vergleich zwischen spektraler Landbedeckungsklassifikation (Level L1) und objektbasierter Landformklassifikation (Level L2) im Reintal (Bayerische Alpen). Durch die Integration topographischer Parameter wie Hangneigung und Exposition konnte die Differenzierung geomorphologischer Einheiten wie Fels-, Geröll- und Vegetationsflächen verbessert werden (nach Schneevoigt et al., 2007).

2.5.3. Schneebedeckung und saisonale Einflüsse

Schnee und Eisflächen stellen eine weitere Herausforderung für die Landbedeckungsklassifikation dar, da sie je nach Bedeckungsgrad und Jahreszeit stark variierende spektrale Eigenschaften aufweisen. Frischer Schnee besitzt eine sehr hohe Reflexion im sichtbaren und nahinfraroten Bereich, während älterer oder mit Schutt bedeckter Schnee deutlich dunkler erscheint (Stead et al., 2019). In Gebirgsregionen kann diese Variabilität dazu führen, dass Schnee- oder Eisflächen mit hellen Felsformationen verwechselt werden.

Zur Reduzierung dieses Effekts werden häufig zeitlich abgestimmte Aufnahmedaten verwendet, um saisonale Schneebedeckung zu minimieren. Sentinel -2 -Daten bieten durch ihre hohe zeitliche Auflösung die Möglichkeit, Szenen mit minimaler Schneebedeckung zu wählen (Tiwari et al., 2019). Darüber hinaus können spektrale Indizes wie der *Normalized Difference Snow Index (NDSI)* helfen, schneebedeckte Bereiche zu erkennen und vor der Klassifikation gezielt auszuschließen (de Lange, 2020).

2.6 Machine Learning in der Fernerkundung

2.6.1 Klassische Verfahren (Random Forest, SVM)

Machine -Learning -Verfahren haben in den letzten Jahren zunehmend an Bedeutung für die Klassifikation von Landbedeckungen in Gebirgsregionen gewonnen. Sie ermöglichen eine flexible, datengetriebene Modellierung komplexer Zusammenhänge zwischen spektralen, texturalen und topographischen Variablen, ohne dass eine vorherige Annahme über deren Verteilung erforderlich ist (de Lange, 2020).

Zu den am häufigsten eingesetzten Methoden zählen der Random -Forest -Algorithmus (RF) und die Support Vector Machines (SVM). Beide Verfahren gehören zur Gruppe der überwachten Lernverfahren und nutzen Trainingsdaten, um aus bekannten Mustern auf unbekannte Pixel zu schließen. Der Random -Forest -Algorithmus besteht aus einer Vielzahl einzelner Entscheidungsbäume, die jeweils auf unterschiedlichen Teilmengen der Daten trainiert werden (Batta, 2020). Durch diese Ensemble -Struktur werden zufällige Fehler einzelner Modelle ausgeglichen, was zu einer hohen Robustheit gegenüber Rauschen und Ausreißern führt. Random Forests eignen sich besonders für Fernerkundungsdaten, da sie sowohl kontinuierliche als auch kategoriale Eingangsvariablen verarbeiten können und nur geringe Parameteranpassungen erfordern (Sharda et al., 2022). In der geomorphologischen Kartierung werden sie häufig eingesetzt, um Fels -, Geröll - und Vegetationsklassen auf Basis von Sentinel -2 -Daten zu trennen (Alifu et al., 2020; Tiwari et al., 2019). Ein weiterer Vorteil des Random -Forest -Algorithmus liegt in der Möglichkeit, die Bedeutung einzelner Eingangsvariablen (*feature importance*) zu bewerten. Damit lassen sich spektrale Bänder oder topographische Merkmale identifizieren, die den größten Beitrag zur Klassifikation leisten. Diese Funktion unterstützt sowohl die Optimierung des Merkmalsraums als auch die Interpretation der Modellentscheidungen (Sharda et al., 2022).

Im Gegensatz dazu basiert die Support Vector Machine auf der Suche nach einer optimalen Trennfläche (Hyperplane) zwischen Klassen. Diese wird so gewählt, dass der Abstand zu den nächstgelegenen Trainingspunkten maximal ist. Durch die Verwendung von Kernel -Funktionen kann SVM auch nichtlineare Beziehungen zwischen den Variablen modellieren (de Lange, 2020). SVM -Modelle liefern häufig sehr präzise Ergebnisse, erfordern jedoch eine sorgfältige Parametrierung und sind bei großen Datensätzen rechenintensiver als Random Forests (Tiwari et al., 2019). In Studien zur Landbedeckungsklassifikation im Hochgebirge zeigen beide Verfahren vergleichbare Leistungen, wobei Random Forest aufgrund seiner Stabilität und Interpretierbarkeit häufig bevorzugt wird (Robson et al., 2020). Die Kombination beider Ansätze, etwa in Form von Ensemble - oder Hybridmodellen, bietet zudem die Möglichkeit, deren Stärken gezielt zu vereinen und Unsicherheiten in heterogenen Landschaften zu reduzieren (Sharda et al., 2022).




Abbildung 11: Schematischer Ablauf des überwachten Lernens (Supervised Learning Workflow). Trainings - und Testdaten werden zur Modellbildung, Evaluation und Optimierung verwendet (nach Batta, 2020).

2.6.2 Erweiterte Lernverfahren (Deep Learning - theoretischer Überblick)

Deep -Learning -Methoden stellen eine Weiterentwicklung klassischer Machine -Learning -Ansätze dar und ermöglichen es, komplexe Muster in Bilddaten automatisch zu erkennen. Im Gegensatz zu herkömmlichen Verfahren, die auf manuell ausgewählten Merkmalen beruhen, lernen Deep -Learning -Modelle die relevanten Merkmale direkt aus den Eingabedaten. Dadurch entfällt die Notwendigkeit einer expliziten Feature -Definition, was insbesondere bei hochdimensionalen Fernerkundungsdaten von Vorteil ist (Robson et al., 2020).

Das am weitesten verbreitete Modell in der Fernerkundung ist das Convolutional Neural Network (CNN). CNNs bestehen aus mehreren Schichten, die Eingabebilder schrittweise in abstraktere Repräsentationen überführen. Frühere Schichten erkennen einfache Strukturen wie Kanten oder Texturen, während tiefere Schichten komplexe Formen oder räumliche Muster

identifizieren (Thomas et al., 2023). Diese hierarchische Merkmalsextraktion ermöglicht eine robuste Trennung von Klassen, die sich spektral stark überlappen - etwa zwischen Fels, Geröll und eisbedeckten Flächen. CNNs nutzen räumliche Kontextinformationen und sind damit besonders geeignet für die Analyse von Gebirgsregionen mit unregelmäßigen Formen und variabler Beleuchtung (Whalley, 2024). Sie können multispektrale Daten, digitale Geländemodelle und Texturmerkmale gleichzeitig verarbeiten und dadurch spektrale sowie topographische Zusammenhänge erkennen. In aktuellen Studien wird gezeigt, dass CNNs die Genauigkeit der Kartierung von Gesteins- und Schuttflächen deutlich erhöhen und in vielen Fällen Ergebnisse auf Expertenniveau erzielen (Maslov et al., 2025; Yang et al., 2024).

Ein zentraler Fortschritt besteht in der Kombination von Deep Learning mit objektbasierten Verfahren (OBIA). Dabei werden zunächst Segmente aus den Bilddaten gebildet, die anschließend von CNNs klassifiziert werden. Diese Hybridansätze vereinen die Vorteile beider Methoden: die strukturelle Kohärenz von OBIA und die lernbasierte Merkmalsextraktion von Deep Learning (Thomas et al., 2023). Die Implementierung von Deep-Learning-Modellen erfordert umfangreiche Trainingsdatensätze und hohe Rechenkapazitäten. Transfer-Learning-Strategien bieten hier eine Lösung, indem bereits vortrainierte Modelle an neue Regionen angepasst werden. Dadurch lassen sich auch mit begrenzten Trainingsdaten stabile Ergebnisse erzielen und die Modelle auf andere Gebirge übertragen (Maslov et al., 2025). Trotz hoher Genauigkeit bleibt die Nachvollziehbarkeit der Modellentscheidungen eine Herausforderung. Die internen Gewichtungen der neuronalen Netze sind schwer interpretierbar, was das Verständnis der zugrunde liegenden Entscheidungsprozesse erschwert (Sharda et al., 2022). In der aktuellen Forschung wird daher verstärkt an erklärbaren Deep-Learning-Methoden gearbeitet, die eine transparente Bewertung der Klassifikationsergebnisse ermöglichen sollen. Die Leistungsfähigkeit beider Methoden ist gut dokumentiert, ihre Eignung hängt jedoch stark von Datenverfügbarkeit, räumlicher Auflösung und Modellkomplexität ab. Vor diesem Hintergrund ist ein systematischer Vergleich beider Ansätze für die vorliegende Fragestellung notwendig.

2.6.3 Vergleich von Random Forest und Convolutional Neural Networks für die Klassifikation alpiner Oberflächen

Die in Abschnitt 2.6 dargestellten Verfahren zeigen, dass sowohl Random Forest (RF) als auch Convolutional Neural Networks (CNN) grundsätzlich in der Lage sind, komplexe Muster in multispektralen und topographischen Daten zu erkennen. Für die Klassifikation von Fels- und

Geröllflächen unterscheiden sich beide Ansätze jedoch deutlich hinsichtlich Datenbedarf, Modellkomplexität, Interpretierbarkeit und Robustheit gegenüber heterogenen Landschaftsstrukturen. Random -Forest -Modelle haben sich in hochalpinen Regionen als besonders robust erwiesen, da sie mit einer begrenzten Menge an Trainingsdaten stabile Ergebnisse liefern und sowohl spektrale als auch topographische Variablen gemeinsam verarbeiten können (Tiwari et al., 2019; Sharda et al., 2022). Die Ensemble -Struktur verhindert ein starkes Overfitting und ermöglicht eine transparente Bewertung der Merkmalsbedeutung. Gerade die Kombination unterschiedlicher Variablentypen ist für die Trennung von Fels - und Geröllflächen entscheidend, da spektrale Informationen allein aufgrund von Schatten, Blockorientierungen und Feuchtevariationen häufig nicht ausreichen (Singh & Sood, 2018).

CNNs zeigen in vielen Studien ebenfalls sehr gute Leistungswerte - insbesondere bei der Analyse komplexer Texturen und unregelmäßiger Oberflächen (Thomas et al., 2023; Maslov et al., 2025). Sie sind in der Lage, räumliche Kontextinformationen automatisch zu erkennen und können in Kombination mit OBIA -Methoden detaillierte Strukturen wie Schuttkörper oder Gletscherschutt erfassen. Allerdings erfordern CNNs umfangreiche Trainingsdatensätze, eine hohe räumliche Auflösung und eine beträchtliche Rechenleistung. Diese Voraussetzungen sind in vielen alpinen Studiengebieten nicht gegeben, da hochaufgelöste flächendeckende Daten häufig fehlen und die manuelle Erfassung großer Mengen an Trainingspolygone kaum realisierbar ist (Pirkash, 2025). Zudem ist die Nachvollziehbarkeit der Modellentscheidungen bei CNNs eingeschränkt. Die interne Gewichtung der Netzschichten ist nur schwer interpretierbar, was die Ableitung geomorphologisch plausibler Zusammenhänge erschwert (Sharda et al., 2022). Für Fragestellungen, bei denen die Klassifikation nicht nur ein technisches, sondern auch ein inhaltlich interpretierbares Ergebnis liefern soll - wie bei der Analyse von Fels - und Geröllflächen - stellt dies eine wesentliche Einschränkung dar.

Vor diesem Hintergrund bietet Random Forest eine methodisch geeignete Alternative:

- geringer Datenbedarf (prak-tisch relevant im hochalpinen Gelände),
- robuster Umgang mit spektraler Heterogenität,
- Mischung aus spektralen und topographischen Variablen problemlos integrierbar,
- Interpretierbarkeit der Merkmalsbeiträge,
- direkt in der verwendeten GIS -Umgebung implementierbar,
- Ausführung ohne GPU - oder Deep -Learning -Infrastruktur.

Die Literatur zeigt zudem, dass CNN -Modelle ihre Stärken vor allem bei hochaufgelösten Daten ausspielen können (Thomas et al., 2023; Yang et al., 2024). Für Sentinel -2 -Daten mit 10 m Auflösung ist die Texturinformation jedoch begrenzt, wodurch ein wesentlicher Vorteil von CNNs entfällt. Studien, die CNNs dennoch auf mittlere Auflösungen anwenden, arbeiten fast ausschließlich mit sehr großen Datensätzen oder auf stark strukturierten Oberflächen wie Gletscherschutt (Robson et al., 2020; Maslov et al., 2025), während die gezielte Differenzierung von Fels und Geröll bei moderater Auflösung bisher kaum systematisch untersucht wurde. Auf Basis dieser Aspekte fällt die methodische Entscheidung dieser Arbeit eindeutig zugunsten eines Random -Forest -Modells aus. RF ermöglicht eine verlässliche Klassifikation unter den gegebenen Datenbedingungen und unterstützt zugleich eine transparente Interpretation der Modellentscheidungen - ein zentraler Punkt für die geomorphologische Analyse der Zielklassen. Darüber hinaus ist RF vollständig in ArcGIS Pro implementiert, wodurch ein konsistenter, reproduzierbarer Workflow gewährleistet wird. Da die differenzierte Klassifikation von Fels - und Geröllflächen auf Sentinel -2 -Niveau in der aktuellen Literatur nur begrenzt behandelt wird, adressiert der gewählte Ansatz eine konkrete Forschungslücke und bietet einen methodisch begründeten Beitrag zur Weiterentwicklung existierender Klassifikationsstrategien.

2.7 Bewertungsmethoden (Kappa, Precision, Recall)

Die Bewertung der Klassifikationsergebnisse ist ein zentraler Bestandteil der Fernerkundungsanalyse, da sie Aufschluss über die Zuverlässigkeit und Genauigkeit der Modellvorhersagen gibt. Dabei werden quantitative Kennwerte eingesetzt, um die Übereinstimmung zwischen vorhergesagten und tatsächlich beobachteten Klassen zu bestimmen (de Lange, 2020).

Ein grundlegendes Maß stellt die Gesamtgenauigkeit (Overall Accuracy) dar, welche den Anteil der korrekt klassifizierten Pixel an der Gesamtzahl aller untersuchten Pixel beschreibt. Diese Metrik liefert jedoch keine Informationen über die Genauigkeit einzelner Klassen, weshalb zusätzliche Indikatoren erforderlich sind (Tiwari et al., 2019). Die Precision (Genauigkeit) beschreibt, wie viele der als eine bestimmte Klasse vorhergesagten Pixel tatsächlich dieser Klasse angehören. Sie misst also die Zuverlässigkeit der Klassifikation innerhalb einer Kategorie. Die Recall (Empfindlichkeit) gibt an, wie vollständig eine Klasse durch das Modell erkannt wurde - also den Anteil der korrekt identifizierten Pixel an allen tatsächlich vorhandenen Pixeln dieser

Klasse. Beide Kennwerte ergänzen sich, da ein Modell sowohl hohe Precision als auch hohen Recall erreichen sollte, um eine verlässliche Klassifizierung zu gewährleisten (Sharda et al., 2022). Zur Gesamteinschätzung der Klassifikationsgüte wird häufig der Kappa -Koeffizient verwendet. Er berücksichtigt zufällige Übereinstimmungen zwischen vorhergesagten und tatsächlichen Klassen und liefert dadurch ein realistischeres Maß der Modellleistung als die reine Genauigkeit. Ein Kappa -Wert von 1 steht für eine vollständige Übereinstimmung, während 0 einer zufälligen Klassifikation entspricht (de Lange, 2020).

Neben diesen Kennwerten werden in der Praxis häufig Konfusionsmatrizen eingesetzt. Sie stellen die Zuordnung zwischen vorhergesagten und tatsächlichen Klassen tabellarisch dar und bilden die Grundlage für die Berechnung von Accuracy, Precision, Recall und Kappa.

		Referenzdaten					
		Laubwald	Nadelwald	Acker	Wiese	gesamt	User's Accuracy
klassifizierte Daten	Laubwald	139	8	2	4	153	91%
	Nadelwald	7	101	5	4	117	86%
	Acker	5	4	75	2	86	87%
	Wiese	4	7	3	45	59	76%
gesamt		155	120	85	55	415	
Producer's Accuracy		90%	84%	88%	82%		

Abbildung 12: Beispiel einer Konfusionsmatrix mit Berechnung der Producer's und User's Accuracy (nach de Lange, 2020, S. 493).

Durch die Analyse der Fehldetektionen können Schwächen des Modells gezielt identifiziert und optimiert werden (Tiwari et al., 2019).

In der Fernerkundung von Gebirgsregionen sind solche Validierungsmetriken besonders relevant, da heterogene Oberflächenstrukturen und topographische Effekte die Trennschärfe der Modelle stark beeinflussen. Die Kombination mehrerer Bewertungsgrößen ermöglicht daher eine ausgewogene Beurteilung der Klassifikationsleistung und bildet die Grundlage für den Vergleich unterschiedlicher Methoden und Datensätze.

Die in Kapitel 2 dargestellten theoretischen Grundlagen zeigen, welche Merkmale für die Trennung von Fels - und Geröllflächen relevant sind und welche methodischen Herausforderungen sich aus der spektralen Heterogenität, den Schatteneffekten und der räumlichen Auflösung ergeben. Gleichzeitig wurde deutlich, dass ein Random -Forest -Modell unter diesen Bedingungen die geeignetste Methode darstellt, da es sowohl spektrale als auch topographische Variablen zuverlässig verarbeitet und eine nachvollziehbare Interpretation der Modellscheidungen ermöglicht. Auf dieser Basis wird im folgenden Methodenteil beschrieben, wie die theoretisch hergeleiteten Anforderungen praktisch umgesetzt werden. Dazu gehören die

Auswahl und Vorverarbeitung der Sentinel -2 -Daten, die Ableitung relevanter topographischer Parameter, die Erstellung geeigneter Trainingsgebiete sowie der Aufbau und die Validierung des Klassifikationsmodells. Kapitel 3 überführt damit die konzeptionellen Überlegungen des Theorieteils in einen klar strukturierten und reproduzierbaren Arbeitsablauf.

Obwohl im Vorfeld auch tiefergehende Deep -Learning -Ansätze in Betracht gezogen wurden, zeigte die theoretische Analyse, dass ein Random -Forest -Modell unter den gegebenen Datenbedingungen, Auflösungsgrenzen und dem verfügbaren Trainingsumfang die methodisch sinnvollere und transparenter interpretierbare Wahl darstellt.

3 Methodik

3.1 Softwaregrundlage und methodische Rahmenbedingungen

Für die Umsetzung der praktischen Arbeitsschritte wird ArcGIS Pro als zentrale Softwareumgebung verwendet. Die Entscheidung für ArcGIS Pro basiert auf der Kombination aus umfangreichen Rasterverarbeitungswerkzeugen, integrierten Machine -Learning -Modulen und einer stabilen Unterstützung großer Datensätze, wie sie bei der Verarbeitung von Sentinel -2 -Szenen und digitalen Höhenmodellen erforderlich sind. Der Random -Forest -Algorithmus ist in ArcGIS Pro vollständig implementiert, wodurch sowohl Training als auch Klassifikation direkt innerhalb derselben Umgebung durchgeführt werden können. Dies ermöglicht einen konsistenten, reproduzierbaren Workflow ohne externe Modellierungsframeworks.

Ein weiterer Vorteil liegt in der Verwendung von arcpy, das eine klare Dokumentation und Automatisierung der einzelnen Prozessschritte erlaubt. Im Vergleich zu alternativen Plattformen wie QGIS, Google Earth Engine oder rein Python -basierten Workflows bietet ArcGIS Pro eine enge Verzahnung von Datenmanagement, GIS -Analyse und Modellierung, wodurch die Erstellung, Überwachung und Validierung komplexer Arbeitsabläufe erleichtert wird. Die Software eignet sich damit besonders für Projekte, in denen spektrale, topographische und texturale Informationen gemeinsam verarbeitet werden und ein transparent nachvollziehbarer Klassifikationsprozess erforderlich ist.

3.2 Datenquellen und Datenauswahl

Für die vorliegende Untersuchung wurden zwei zentrale Datensätze herangezogen: multi - spektrale Satellitenaufnahmen der Sentinel -2 -Mission sowie ein hochauflösendes digitales Höhenmodell (DHM) des Untersuchungsgebiets Rettenbachferner in den Ötztaler Alpen. Beide Datensätze dienen als Grundlage für die Ableitung topographischer und spektraler Merkmale, die im Rahmen der Klassifikation von Fels - und Geröllflächen eingesetzt werden. Die Sentinel -2 -Daten stammen aus dem europäischen Erdbeobachtungsprogramm Copernicus und wurden über den Copernicus Open Access Hub bezogen. Verwendet wurden zwei atmosphärenkorrigierte Level -2A -Szenen vom 28. September 2023 (Produktbezeichnungen: S2B_MSIL2A_20230928T101719_N0510_R065_T32TPT_20241026T142623.SAFE und S2B_MSIL2A_20230928T101719_N0510_R065_T32TPS_20241026T142623.SAFE). Beide Kacheln decken gemeinsam das Untersuchungsgebiet vollständig ab. Sie enthalten alle 13 Spektralbänder des Multispectral Instrument (MSI) mit einer räumlichen Auflösung von 10 bis 60 Metern. Für die vorliegende Arbeit wurden insbesondere die Bänder im sichtbaren und nahinfraroten Bereich (B2 - B8) herangezogen, da sie sich für die Unterscheidung verschiedener Oberflächenmaterialien bewährt haben. Zur Ergänzung der spektralen Informationen wurde ein hochauflösendes digitales Höhenmodell (DHM) der Republik Österreich verwendet. Das Datenset Digitales Höhenmodell 10 m - Lambert (DHM_AT_LAMB_10m_2018.tif) wurde über das nationale Datenportal data.gv.at bezogen und basiert auf Airborne -Laserscanning -Daten mit einer Rasterauflösung von 10 Metern. Das Modell repräsentiert die Terrainoberfläche und bildet damit eine wichtige Grundlage für die Berechnung topographischer Parameter wie Hangneigung (Slope) und Exposition (Aspect). Alle Datensätze wurden im einheitlichen Koordinatensystem MGI / Austria Lambert (EPSG: 31287) verarbeitet, um eine konsistente räumliche Grundlage für die anschließende Analyse zu gewährleisten. Das Untersuchungsgebiet umfasst den Bereich des Rettenbachferners sowie angrenzende alpine Fels - und Geröllflächen im südwestlichen Tirol.




Abbildung 13: Untersuchungsgebiet Rettenbachferner (Ötztaler Alpen) mit Ausschnitt des verwendeten digitalen Höhenmodells (10 m) und abgeleitetem Hillshade.
Quelle: eigene Darstellung auf Basis von data.gv.at (2024)

3.2.1 Untersuchungsgebiet und Begründung der Gebietsauswahl

Das Untersuchungsgebiet umfasst den Rettenbachferner und die angrenzenden Hangbereiche in den Ötztaler Alpen (Tirol). Die Region weist eine ausgeprägte hochalpine Morphologie auf, geprägt von steilen Felsflanken, ausgedehnten Schuttkörpern und dynamischen glazialen Formen. Diese Kombination aus kompaktem Fels, instabilem Geröllmaterial und klar ausgeprägten Reliefstrukturen bietet besonders geeignete Voraussetzungen, um die Leistungsfähigkeit automatisierter Klassifikationsansätze zur Trennung dieser Oberflächentypen zu untersuchen. Der Rettenbachferner ist methodisch besonders geeignet, da die Kontraste zwischen Fels- und Geröllflächen aufgrund der stark reliefgeprägten Topographie deutlich hervortreten. Das Gebiet weist ein breites Spektrum an Hangneigungen und Expositionen auf, wodurch unterschiedliche Beleuchtungs- und Schattenverhältnisse entstehen. Solche Bedingungen stellen hohe Anforderungen an Klassifikationsmodelle und ermöglichen eine realistische Bewertung der Modellrobustheit. Gleichzeitig ist die Vegetationsbedeckung oberhalb der Waldgrenze gering, sodass die spektralen Signaturen von Fels und Lockermaterial weniger überlagert werden. Ein weiterer Vorteil liegt in der guten Datenverfügbarkeit. Für das Gebiet existieren mehrere wolkenarme Sentinel-2-Szenen sowie hochauflösende digitale Gelände- und Oberflächenmodelle, die eine präzise Ableitung topographischer Parameter ermöglichen. Zusätzlich ist die Region in der glaziologischen und geomorphologischen

Forschung gut dokumentiert, während die systematische Klassifikation von Fels - und Geröllflächen auf multispektralen Satellitendaten bisher nur begrenzt untersucht wurde. Das Gebiet bietet daher eine geeignete Grundlage, um die in Kapitel 2 beschriebenen theoretischen Ansätze unter realistischen alpinen Bedingungen praktisch zu erproben und gleichzeitig eine bestehende Forschungslücke zu adressieren.

3.2.2 Begründung der räumlichen Auflösung (10 m)

Die Wahl der 10 -m -Bänder von Sentinel -2 basiert auf einer systematischen Abwägung zwischen räumlicher Detailgenauigkeit, spektraler Aussagekraft, flächendeckender Verfügbarkeit und methodischer Eignung für die Differenzierung der definierten Zielklassen. Für die vorliegende Fragestellung steht nicht die Erfassung kleinskaliger Texturmuster im Vordergrund, sondern die Trennung dominanter Oberflächenmaterialien (*bare_rock*, *scree*, *other_surface*) auf Grundlage ihrer spektralen Eigenschaften und ihres topographischen Kontexts.

Zahlreiche Studien zeigen, dass Fels - und Geröllflächen in multispektralen Satellitendaten primär durch Unterschiede im Reflexionsverhalten im sichtbaren und nahinfraroten Spektralbereich sowie durch ihre Lage im Relief differenziert werden können (Thomas et al., 2023; Singh & Sood, 2018). Die 10 -m -Bänder von Sentinel -2 (insbesondere Red, NIR und SWIR) bieten hierfür eine geeignete spektrale Grundlage und ermöglichen zugleich eine räumliche Abbildung, die für großflächige alpine Oberflächenformen ausreichend differenziert ist.

Hochaufgelöste Daten (<5 m) erlauben zwar eine detailliertere Erfassung einzelner Blockstrukturen oder kleinräumiger Übergangsbereiche, sind jedoch häufig kostenpflichtig, nicht flächendeckend verfügbar und mit einem deutlich höheren Vorverarbeitungs - und Rechenaufwand verbunden. Zudem steht bei sehr hochauflösenden Bilddaten häufig die Analyse texturaler Muster im Vordergrund, während die vorliegende Arbeit auf einer pixelbasierten, variablenorientierten Klassifikation beruht.

Deep -Learning -Ansätze wie Convolutional Neural Networks (CNNs) entfalten ihre Stärken insbesondere bei hochauflösenden Bilddaten, bei denen komplexe räumliche Textur - und Strukturinformationen automatisiert extrahiert werden können (Maslov et al., 2025; Yang et al., 2024). Im vorliegenden Fall basiert die Analyse jedoch auf multispektralen Sentinel -2 -Daten mit einer Auflösung von 10 m, bei denen großflächige Materialunterschiede dominieren und feinstrukturelle Texturmuster nur eingeschränkt aufgelöst werden. Unter diesen Bedingungen bietet ein ensemblebasiertes, variablenorientiertes Verfahren wie Random Forest

eine methodisch angemessene und robuste Lösung. CNN -Modelle würden hier keinen strukturellen Vorteil ausspielen, gleichzeitig jedoch höhere Anforderungen an Trainingsdatengröße und Modelloptimierung stellen.

Ein weiterer zentraler Aspekt betrifft die topographischen Rahmenbedingungen im Hochgebirge. Reliefenergie, Exposition und Schattenwurf erzeugen selbst innerhalb homogener Materialflächen eine erhebliche spektrale Variabilität. Studien weisen darauf hin, dass diese intra-klassen Variabilität weniger durch die Pixelgröße als durch Relief - und Beleuchtungseffekte bedingt ist (Singh & Sood, 2018; Sharda et al., 2022). Für die Differenzierung alpiner Oberflächenformen ist daher die Kombination spektraler Informationen mit topographischen Parametern entscheidender als eine möglichst feine räumliche Auflösung.

Unter Berücksichtigung dieser Faktoren stellt die 10 -m -Auflösung von Sentinel -2 einen methodisch fundierten Kompromiss dar:

- Sie ermöglicht eine stabile spektrale Erfassung der definierten Zielklassen,
- sie ist frei verfügbar und flächendeckend einsetzbar,
- sie erlaubt eine effiziente Verarbeitung des gesamten Untersuchungsgebiets,
- und sie steht im Einklang mit dem gewählten pixelbasierten Random -Forest -Ansatz.

Die Nutzung der 10 -m -Bänder ist somit nicht nur technisch praktikabel, sondern wissenschaftlich begründet und konsistent mit der übergeordneten Methodik dieser Arbeit.

3.3 Vorverarbeitung in ArcGIS Pro

3.3.1 Vorverarbeitung der Sentinel -2 -Daten

Zur Vorbereitung der Klassifikation wurden die beiden Sentinel -2 -Szenen zunächst in ArcGIS Pro geöffnet und einzeln als „Bottom -of -Atmosphere (BOA) Reflectance“ -Produkte aufbereitet. Die relevanten Bänder mit einer räumlichen Auflösung von 10 und 20 Metern wurden jeweils mosaikiert, um ein durchgehendes Abbild des Untersuchungsgebiets zu erhalten. Dieser Schritt erfolgte mit dem Werkzeug Mosaic to New Raster unter Beibehaltung des Koordinatensystems MGI / Austria Lambert (EPSG: 31287) und einer Bit -Tiefe von 16 Bit Unsigned. Da die multispektralen Sentinel -2 -Bänder unterschiedliche Pixelgrößen aufweisen, wurden die 20 -m -Bänder im Anschluss mit dem Werkzeug Resample (Data Management) bilinear auf 10 Meter umgerechnet. Dadurch liegen alle spektralen Kanäle auf einer gemeinsamen räumlichen Auflösung vor, was eine konsistente Kombination und Analyse ermöglicht.

Nach dem Resampling wurden die 10 -m - und 20 -m -Mosaiks mit dem Werkzeug Composite Bands zu einem mehrbandigen Raster -Stack zusammengeführt, das sämtliche für die Klassifikation relevanten Sentinel -2 -Kanäle enthält. Zur räumlichen Eingrenzung auf das Untersuchungsgebiet erfolgte anschließend ein Zuschnitt (Extract by Mask) unter Verwendung des Polygons „Rettenbachferner“. Durch diese Schritte wurde ein harmonisierter, georeferenzierter Datensatz erstellt, der als Grundlage für die Ableitung spektraler Indizes und die anschließende Klassifikation der Fels - und Geröllflächen dient.

3.3.2 Topographische Vorverarbeitung des digitalen Höhenmodells (DHM)

Zur Ergänzung der spektralen Informationen aus den Sentinel-2-Daten wurde ein digitales Höhenmodell (DHM) der Republik Österreich in die Vorverarbeitung einbezogen. Das DHM basiert auf Airborne-Laserscanning-Daten, besitzt eine räumliche Auflösung von 10 m und liegt im Koordinatensystem MGI / Austria Lambert (EPSG: 31287) vor.

Auf Grundlage des DHM wurde ein Schummerungsmodell (Hillshade) berechnet. Dieses simuliert die Beleuchtung des Geländes unter einem definierten Sonnenstand und dient der anschaulichen Darstellung der Reliefstrukturen im Untersuchungsgebiet. Die Schummerung ermöglicht eine visuelle Hervorhebung von Hangformen, Graten, Rinnen und weiteren morphologischen Strukturen und unterstützt damit die räumliche Einordnung der Analyseergebnisse. Das DHM selbst wird im Random-Forest-Modell nicht direkt als erklärende Variable verwendet. Seine Nutzung beschränkt sich in diesem Arbeitsschritt auf die visuelle Darstellung der topographischen Gegebenheiten. Für die Klassifikation relevante topographische Variablen (Hangneigung und Exposition) werden separat aus dem DHM abgeleitet und dem Modell als eigenständige Eingangsgrößen zugeführt.




Abbildung 14: Schummerungsdarstellung (Hillshade) des digitalen Höhenmodells (10 m) im Bereich des Rettenbachferners. Die Darstellung simuliert die Geländebeleuchtung und verdeutlicht die morphologische Struktur des stark reliefierten Untersuchungsgebiets.

3.3.3 Ableitung topographischer Variablen (Slope und Aspect)

Neben der rein visuellen Schummerungsdarstellung wurden aus dem digitalen Höhenmodell zusätzlich die topographischen Parameter Hangneigung (Slope) und Exposition (Aspect) abgeleitet. Diese Variablen liefern strukturbezogene Zusatzinformationen, die über rein spektrale Eigenschaften hinausgehen und den Reliefkontext eines Pixels explizit berücksichtigen.

Die Hangneigung beschreibt die Steilheit des Geländes und steht in engem Zusammenhang mit geomorphologischen Prozessen wie Materialtransport, Erosionsdynamik oder Blockakkumulation. Die Exposition gibt die Hangorientierung im Wertebereich von 0 -360° an und beeinflusst insbesondere Strahlungseintrag, Schneeeverweildauer, Feuchtebedingungen und Vegetationsentwicklung. Beide Parameter wirken sich somit indirekt auf die spektralen Eigenschaften der Oberflächen aus. Die Berechnung erfolgte mit den Standardwerkzeugen *Slope* und *Aspect* des ArcGIS Spatial Analyst. Die Hangneigung wurde in Grad ausgegeben, die Exposition im Winkelmaß von 0 -360°. Beide Raster wurden in einer räumlichen Auflösung von 10 m geführt, sodass sie exakt dem Rastermaßstab der Sentinel -2 -Bänder entsprechen. Anschließend wurden sie in den gemeinsamen Raster -Stack integriert, der als Eingabe für das Random -Forest -Modell dient. Die Einbindung topographischer Variablen ist insbesondere im

Hochgebirge methodisch relevant, da dort starke Reliefenergie und ausgeprägte Hangorientierungen das spektrale Signal erheblich beeinflussen können. Identische Materialien können je nach Exposition unterschiedliche Reflexionswerte aufweisen, insbesondere in steilen oder schattigen Hanglagen. Durch die Integration von Hangneigung und Exposition erhält das Modell explizite Kontextinformationen zur Reliefposition eines Pixels und kann spektral ähnliche, jedoch geomorphologisch unterschiedlich positionierte Flächen besser differenzieren.

Die Nutzung solcher Reliefparameter entspricht etablierten Ansätzen der alpinen Fernerkundung, in denen topographische Variablen wiederholt als leistungssteigernde Zusatzmerkmale beschrieben werden (z. B. Singh & Sood, 2018; Sharda et al., 2022).

3.4 Feature Engineering

3.4.1 Erstellung der Trainingsdaten aus OpenStreetMap (Overpass Turbo)

Für die Generierung der Referenzdaten wurden Polygone aus OpenStreetMap (OSM) herangezogen. OSM stellt im alpinen Raum eine detaillierte und frei zugängliche Geodatenquelle dar, in der geomorphologisch relevante Oberflächenformen wie Fels - und Geröllflächen differenziert erfasst sind. Die Datenextraktion erfolgte über die Webanwendung Overpass Turbo, die eine gezielte Abfrage der OSM -Datenbank mittels der Overpass Query Language (OQL) ermöglicht. Zur Selektion relevanter Flächen wurden Objekte mit dem Attribut `natural` abgefragt. Berücksichtigt wurden folgende Klassen:

- `bare_rock`
- `scree`
- `fell`
- `heath`
- `scrub`
- `glacier`

Die Klassen `bare_rock` und `scree` entsprechen unmittelbar den Zielklassen Fels und Geröll. Die übrigen Klassen (`fell`, `heath`, `scrub`, `glacier`) wurden zur Sammelkategorie „`other_surface`“ zusammengefasst, um eine dreiklassige Differenzierung zwischen Fels, Geröll und sonstigen Oberflächenformen zu ermöglichen.

Die verwendete Overpass -Query lautete:

```
[out:json][timeout:500];
```

```
(
  way["natural"~"^(bare_rock|scree|fell|heath|scrub|glacier)$"]({{bbox}});
  relation["natural"~"^(bare_rock|scree|fell|heath|scrub|glacier)$"]({{bbox}});
);
out body;
>;
out skel qt;
```

Die Bounding Box wurde auf das Untersuchungsgebiet des Rettenbachferners begrenzt. Das Abfrageergebnis wurde als GeoJSON -Datei exportiert und in ArcGIS Pro mithilfe des Werkzeugs „JSON to Features“ in eine Polygon -Feature -Class konvertiert. Anschließend erfolgte ein Zuschchnitt der Polygone auf das definierte Arbeitsgebiet mittels „Clip“.

Alternativ wäre ein vollständiger OSM -Datenimport (z. B. über Geofabrik), eine manuelle Digitalisierung oder die Nutzung nationaler Geodatensätze möglich gewesen. Overpass Turbo wurde gewählt, da es eine gezielte Attributselektion, eine thematische Fokussierung sowie eine vollständig dokumentierbare und reproduzierbare Datenerhebung ermöglicht.

Da OSM als community -basiertes Projekt regionale Unterschiede in Genauigkeit und Aktualität aufweisen kann, wurden die extrahierten Polygone visuell anhand von Orthofotos überprüft. Die finalen Polygonflächen bilden die räumliche Referenzbasis für die Ableitung der Trainings - und Testdaten.




Abbildung 15: Aus OpenStreetMap extrahierte Polygone der Klassen scree (blau) und bare_rock (magenta) im Untersuchungsgebiet des Rettenbachferners, überlagert auf dem Hillshade des digitalen Höhenmodells (10 m). Die Daten wurden

über *Overpass Turbo* mittels einer gezielten Query abgerufen und anschließend in *ArcGIS Pro* zugeschnitten und als Trainingsdaten für die Klassifikation aufbereitet.

3.4.2 Ableitung von Trainingspunkten innerhalb der OSM -Polygone

Zur Verknüpfung der Rasterwerte mit den Referenzflächen wurden zufällig verteilte Punkte innerhalb der OSM -Polygone generiert. Vor der Punkterstellung wurden die Polygone je Klasse mittels des Werkzeugs „Dissolve“ zusammengefasst. Dadurch wird verhindert, dass einzelne kleine Polygone aufgrund ihrer Anzahl überrepräsentiert werden, während größere zusammenhängende Flächen unterrepräsentiert bleiben. Die Zusammenfassung gewährleistet eine gleichmäßige Stichprobenverteilung über die gesamte Klassenfläche und reduziert potenzielle Verzerrungen in der Trainingsbasis.

Die Punkterzeugung erfolgte in *ArcGIS Pro* mit dem Werkzeug „Create Random Points“. Für die drei Zielklassen wurden folgende Stichprobengrößen festgelegt:

- *bare_rock*: 2.000 Punkte
- *scree*: 2.000 Punkte
- *other_surface*: 4.000 Punkte

Die Wahl von jeweils 2.000 Punkten für die Klassen *bare_rock* und *scree* dient der Sicherstellung einer stabilen und statistisch belastbaren Trainingsbasis. Eine ausreichend große Stichprobe ermöglicht es dem Random -Forest -Algorithmus, die spektrale und topographische Variabilität innerhalb der Klassen zuverlässig zu erfassen, ohne dass einzelne Zufallsausprägungen dominieren. Gleichzeitig bleibt der Datensatzumfang rechnerisch effizient und vermeidet eine unnötige Erhöhung der Modellkomplexität.

Für die Klasse *other_surface* wurde eine höhere Punktzahl (4.000) gewählt. Diese Klasse umfasst mehrere unterschiedliche Oberflächentypen (*fell*, *heath*, *scrub*, *glacier*) und weist daher eine größere interne Heterogenität auf als die Klassen *bare_rock* und *scree*. Eine erhöhte Stichprobengröße stellt sicher, dass die verschiedenen Subtypen innerhalb dieser Sammelkategorie ausreichend repräsentiert sind und nicht unterproportional in das Training eingehen. Darüber hinaus trägt die erhöhte Punktzahl dazu bei, eine potenzielle Klassenimbalance auszugleichen, da *other_surface* flächenmäßig im Untersuchungsgebiet dominiert. Insgesamt ergibt sich eine Trainingsbasis von 8.000 Punkten. Diese Stichprobengröße gewährleistet eine ausreichende Repräsentativität aller Klassen bei gleichzeitig kontrolliertem Rechenaufwand und bildet eine stabile Grundlage für das Random -Forest -Verfahren.

Jeder generierte Punkt liegt vollständig innerhalb eines eindeutig zugeordneten Referenzpolygons, wodurch eine klare Klassenreferenz gewährleistet ist. Für die Modellierung wurde ein numerisches Klassenfeld (classvalue) definiert:

- 1 = bare_rock
- 2 = scree
- 3 = other_surface

Dieses Feld dient als Zielvariable im Random -Forest -Klassifikator.

3.4.3 Extraktion spektraler und topographischer Werte

Zur Anreicherung der generierten Trainingspunkte mit erklärenden Variablen wurden für jede Punktposition die Werte aller relevanten Rasterdatensätze extrahiert. Dieser Schritt erfolgte in ArcGIS Pro mit dem Werkzeug „Extract Multi Values to Points“.

Für jeden Punkt wurden folgende Variablen hinterlegt:

- Sentinel -2 -Bänder (10 m sowie auf 10 m resampelte 20 m -Bänder)
- Hangneigung (Slope)
- Exposition (Aspect)
- Höhenwert aus dem digitalen Höhenmodell (10 m)

Die Kombination spektraler und topographischer Merkmale ermöglicht eine differenzierte Beschreibung der Oberflächenbedingungen. Während die multispektralen Sentinel -2 -Bänder materialbezogene Reflexionseigenschaften erfassen, liefern Hangneigung, Exposition und Höhe zusätzliche Informationen zur geomorphologischen Einbettung der Flächen.

Durch diese Attributanreicherung entsteht ein multivariater Datensatz, der als Eingangsvariablenbasis für den Random -Forest -Klassifikator dient.

3.4.4 Zusammenführung und räumliche Trennung der Trainings - und Testdaten

Nach der Extraktion der Rasterwerte wurden die Punktdatensätze aller drei Klassen mittels des Werkzeugs „Merge“ zu einer gemeinsamen Feature -Class zusammengeführt.

Die resultierende Punktbasis enthält für jeden Stichprobenpunkt:

- die Klasseninformation (classvalue)
- sämtliche spektralen Sentinel -2 -Variablen
- die topographischen Parameter

Um eine realistische Bewertung der Modellleistung zu gewährleisten und Data Leakage zu vermeiden, wurde anschließend ein räumlicher Trainings-/Test-Split durchgeführt.

Die Punktdaten wurden entlang einer vertikalen Trennlinie im Zentrum des Untersuchungsgebiets (X-Koordinate = 221755.317766) in zwei Teilmengen untergliedert. Die westlich gelegenen Punkte wurden als Trainingsdaten definiert, während die östlich gelegenen Punkte als unabhängige Testdaten dienten. Durch diese räumliche Trennung wird verhindert, dass das Modell auf räumlich unmittelbar benachbarten Pixeln trainiert und getestet wird. Dadurch wird die Generalisierungsfähigkeit des Random-Forest-Modells unter realistischeren Bedingungen bewertet. Die Trainingsdaten wurden ausschließlich für das Modelltraining verwendet, während die Testdaten im weiteren Workflow ausschließlich der unabhängigen Validierung dienten.




Abbildung 16: Darstellung des räumlichen Trainings-/Test-Splits der Stichprobenpunkte im Untersuchungsgebiet. Die westlich der Split-Grenze liegenden Punkte wurden für das Modelltraining verwendet ($n = 1.490$), die östlichen Punkte dienten der unabhängigen Validierung ($n = 758$).

3.5 Modelltraining mit dem Random-Forest-Klassifikator

3.5.1 Vorbereitung der Trainingsdaten

Für das Modelltraining wurden ausschließlich die im räumlichen Split definierten Trainingspunkte verwendet. Die Testpunkte wurden konsequent vom Trainingsprozess ausgeschlossen und ausschließlich für die spätere Validierung herangezogen. Die Trainingspunkte enthalten neben der Zielvariable (classvalue) sämtliche spektralen Sentinel -2 -Variablen sowie die topographischen Parameter Hangneigung, Exposition und Höhe. Punkte mit fehlenden Rasterwerten wurden aus dem Datensatz entfernt, um eine konsistente und stabile Trainingsbasis sicherzustellen. Die Zielvariable classvalue wurde gemäß der in Abschnitt 3.4.2 definierten dreiklassigen Kodierung verwendet. Durch die stratifizierte Stichprobe von insgesamt 8.000 Trainingspunkten liegt eine ausgewogene und statistisch belastbare Trainingsbasis vor. Diese bildet die Grundlage für das überwachte Lernverfahren und ermöglicht die Modellierung der spektralen und topographischen Unterschiede zwischen Fels -, Geröll - und sonstigen Oberflächenformen im Untersuchungsgebiet.

3.5.2 Auswahl und Begründung des Klassifikationsverfahrens

Für die Klassifikation der alpinen Oberflächenformen wurde ein Random -Forest -Klassifikator eingesetzt. Die Wahl dieses Verfahrens basiert auf methodischen sowie datenbezogenen Überlegungen. Random Forest zählt zu den ensemblebasierten, baumgestützten Lernverfahren und eignet sich insbesondere für Datensätze mit hoher Variablenzahl und komplexen, nichtlinearen Zusammenhängen. Die Kombination aus multispektralen Sentinel -2 -Bändern und topographischen Parametern führt zu heterogenen Merkmalsräumen, die durch baumbasierte Modelle ohne Annahmen über die zugrunde liegende Datenverteilung effizient modelliert werden können (Thomas et al., 2023). Darüber hinaus gilt Random Forest als vergleichsweise robust gegenüber Ausreißern und moderaten Klassenungleichgewichten.

Als alternative Methodik wurden Deep -Learning -Ansätze, insbesondere Convolutional Neural Networks (CNNs), berücksichtigt. CNN -basierte Verfahren zeigen in zahlreichen Studien eine hohe Leistungsfähigkeit, insbesondere bei sehr hochauflösenden Bilddaten und objektbasierten Detailanalysen. Ihr Vorteil liegt vor allem in der automatisierten Erkennung räumlicher Textur - und Strukturmuster. Im vorliegenden Fall basiert die Analyse jedoch auf multispektralen Satellitendaten mittlerer räumlicher Auflösung (10 m), bei denen großflächige Materialunterschiede dominieren und feinstrukturelle Texturinformationen nur begrenzt vorhanden

sind. Unter diesen Bedingungen erzielen klassische Machine -Learning -Verfahren häufig vergleichbare oder stabilere Ergebnisse als CNN -Modelle (Pirkash, 2025; Maslov et al., 2025). Zudem sind Deep -Learning -Ansätze typischerweise mit höherem Trainingsaufwand und größerer Modellkomplexität verbunden. Da das Ziel dieser Arbeit die robuste und reproduzierbare Trennung großräumiger alpiner Oberflächenformen ist, stellt Random Forest unter den gegebenen Daten - und Rahmenbedingungen die methodisch angemessene und wissenschaftlich gut begründete Wahl dar.

3.5.3 Konfiguration und Training des Random -Forest -Modells

Das Modelltraining erfolgte in ArcGIS Pro mit dem Werkzeug „Train Random Trees Classifier“. Als Eingabe diente der multibandige Sentinel -2 -Stack (s2_stack_clip) in Kombination mit der im räumlichen Split definierten Trainingspunkt -Feature -Class. Das Feld classvalue wurde als Zielvariable festgelegt. Die Modellparameter wurden wie folgt definiert:

- Max Number of Trees: 50
Diese Anzahl gewährleistet eine stabile Aggregation mehrerer Entscheidungsbäume bei gleichzeitig moderatem Rechenaufwand. Ensemble -basierte Verfahren erreichen ab einer bestimmten Baumanzahl eine weitgehende Stabilisierung der Modellleistung, sodass zusätzliche Bäume nur noch geringe Verbesserungen bewirken (Thomas et al., 2023; Sharda et al., 2022).
- Max Tree Depth: 30
Die gewählte maximale Baumtiefe erlaubt die Abbildung komplexer, nichtlinearer Zusammenhänge zwischen spektralen und topographischen Variablen, ohne eine übermäßige Spezialisierung einzelner Entscheidungsbäume zu begünstigen.
- Max Number of Samples per Class: 1000
Dieser Wert entspricht der maximalen Stichprobengröße der kleineren Klassen (*bare_rock* und *scree*) und verhindert, dass die flächenmäßig dominierende Klasse *other_surface* das Training unverhältnismäßig beeinflusst.

Das Training resultierte in einer Modelldefinitionsdatei (RF_classifier.ecd), welche die Struktur der Entscheidungsbäume sowie die erlernten Klassifikationsregeln enthält und im folgenden Schritt zur flächendeckenden Rasterklassifikation eingesetzt wurde.




Abbildung 17: Konfiguration des Random -Forest -Modells im Werkzeug „Train Random Trees Classifier“ (ArcGIS Pro).

Die Anzahl der Entscheidungsbäume wurde auf 50 festgelegt, da sich Ensemble -Modelle ab einer bestimmten Baumanzahl stabilisieren und zusätzliche Bäume nur geringe Leistungsverbesserungen bewirken. Die maximale Baumtiefe von 30 ermöglicht die Abbildung komplexer nichtlinearer Zusammenhänge zwischen spektralen und topographischen Variablen, ohne eine übermäßige Spezialisierung einzelner Bäume zu begünstigen. Die Begrenzung der Stichprobenanzahl pro Klasse dient der Vermeidung einer Dominanz flächenstärkerer Klassen im Trainingsprozess.

3.5.4 Technische Umsetzung (ArcGIS Pro und arcpy)

Das Modelltraining wurde vollständig innerhalb von ArcGIS Pro durchgeführt. Die Verwendung einer einheitlichen GIS -Umgebung gewährleistet eine konsistente Datenverarbeitung sowie eine klare Dokumentation der einzelnen Verarbeitungsschritte.

Die eingesetzten Werkzeuge basieren auf dem arcpy -Modul und sind damit grundsätzlich skriptfähig. Dadurch ist eine reproduzierbare Umsetzung des Trainingsprozesses möglich. In der vorliegenden Arbeit wurde der grafische Workflow verwendet, um die Parametrierung des Modells transparent darzustellen und die einzelnen Einstellungen nachvollziehbar zu dokumentieren.

3.5.5 Ergebnis des Trainingsschrittes

Das trainierte Random -Forest -Modell wurde als Modelldefinitionsdatei (RF_classifier.ecd) gespeichert. Diese Datei enthält die Struktur der Entscheidungsbäume sowie die erlernten Klassifikationsregeln und bildet die Grundlage für die anschließende Anwendung des Modells auf den Sentinel -2 -Rasterstack. Im folgenden Schritt wird das trainierte Modell zur flächen-deckenden dreiklassigen Klassifikation des Untersuchungsgebiets eingesetzt.

3.6 Anwendung des Random -Forest -Modells auf die Sentinel -2 -Daten

Nach Abschluss des Trainingsprozesses wurde das erstellte Klassifikationsmodell auf den multispektralen Sentinel -2 -Datenstack angewendet, um eine flächendeckende Kartierung der Fels - und Geröllflächen im Untersuchungsgebiet zu erzeugen. Die Umsetzung erfolgte in ArcGIS Pro mithilfe des Werkzeugs Classify Raster, wobei als Eingaberaster der zuvor erstellte Bandstack (s2_stack_clip) sowie die topographischen Ableitungen Slope und Aspect dienten. Als Klassifikationsmodell wurde die im Training generierte Modelldatei RF_classifier.ecd eingebunden, die sämtliche Entscheidungsbäume und Parameter des Random -Forest -Ansatzes enthält. Für jedes Pixel wurden die Werte der spektralen und topographischen Variablen automatisiert durch das Modell bewertet und einer der beiden Zielklassen bare_rock (1) oder scree (2) zugewiesen. Das Ausgaberraster (RF_classification.tif) besitzt eine räumliche Auflösung von 10 m und liegt im selben Koordinatenreferenzsystem wie die Eingangsdaten vor, sodass keine zusätzliche Reprojektion erforderlich war. Die Klassifikation erfolgte vollständig pixelbasiert, eine Segmentierung oder Generalisierung der Flächen wurde bewusst nicht vorgenommen, um die reine Modellwirkung zu bewahren. Anschließend wurde das Klassifikationsergebnis auf das definierte Untersuchungsgebiet geclippt, sodass ausschließlich Pixel innerhalb der alpinen Testregion Berücksichtigung finden. Die Ausgabe wurde mit einer zweistufigen Klassenlegende versehen, um eine klare visuelle Differenzierung von Fels - und Geröllflächen zu gewährleisten. Dieses Raster bildet die Grundlage für die weiterführende Ergebnisanalyse sowie die nachfolgende Validierung der Modellgüte.

Die nachfolgende Abbildung fasst den gesamten methodischen Workflow der vorliegenden Arbeit schematisch zusammen.



Abbildung 18: Methodischer Workflow der dreiklassigen Random -Forest -Klassifikation von Fels -, Geröll - und weiteren Oberflächenformen im Untersuchungsgebiet.

4 Ergebnisse

4.1 Räumliche Verteilung der Klassifikationsergebnisse

Nach Abschluss des Trainingsprozesses wurde das trainierte Random -Forest -Modell auf den multispektralen Sentinel -2 -Datenstack angewendet, um eine flächendeckende dreiklassige Kartierung der alpinen Oberflächenformen im Untersuchungsgebiet zu erzeugen.

Die Umsetzung erfolgte in ArcGIS Pro mit dem Werkzeug „Classify Raster“. Als Eingabe diente der multibandige Sentinel -2 -Stack (s2_stack_clip), der die spektralen Bänder sowie die abgeleiteten topographischen Variablen (Hangneigung, Exposition und Höhe) umfasst. Als Klassifikationsmodell wurde die im Trainingsprozess generierte Modelldefinitionsdatei (RF_classifier.ecd) eingebunden. Für jedes Rasterpixel wurden die spektralen und topographischen Variablen durch das Modell bewertet und einer der drei Zielklassen zugeordnet. Die Klassifikation erfolgte vollständig pixelbasiert; eine nachträgliche Segmentierung oder Generalisierung der Flächen wurde nicht vorgenommen, um die unmittelbare Modellwirkung unverändert abzubilden. Das resultierende Ausgaberraster (RF_classification.tif) besitzt eine räumliche Auflösung von 10 m und liegt im selben Koordinatenreferenzsystem wie die Eingangsdaten vor. Eine zusätzliche Reprojektion war daher nicht erforderlich. Anschließend wurde das Klassifikationsergebnis auf das definierte Untersuchungsgebiet zugeschnitten, sodass ausschließlich Pixel innerhalb der alpinen Untersuchungsregion berücksichtigt werden.

Die Ausgabe wurde mit einer dreistufigen Klassenlegende visualisiert und bildet die Grundlage für die anschließende Ergebnisanalyse sowie die Validierung der Modellgüte. Die Ausgabe wurde mit einer dreistufigen Klassenlegende visualisiert und bildet die Grundlage für die anschließende Ergebnisanalyse sowie die Validierung der Modellgüte.

Random-Forest-Klassifikation von Fels-, Geröll- und sonstigen Oberflächen im Gebiet des Rettenbachferners




Abbildung 19: Ergebnis der dreiklassigen Random -Forest -Klassifikation im Untersuchungsgebiet des Rettenbachferners (räumliche Auflösung 10 m). Dargestellt sind die Klassen Bare Rock, Scree und Other Surface.

4.2 Validierung der Klassifikation

Zur Bewertung der Modellgüte wurde eine unabhängige Validierung anhand der im räumlichen Split definierten Teststichprobe durchgeführt. Insgesamt gingen 3.311 Testpunkte in die Berechnung der Konfusionsmatrix ein. Diese Punkte wurden nicht im Trainingsprozess verwendet und ermöglichen daher eine realistische Einschätzung der Generalisierungsfähigkeit des Modells.

Für jeden Testpunkt wurde der klassifizierte Rasterwert extrahiert und mit der Referenzklasse verglichen. Auf dieser Grundlage wurde eine dreiklassige Konfusionsmatrix erstellt, aus der die Gesamtgenauigkeit, die Produzentengenauigkeit (Producer's Accuracy), die Nutzer*innen-genauigkeit (User's Accuracy) sowie der Kappa -Koeffizient berechnet wurden.

Die Gesamtgenauigkeit der Klassifikation beträgt 62,8 %, der Kappa -Koeffizient liegt bei 0,38. Dies weist auf eine deutliche, jedoch nicht vollständige Übereinstimmung zwischen Referenz - und Klassifikationsdaten hin. Die klassenbezogenen Genauigkeiten zeigen deutliche Unterschiede: Die Klasse *other_surface* erreicht mit einer Produzentengenauigkeit von 93,6 % die

höchste Erkennungsrate. Dies bedeutet, dass der überwiegende Teil der Referenzpunkte dieser Klasse korrekt identifiziert wurde. Die Nutzer*innengenauigkeit beträgt 65,7 %, was darauf hinweist, dass ein Teil der als *other_surface* klassifizierten Pixel tatsächlich anderen Klassen zuzuordnen ist. Für *bare_rock* liegt die Produzentengenauigkeit bei 32,4 %, für *scree* bei 38,6 %. Diese Werte zeigen, dass ein erheblicher Anteil der Referenzpunkte dieser beiden Klassen vom Modell nicht korrekt erkannt wurde. Die Nutzer*innengenauigkeit beträgt 64,0 % für *bare_rock* und 50,6 % für *scree*, was auf eine moderate Zuverlässigkeit der jeweiligen Klassenzuweisung hinweist. Die Konfusionsmatrix verdeutlicht, dass insbesondere zwischen *bare_rock* und *scree* ausgeprägte Fehlklassifikationen auftreten. Diese Verwechslungen sind vor allem auf die spektrale Ähnlichkeit beider Oberflächentypen zurückzuführen. Grobblockiges Geröll und kompakter Fels weisen vergleichbare Reflexionseigenschaften im sichtbaren und nahinfraroten Spektralbereich auf. Zusätzlich können topographische Effekte, Schattenschichten sowie subpixelige Durchmischungen innerhalb der 10 -m -Pixel zu Unsicherheiten in der Klassenzuweisung führen. Die erzielte Gesamtgenauigkeit liegt im Bereich vergleichbarer Studien zur Klassifikation alpiner Oberflächen mit Sentinel -2 -Daten mittlerer räumlicher Auflösung. Die Ergebnisse bestätigen die grundsätzliche Eignung des gewählten Modellansatzes, zeigen jedoch zugleich die Grenzen einer pixelbasierten Klassifikation bei komplex strukturierten Hochgebirgsflächen.

final_matrix								
Field: Add Calculate Selection: Select By Attributes Zoom To Switch Cl								
	OBJECTID *	ClassValue	C_1	C_2	C_3	Total	U_Accuracy	Kappa
1	1	C_1	317	129	49	495	0.640404	0
2	2	C_2	236	295	52	583	0.506003	0
3	3	C_3	425	340	1468	2233	0.657412	0
4	4	Total	978	764	1569	3311	0	0
5	5	P_Accuracy	0.324131	0.386126	0.935628	0	0.628209	0
6	6	Kappa	0	0	0	0	0	0.375792
Click to add new row.								

Abbildung 20: Konfusionsmatrix der Validierung mit Overall Accuracy von 62,8 % und Kappa von 0,38.

4.3 Einordnung der Klassifikationsergebnisse

Die dreiklassige Random -Forest -Klassifikation zeigt eine räumlich differenzierte Verteilung der Oberflächenformen im Untersuchungsgebiet. Während die Klasse *other_surface* großflächig zusammenhängende Bereiche abdeckt, treten *bare_rock* und *scree* überwiegend in stärker reliefierten Hang - und Gratlagen auf.

Die Validierungsergebnisse (vgl. Abschnitt 4.2) verdeutlichen jedoch, dass die Trennung zwischen *bare_rock* und *scree* nur eingeschränkt gelingt. Insbesondere zwischen diesen beiden Klassen treten ausgeprägte Fehlklassifikationen auf. Dies spiegelt die geomorphologische Realität wider, da Fels - und Geröllflächen in hochalpinen Gebieten häufig mosaikartig ineinandergreifen und graduelle Übergänge bilden. Die pixelbasierte Klassifikation ordnet jedoch jedem 10 -m -Pixel eine dominante Klasse zu, wodurch Übergangsbereiche zwangsläufig vereinfacht dargestellt werden.

Die hohe Produzentengenauigkeit der Klasse *other_surface* deutet darauf hin, dass großflächige und spektral klar abgrenzbare Oberflächen zuverlässig erkannt werden. Demgegenüber zeigen die geringeren Genauigkeitswerte für *bare_rock* und *scree*, dass spektrale Ähnlichkeiten sowie subpixelige Durchmischungen die Klassifikation erschweren. Insbesondere blockreiche Geröllflächen und kompakte Felsbereiche weisen vergleichbare Reflexionseigenschaften auf, wodurch eine eindeutige Differenzierung auf 10 -m -Auflösung begrenzt bleibt.

Die Ergebnisse sind daher als generalisierte Abbildung dominanter Oberflächentypen zu interpretieren. Sie liefern eine konsistente Übersicht über die räumliche Struktur der alpinen Landschaft, erfassen jedoch nicht sämtliche kleinräumigen Übergangsprozesse.

Insgesamt bestätigen die Resultate die grundsätzliche Eignung des gewählten Modellansatzes für eine flächenhafte Differenzierung alpiner Oberflächenformen, verdeutlichen jedoch zugleich die Grenzen einer pixelbasierten Klassifikation bei mittlerer räumlicher Auflösung.

5. Diskussion

5.1 Interpretation der Ergebnisse

Die durchgeführte dreiklassige Klassifikation zeigt eine räumlich differenzierte Verteilung der Oberflächenformen im Untersuchungsgebiet. Während die Klasse *other_surface* großflächig zusammenhängende Bereiche abdeckt, treten *bare_rock* und *scree* überwiegend in stärker reliefierten Hang - und Gratlagen auf. Die räumlichen Muster entsprechen damit grundsätzlich den geomorphologischen Erwartungen für hochalpine Landschaften.

Die Validierung ergibt eine Overall Accuracy von 62,8 % sowie einen Kappa -Koeffizienten von 0,38. Diese Werte deuten auf eine moderate, jedoch keine perfekte Übereinstimmung zwischen Referenz - und Klassifikationsdaten hin. Auffällig ist insbesondere die vergleichsweise hohe Genauigkeit der Klasse *other_surface*, während zwischen *bare_rock* und *scree* deutliche Fehlklassifikationen auftreten. Ein erheblicher Anteil der Referenzpunkte dieser beiden Klassen wird jeweils der anderen Klasse zugeordnet.

Diese Verwechslungen sind geomorphologisch nachvollziehbar. Fels - und Geröllflächen bilden im Hochgebirge häufig keine scharf abgegrenzten Einheiten, sondern gehen graduell ineinander über. Blockreiche Geröllfelder enthalten oft größere Felsanteile, während kompakte Felsflächen durch Verwitterungsprozesse mit lockerem Material überdeckt sein können. Auf der 10 -m -Pixelauflösung von Sentinel -2 werden solche Übergangsbereiche zwangsläufig generalisiert, sodass ein Pixel jeweils nur einer dominanten Klasse zugewiesen wird. Subpixelige Durchmischungen bleiben dabei unberücksichtigt. Die Kombination aus spektralen Sentinel -2 -Bändern und topographischen Parametern liefert dennoch eine stabile Grundlage zur Unterscheidung großflächiger Oberflächentypen. Insbesondere Hangneigung und Exposition tragen dazu bei, strukturelle Unterschiede im Reliefkontext zu berücksichtigen. Die Ergebnisse zeigen somit, dass der Random -Forest -Ansatz geeignet ist, dominante alpine Oberflächenformen flächenhaft zu erfassen, auch wenn eine eindeutige Trennung zwischen spektral ähnlichen Klassen nur eingeschränkt möglich ist. Insgesamt ist die Modellleistung als realistisch für eine pixelbasierte Klassifikation mittlerer räumlicher Auflösung einzustufen. Die Resultate liefern eine konsistente Übersicht über die räumliche Struktur des Untersuchungsgebiets, verdeutlichen jedoch zugleich die Grenzen der Differenzierung zwischen Fels - und Geröllflächen unter natürlichen Übergangsbedingungen.

5.2 Methodische Herausforderungen und Unsicherheiten

5.2.1 Einfluss der Datenbasis und Referenzdaten

Die erzielte Gesamtgenauigkeit von 62,8 % verdeutlicht, dass die Klassifikation zwar belastbare Muster liefert, jedoch mit Unsicherheiten verbunden ist. Ein zentraler Einflussfaktor ist die verwendete Datenbasis, insbesondere die OSM -basierten Referenzflächen.

OpenStreetMap stellt eine frei verfügbare und thematisch differenzierte Datenquelle dar, ist jedoch ein community -basiertes Projekt mit variierender räumlicher Genauigkeit und

Detailtiefe. Die Referenzpolygone repräsentieren überwiegend klar abgegrenzte Oberflächentypen, während Übergangszonen oder kleinräumig durchmischte Bereiche nur eingeschränkt abgebildet werden. In hochalpinen Landschaften treten jedoch häufig graduelle Übergänge zwischen Fels - und Geröllflächen auf, die in polygonbasierten Referenzdaten nur vereinfacht erfasst werden. Ein weiterer Aspekt betrifft die Generalisierung innerhalb der OSM -Polygone. Auch wenn zufällige Punkte innerhalb der Flächen generiert wurden, können interne Heterogenitäten - etwa kleinere Geröllinseln innerhalb von Felsbereichen - nicht vollständig berücksichtigt werden. Dadurch kann es zu Abweichungen zwischen der tatsächlichen Oberflächenstruktur und der zugewiesenen Referenzklasse kommen. Die räumliche Trennung von Trainings - und Testpunkten reduziert zwar die Gefahr einer direkten Überanpassung, dennoch können ähnliche geomorphologische Rahmenbedingungen in beiden Teilbereichen auftreten. Dies kann die Modellleistung sowohl begünstigen als auch einschränken. Die Validierungsergebnisse sind daher stets im Kontext der Qualität und Generalisierung der zugrunde liegenden Referenzdaten zu interpretieren.

5.2.2 Einfluss der räumlichen Auflösung und Topographie

Eine weitere zentrale Unsicherheitsquelle ergibt sich aus der räumlichen Auflösung der eingesetzten Sentinel -2 -Daten. Mit einer Pixelgröße von 10 m werden kleinräumige geomorphologische Strukturen nur begrenzt erfasst. Insbesondere in blockreichen Geröllfeldern oder stark fragmentierten Felsbereichen können innerhalb eines Pixels mehrere Oberflächentypen auftreten, was zu Mischpixeln führt. Diese subpixeligen Durchmischungen erschweren eine eindeutige Klassenzuweisung und tragen zur beobachteten Verwechslung zwischen *bare_rock* und *scree* bei. Während großflächige und relativ homogene Bereiche zuverlässig identifiziert werden, ist die Differenzierung in Übergangs - und Randbereichen naturgemäß eingeschränkt. Zusätzlich beeinflussen topographische Effekte wie Hangneigung, Exposition und Schattenwurf die spektralen Eigenschaften der Oberflächen. In steilen Hanglagen können starke Beleuchtungsunterschiede auftreten, wodurch identische Materialien unterschiedliche Reflexionswerte aufweisen. Die Integration topographischer Ableitungen in das Modell trägt zwar zur Berücksichtigung des Reliefkontextes bei, kann jedoch spektrale Überlagerungen nicht vollständig kompensieren. Die Modellunsicherheiten sind daher nicht ausschließlich auf das gewählte Klassifikationsverfahren zurückzuführen, sondern spiegeln grundlegende Limitationen der Datengrundlage und der räumlichen Auflösung wider.

5.2.3 Grenzen der Klassendefinition und Modellübertragbarkeit

Die gewählte Dreiteilung in *bare_rock*, *scree* und *other_surface* stellt eine notwendige Vereinfachung der tatsächlich komplexen hochalpinen Oberflächenverhältnisse dar. Obwohl diese Klassendefinition eine praktikable Struktur für die automatisierte Modellierung bietet, bildet sie die geomorphologische Vielfalt nur in generalisierter Form ab. Insbesondere die Zusammenfassung unterschiedlicher Oberflächentypen (z. B. *fell*, *heath*, *scrub*, *glacier*) in der Sammelkategorie *other_surface* führt zu einer inhaltlichen Vereinfachung. Innerhalb dieser Klasse bestehen erhebliche strukturelle und spektrale Unterschiede, die im Modell nicht weiter differenziert werden. Gleichzeitig zeigt die Validierung, dass die größte Unsicherheit zwischen *bare_rock* und *scree* auftritt, da diese Oberflächentypen in natürlichen Gebirgslandschaften häufig mosaikartig ineinandergreifen und keine scharf abgegrenzten Einheiten bilden. Die erzielten Ergebnisse sind daher im Kontext der gewählten Klassendefinition zu interpretieren. Eine feinere Untergliederung - etwa in unterschiedliche Gerölltypen, Übergangszonen oder vegetationsdurchsetzte Flächen - würde voraussichtlich zu einer höheren Modellkomplexität und möglicherweise zu geringeren Genauigkeitswerten führen. Auch hinsichtlich der Übertragbarkeit ist zu berücksichtigen, dass das Modell auf den spezifischen geomorphologischen und spektralen Bedingungen des Untersuchungsgebiets basiert. Unterschiede in Lithologie, Vegetationsbedeckung, Exposition oder klimatischen Rahmenbedingungen können in anderen alpinen Regionen zu abweichenden Reflexionsmustern führen. Eine direkte Übertragung des trainierten Modells auf andere Gebiete ist daher nicht ohne erneute Anpassung der Trainingsdaten und Validierung möglich. Nichtsdestotrotz zeigt die Untersuchung, dass der Random-Forest-Ansatz unter Verwendung frei verfügbarer Satellitendaten grundsätzlich geeignet ist, dominante Oberflächentypen im Hochgebirge automatisiert zu erfassen. Die Modellleistung ist dabei als kontextabhängig und maßstabsbezogen zu verstehen.

5.3 Vergleich mit bestehenden Studien und Literatur

Die in dieser Arbeit erzielten Ergebnisse fügen sich grundsätzlich in den bisherigen Forschungsstand zur Klassifikation glazial-periglazialer Oberflächenformen ein. Zahlreiche Studien zeigen, dass maschinelle Lernverfahren - insbesondere Random-Forest-Modelle - für die automatisierte Erfassung geomorphologischer Einheiten gut geeignet sind, da sie nichtlineare

Zusammenhänge zwischen spektralen und topographischen Variablen erfassen und robuste Ergebnisse bei heterogenen Eingangsdatensätzen liefern (z. B. Thomas et al., 2023; Sharda et al., 2022). In vergleichbaren Untersuchungen werden teilweise höhere Gesamtgenauigkeiten berichtet, insbesondere bei zweiklassigen Klassifikationen oder bei Verwendung hochauflösender Bilddaten. Allerdings hängt die Modellgüte stark von der Anzahl der Klassen, der Komplexität des Untersuchungsgebiets, der räumlichen Auflösung sowie der Validierungsstrategie ab. Studien ohne räumlich getrennte Trainings - und Testdatensätze oder mit homogenen Referenzflächen erzielen häufig höhere Genauigkeitswerte. Die in dieser Arbeit erreichte Overall Accuracy von 62,8 % liegt unter den in einzelnen Publikationen berichteten Spitzenwerten, ist jedoch im Kontext einer dreiklassigen, räumlich getrennten Validierung mit 10 -m -Sentinel -2 -Daten als realistisch einzustufen. Insbesondere die Differenzierung zwischen spektral ähnlichen Oberflächen wie *bare_rock* und *scree* stellt eine bekannte Herausforderung dar, die auch in anderen alpinen Studien beschrieben wird. Ein zentraler Erfolgsfaktor, der sich mit der Literatur deckt, ist die Integration topographischer Ableitungen in den Merkmalsraum. Hangneigung und Exposition werden wiederholt als wichtige Zusatzvariablen hervorgehoben, da sie eng mit geomorphologischen Prozessen verknüpft sind und strukturelle Unterschiede zwischen Oberflächentypen verstärken können. Die Ergebnisse dieser Arbeit bestätigen, dass die Kombination spektraler Sentinel -2 -Daten mit Reliefparametern eine wesentliche Voraussetzung für eine differenzierte Oberflächenklassifikation im Hochgebirge darstellt.

Gleichzeitig zeigen Untersuchungen mit komplexeren Klassenschemata oder stärker fragmentierten Landschaften, dass die Modellleistung mit zunehmender Klassenanzahl und struktureller Heterogenität typischerweise abnimmt. Vor diesem Hintergrund ist die vorliegende Klassifikation als generalisierte Abbildung dominanter Oberflächentypen zu verstehen, nicht als hochauflösende Detailkartierung. Insgesamt bestätigt die Arbeit den in der Literatur beschriebenen Nutzen datengetriebener Klassifikationsverfahren für die geomorphologische Kartierung, verdeutlicht jedoch zugleich die maßstabs - und kontextabhängige Natur der erzielten Modellleistung.

5.4 Relevanz für Praxis und Forschung

Die Ergebnisse dieser Arbeit verdeutlichen, dass satellitengestützte Klassifikationsverfahren einen relevanten Beitrag zur geomorphologischen Kartierung in hochalpinen Regionen leisten können. Die automatisierte Differenzierung zwischen *bare_rock*, *scree* und *other_surface*

ermöglicht eine flächenhafte Erfassung dominanter Oberflächentypen, die mit klassischen Geländeerhebungen nur unter erheblichem Zeit - und Ressourcenaufwand realisierbar wäre. Obwohl die erreichte Modellgenauigkeit eine vollständige Detailkartierung nicht ersetzt, bietet die Klassifikation eine konsistente Übersicht über großräumige Muster der Oberflächenverteilung. Daraus ergibt sich ein praxisrelevantes Potenzial insbesondere für Anwendungen in der alpinen Gefahrenbeurteilung, der Gletscher - und Permafrostforschung sowie im Naturschutz - und Flächenmanagement. Karten zur räumlichen Verteilung von Geröll -, Fels - und sonstigen Oberflächenbereichen können beispielsweise als Grundlage für die Abschätzung potenzieller Steinschlag - oder Rutschungsprozesse dienen oder Hinweise auf geomorphologisch aktive Zonen liefern. Auch aus wissenschaftlicher Perspektive ist die angewandte Methodik von Bedeutung. Die Studie zeigt, dass bereits multispektrale Satellitendaten mittlerer räumlicher Auflösung in Kombination mit maschinellen Lernverfahren eine belastbare Differenzierung großflächiger Oberflächentypen ermöglichen. Dies unterstreicht, dass hochauflösende und kostenintensive Sensordaten nicht zwingend erforderlich sind, um grundlegende geomorphologische Strukturen zu analysieren. Gleichzeitig verdeutlichen die Ergebnisse die Grenzen einer pixelbasierten Klassifikation bei komplexen Übergangszonen, was wichtige Implikationen für zukünftige Forschungsdesigns besitzt. Darüber hinaus liefert die Arbeit einen transparent dokumentierten und reproduzierbaren Workflow, der prinzipiell auf andere alpine Untersuchungsgebiete übertragen werden kann, sofern eine angepasste Trainings - und Validierungsstrategie implementiert wird. Insgesamt leistet die Untersuchung damit einen Beitrag zur methodischen Weiterentwicklung digitaler Geomorphologie und zeigt, dass datengetriebene Klassifikationsverfahren ein geeignetes Instrument darstellen, um räumliche Muster alpiner Oberflächenformen systematisch und flächenhaft zu analysieren. Die Ergebnisse können als Ausgangspunkt für weiterführende Fragestellungen dienen, etwa zur zeitlichen Dynamik von Fels - und Geröllflächen im Kontext klimabedingter Gletscher - und Permafrostveränderungen.

6 Fazit und Ausblick

6.1 Zusammenfassung der Erkenntnisse

Ziel dieser Arbeit war es, zu untersuchen, inwieweit sich alpine Oberflächenformen - insbesondere *bare_rock*, *scree* und *other_surface* - mithilfe multispektraler Sentinel -2 -Daten und eines Random -Forest -Klassifikationsansatzes automatisiert differenzieren lassen.

Hierfür wurden OSM -basierte Referenzpolygone aufbereitet, zufällige Trainings - und Testpunkte abgeleitet und um spektrale sowie topographische Variablen ergänzt. Auf Grundlage dieser dreiklassigen Trainingsbasis wurde ein Random -Forest -Modell trainiert und anschließend auf den gesamten Datensatz angewendet.

Die Klassifikation zeigt eine räumlich konsistente Verteilung dominanter Oberflächentypen im Untersuchungsgebiet. Die Validierung mit einer unabhängigen Teststichprobe ergab eine Overall Accuracy von 62,8 % sowie einen Kappa -Koeffizienten von 0,38. Während die Klasse *other_surface* vergleichsweise zuverlässig erkannt wurde, treten zwischen *bare_rock* und *scree* deutliche Fehlklassifikationen auf. Diese Verwechslungen sind insbesondere auf spektrale Ähnlichkeiten sowie auf graduelle Übergänge zwischen Fels - und Geröllflächen zurückzuführen. Die Ergebnisse verdeutlichen, dass die Kombination aus multispektralen Sentinel -2 - Daten und topographischen Parametern im Rahmen der gewählten Methodik geeignet ist, großflächige alpine Oberflächenstrukturen automatisiert zu erfassen. Gleichzeitig zeigen sie jedoch die Grenzen einer pixelbasierten Klassifikation mittlerer räumlicher Auflösung bei der Differenzierung spektral ähnlicher und räumlich durchmischter Klassen. Insgesamt bestätigt die Arbeit das Potenzial datengetriebener Klassifikationsverfahren für die digitale geomorphologische Kartierung, macht jedoch zugleich deutlich, dass die Modellleistung stark von Klassendefinition, Referenzdatenqualität und räumlicher Auflösung abhängt.

6.2 Empfehlungen für künftige Forschung

Die Ergebnisse dieser Arbeit zeigen, dass eine automatisierte Differenzierung alpiner Oberflächenformen mit frei verfügbaren Satellitendaten grundsätzlich möglich ist, jedoch durch die räumliche Auflösung und die Klassendefinition begrenzt wird. Ein zentrales Entwicklungspotenzial liegt in einer differenzierteren Klasseneinteilung. Zukünftige Studien könnten beispielsweise Übergangszonen, unterschiedliche Gerölltypen oder vegetationsdurchsetzte Bereiche gesondert berücksichtigen. Dabei wäre jedoch zu prüfen, inwieweit sich diese Klassen spektral ausreichend voneinander abgrenzen lassen. Darüber hinaus erscheint die Einbindung höher aufgelöster Fernerkundungsdaten vielversprechend. UAV -gestützte Photogrammetrie, Laserscanning oder hochauflösende Satellitendaten könnten insbesondere in kleinräumig strukturierten Bereichen zu einer verbesserten Differenzierung beitragen. Auch zeitserielle

Analysen bieten Potenzial, um dynamische Prozesse wie Gletscherrückzug, Permafrostdegradation oder Hanginstabilitäten systematisch zu erfassen.

Methodisch könnte zudem ein Vergleich unterschiedlicher Klassifikationsverfahren - etwa Support -Vector -Machines oder Deep -Learning - Ansätze - weitere Erkenntnisse über die Leistungsfähigkeit verschiedener Modelle unter alpinen Bedingungen liefern. Ein solcher Vergleich würde eine differenziertere Bewertung algorithmischer Stärken und Schwächen ermöglichen.

6.3 Praktische Anwendungsmöglichkeiten

Die entwickelte Methodik bietet Potenzial für verschiedene Anwendungsfelder in Forschung und Praxis. Flächenhafte Klassifikationen alpiner Oberflächenformen können als Grundlage für geomorphologische Analysen, Naturgefahrenabschätzungen sowie für Monitoringprozesse in hochalpinen Regionen dienen. Insbesondere im Kontext von Steinschlag -, Rutschungs- oder Permafrostprozessen können Informationen zur räumlichen Verteilung von Fels -, Geröll- und sonstigen Oberflächenbereichen wertvolle Hinweise auf potenziell instabile Zonen liefern. Die satellitengestützte Datenerhebung ermöglicht dabei eine regelmäßige und vergleichsweise kosteneffiziente Aktualisierung großräumiger Kartierungen. Auch für die Gletscher- und Klimafolgenforschung kann die automatisierte Erfassung dominanter Oberflächentypen einen Beitrag leisten, etwa zur Analyse von Veränderungen im Umfeld zurückweichender Gletscherzungen oder zur Beobachtung neu freigelegter Fels- und Schuttflächen. Die entwickelte Vorgehensweise ist prinzipiell auf andere alpine Untersuchungsgebiete übertragbar, sofern eine angepasste Trainings- und Validierungsstrategie implementiert wird. Damit stellt die Arbeit einen Baustein für die systematische, datengetriebene Analyse geomorphologischer Muster im Hochgebirge dar.

Literaturverzeichnis

- Alifu, H., Vuillaume, J., Johnson, B. A., & Hirabayashi, Y. (2020). *Machine -learning classification of debris -covered glaciers using a combination of Sentinel -1/ -2 (SAR/optical), Landsat 8 (thermal) and digital elevation data*. doi:10.1016/j.geomorph.2020.107365
- Batta, M. (2020). *Machine learning algorithms - a review*. doi:https://www.ijsr.net
- data.gv.at. (2018). Bundesamt für Eich - und Vermessungswesen (BEV). Digitales Höhenmodell Österreich 10 m - Lambert. Retrieved from https://www.data.gv.at
- de Lange, N. (2020). *Geoinformatik in Theorie und Praxis (4. Auflage)*. doi:10.1007/978 -3 - 662 -60709 -1
- Delalay, M., Tiwari, V., Ziegler, A. D., Gopal, V., & Passy, P. (2019). *Land -use and land -cover classification using Sentinel -2 data and machine -learning algorithms: Operational method and its implementation for a mountainous area of Nepal*. doi:10.1117/1.jrs.13.014530
- Esri. (2024). ArcGIS Pro 3.x. Environmental Systems Research Institute, Redlands, CA. Retrieved from https://www.esri.com/arcgis
- Hub, C. O. (2024). European Space Agency (ESA). Copernicus Open Access Hub - Sentinel -2 Level -2A Products. Retrieved from https://scihub.copernicus.eu
- Lucas, D. R., Fankhauser, K., & Springman, S. M. (2007). Geotechnical and geophysical characterization of alpine debris slopes. doi:https://doi.org/10.1016/j.enggeo.2007.02.002
- Maslov, K. A., Persello, C., Schellenberger, T., & Stein, A. (2025). *Globally scalable glacier mapping by deep learning matches expert delineation accuracy*. doi:10.1038/s41467 - 024 -54956 -x
- Maslov, K. A., Persello, C., Schellenberger, T., & Stein, A. (n.d.). *Globally scalable glacier mapping by deep learning matches expert delineation accuracy*. doi:10.1038/s41467 - 024 -54956 -x
- Mulders, M., Slaymaker, O., Pikha Shrestha, D., & Zinck, A. (2001). *Remote sensing and GIS applications in mountainous areas - Proceedings of the international symposium Remote sensing and GIS for monitoring soils and geomorphic processes to assist integrated development of mountainous land, Kathmandu, Nepal, 22 -29 August*.

- Pirkash, S. (2025). Machine Learning for Disease Prediction: Comparing CNN vs. Random Forest Algorithms with Ethical AI Insights. University of Management and Technology. doi:<https://doi.org/10.13140/RG.2.2.27755.66080>
- Robson, B. A., Bolch, T., MacDonell, S., Hölbling, D., Rastner, P., & Schaffer, N. (2020). *Automated detection of rock glaciers using deep learning and object -based image analysis*. doi:10.1016/j.rse.2020.112033
- Rowbotham, D., de Scally, F., & Louis, J. (2005). The identification of debris torrent basins using morphometric measures derived within a GIS. doi:<https://doi.org/10.1111/j.0435-3676.2005.00276.x>
- Sass, O. (2007). Bedrock detection and talus thickness assessment in the European Alps using geophysical methods. doi:<https://doi.org/10.1016/j.jappgeo.2006.12.003>
- Schneevoigt, N. J., Van der Linden, S., Thamm, H., & Schrott, L. (2007). *Detecting Alpine landforms from remotely sensed imagery: A pilot study in the Bavarian Alps*. doi:10.1016/j.geomorph.2006.12.034
- Sharda, S., Srivastava, M., Gusain, H. S., Sharma, N. K., Bhatia, K. S., Bajaj, M., . . . Kamel, S. (2022). *A hybrid machine learning technique for feature optimization in object -based classification of debris -covered glaciers*. doi:10.1016/j.asej.2022.101809
- Singh, S., & Sood, V. (2018). *Analytical analysis of shadow removing algorithms over land use and land cover classification*.
- Stead, D., Donati, D., Wolter, A., & Sturzenegger, M. (2019). *Application of remote sensing to the investigation of rock slopes: Experience gained and lessons learned*. doi:10.3390/ijgi8070296
- Thomas, D. J., Robson, B. A., & Racoviteanu, A. (2023). *An integrated deep learning and object -based image analysis approach for mapping debris -covered glaciers*. doi:10.3389/frsen.2023.1161530
- Whalley, W. B. (2024). *Remote sensing and landsystems in the mountain domain: FAIR data accessibility and landform identification in the Digital Earth*. doi:10.3390/rs16173348
- Yang, X., Xie, F., Liu, S., Zhu, Y., Fan, J., Zhao, H., . . . Guo, S. (2024). *Mapping debris -covered glaciers using high -resolution imagery (GF -2) and deep learning algorithms*. doi:10.3390/rs16122062
- Zhang, J., Jia, L., Menenti, M., & Hu, G. (2019). *Glacier facies mapping using a machine - learning algorithm: The Parlung Zangbo Basin case study*. doi:10.3390/rs11040452

Hilfsmittelverzeichnis

KI -/Software - Tool	Einsatz	Betroffene Teile der Arbeit	Bemerkung
OpenAI - Chat-GPT (GPT -4/5)	Sprachliche Überarbeitung wissenschaftlicher Formulierungen; Strukturierung einzelner Kapitel;	Kap. 2 -6 (sprachliche Überarbeitung); Methodik - Workflow	Inhalte wurden eigenständig geprüft, fachlich überarbeitet und an die wissenschaftlichen Anforderungen angepasst. Keine automatische Textübernahme ohne inhaltliche Kontrolle. Alle mithilfe von KI -Tools erstellten Textvorschläge wurden inhaltlich überprüft, fachlich überarbeitet und eigenständig angepasst. Die Verantwortung für Inhalt, Interpretation und wissenschaftliche Argumentation liegt vollständig bei der Autorin.
Miro (Online - Whiteboard - Tool)	Erstellung des Workflow -Diagramms	Methodik - Kapitel (Workflow - Abbildung)	Diagramm eigenständig konzipiert; Tool diente ausschließlich der grafischen Visualisierung.
AI Flowchart Generator	Strukturvorschlag für Workflow -Diagramm	Methodik - Kapitel (Workflow - Abbildung)	Generierte Struktur wurde inhaltlich geprüft und an das tatsächliche Vorgehen angepasst.
ArcGIS Pro (Esri)	Datenvorverarbeitung, Raster -Stack -Erstellung, Ableitung topographischer Variablen, Trainingsdatengenerierung, Random - Forest -Training, Rasterklassifikation, Validierung	Kap. 3 -4	Zentrales Analysewerkzeug der Arbeit.
Microsoft Excel	Berechnung und tabellarische Aufbereitung von Genauigkeitsmaßen	Kap. 4 (Validierung)	Berechnungen basieren auf Confusion Matrix aus ArcGIS.