

**Methodenentwicklung zur fernerkundlichen Klassifizierung von
Gründächern anhand hochaufgelöster RGBI-Orthofotos**
Untersuchungsgebiet Stadtgebiet Innsbruck

Elena Luisa WIEDMANN, Matrikelnummer: 12237945

Innsbruck, 12.04.2026

Masterarbeit

eingereicht an der Universität Innsbruck, Fakultät für Geo- und Atmosphärenwissenschaften
zur Erlangung des akademischen Grades

Master of Science (M. Sc.)

Studiengang Geografie: Globaler Wandel – regionale Nachhaltigkeit

Erstbetreuer:

Ing. Mag. Martin Ladner, PhD

Institut für Geografie

Fakultät für Geo- und Atmosphärenwissenschaften

Zweitbetreuer:

Johannes Rüdissler, PhD

Institut für Ökologie

Fakultät für Biologie

Danksagung

Mit dieser Arbeit endet ein bedeutender Abschnitt meiner akademischen Ausbildung und ich möchte mich an dieser Stelle bei all denjenigen bedanken, die mich währenddessen unterstützt und begleitet haben.

Mein besonderer Dank gilt Martin Ladner, Johannes Rüdiger und Friederike Barkmann für die fachliche Unterstützung, die wertvollen Anregungen und das stets konstruktive Feedback, wodurch diese Arbeit möglich gemacht wurde.

Auch bei meinen FreundInnen und KommilitonInnen möchte ich mich bedanken, die mich in herausfordernden Momenten motiviert und unterstützt haben.

Nicht zuletzt danke ich meiner Familie für ihre Geduld, ihr Verständnis und ihre Unterstützung, die mir den nötigen Rückhalt gegeben haben, um diese Arbeit erfolgreich abzuschließen.

Vielen Dank an alle, die auf unterschiedliche Weise zu diesem Ergebnis beigetragen haben.

Innsbruck, 12.04.2026

Zusammenfassung

Thema der Masterarbeit ist die Methodenentwicklung für die Klassifikation von Gründächern anhand hochaufgelöster RGBI-Orthofotos anhand eines logistischen Regressionsmodells. Untersuchungsgebiet ist das Stadtgebiet Innsbruck.

Gründächer gewinnen zunehmend an Bedeutung in der urbanen Planung, da sie zur Klimawandelfolgenanpassung, zum Biodiversitätserhalt und zur nachhaltigen Flächennutzung beitragen. Um dem Bedarf einer automatisierten Gründächerhebung nachzukommen, zielt die Masterarbeit auf eine fernerkundliche Methodenentwicklung zur Klassifikation von Gründächern auf Basis hochaufgelöster RGBI-Orthofotos innerhalb amtlicher Gebäudeumringe. Kern der Methodik ist die statistische Verarbeitung spektraler Objektwerte mit Hilfe einer logistische Regressionsanalyse. Die Dateneingabe kombiniert sich aus Normalized Difference Vegetations Index (NDVI) und den einzelnen Bändern RGBI. Für die Aufbereitung der Trainingsdatensätze werden mit Hilfe des NDVI und der Luminosity vegetationsstypische Flächen auf Pixelebene identifiziert. Um die klassifizierten Gründächer anhand ihrer Vitalität und Grünflächengröße bewerten zu können, werden die absoluten und relativen Grünflächenanteile pro klassifiziertem Gründach näherungsweise ermittelt. Es zeigt sich, dass die Methodik sehr gut für die Klassifikation von homogenen Flächen geeignet ist, die Precision jedoch bei der Anwendung auf heterogene Daten stark sinkt. Der resultierende Workflow stellt eine leicht zugängliche Methodik für Anwendungen im Bereich der urbanen Fernerkundung dar.

Abstract

The topic of this master thesis is the development of a method for classifying green roofs using high-resolution RGBI orthophotos and a logistic regression model. The study area is the city of Innsbruck.

Green roofs are gaining increasing importance in urban planning, as they contribute to climate change adaptation, biodiversity conservation, and sustainable land use. To meet the need for automated green roof surveys, this master thesis aims to develop a remote sensing method for classifying green roofs based on high-resolution RGBI orthophotos within official building outlines. The core of the methodology is the statistical processing of spectral object values using logistic regression analysis. Data input consists of the Normalized Difference Vegetation Index (NDVI) and the individual spectral bands. For the preparation of the training datasets, vegetation-typical areas are identified at the pixel level using the NDVI and luminosity. To assess the classified green roofs based on their green area size, the absolute and relative green area proportions per classified green roof are approximated. The methodology proves to be very well suited for classifying homogeneous surfaces, but its precision decreases significantly when applied to heterogeneous data. The resulting workflow represents an easily accessible methodology for urban remote sensing applications.

Inhaltsverzeichnis

Abbildungsverzeichnis	iv
Tabellenverzeichnis	vi
Abkürzungsverzeichnis	vii
1 Einleitung	1
2 Forschungsstand methodischer Ansätze zur fernerkundlichen Erfassung von Gründächern	7
3 Die Stadt Innsbruck als Untersuchungsgebiet	13
4 Grundlagendaten und Koordinatensystem	14
5 Methodik.....	16
5.1 Verschneidung und Bufferung	18
5.2 Pixelbasierte Klassifizierung zur Ermittlung vegetationstypischer Pixel pro Dachfläche	19
5.2.1 Berechnung des NDVI-Rasters	19
5.2.2 Berechnung des Luminosity-Rasters.....	20
5.2.3 Schwellenwertermittlung zur Abgrenzung vegetationstypischer Pixel.....	21
5.2.4 Maskierung von nicht-vegetationstypischen Pixeln	24
5.2.5 Validierung der vegetationstypischen Pixelklassifikation	25
5.3 Erstellung der Modelleingabe	27
5.3.1 Erstellung des Modelleingabedatensatzes der Nicht-Gründächer (Label 0)	27
5.3.2 Erstellung des Modelleingabedatensatzes der Gründächer (Label 1)	27
5.3.3 Extraktion der Statistiken	28
5.4 Logistische Regressionanalyse.....	28
5.4.1 Univariate logistische Regression anhand des NDVI	28
5.4.2 Multivariate logistische Regression anhand des NDVI und der Bänder RGBI.....	31
5.5 Pixelbasierte Ermittlung des Grünflächenanteils auf klassifizierten Gründächern	32
6 Ergebnisse	33
6.1 Ergebnisse der univariaten logistische Regression anhand des NDVI	36
6.2 Ergebnisse der multivariaten logistischen Regression anhand NDVI und der Bänder RGBI	41
6.3 Validierung der Klassifikation aller Dachflächen.....	48
6.4 Ergebnisse des pixelbasierten Grünflächenanteils auf klassifizierten Gründächern	50
7 Diskussion.....	53
8 Fazit und Ausblick	56
Literatur.....	58
Anhang 1: Modellzusammenfassung der univariaten logistischen Regression.....	64
Anhang 2: Modellzusammenfassung der multivariaten logistischen Regression.....	65
Anhang 3: RStudio Skript der univariaten logistischen Regressionsanalyse	66
Anhang 4: RStudio Skript der multivariaten logistischen Regressionsanalyse	70

Abbildungsverzeichnis

Abbildung 1: Signaturkurven dreier Oberflächen von Landsat-TM-Kanälen, Kanal 1 entspricht dem blauen Band, Kanal 2 dem grünen und Kanal 3 dem roten Band, Kanal 4 entspricht dem nah-infrarotem Band (Lange 2020, S. 483).....	7
Abbildung 2: Abgegrenztes Untersuchungsgebiet innerhalb des Stadtgebiets Innsbrucks, eigene Darstellung.	13
Abbildung 3: Vereinfachtes Fließschema des objektbasierten Methodenteils, eigene Darstellung.	18
Abbildung 4: Ausschnittsweise Visualisierung des NDVI-Rasters im Untersuchungsgebiet, eigene Darstellung.	20
Abbildung 5: Ausschnittsweise Visualisierung des Luminosity-Rasters im Untersuchungsgebiet, eigene Darstellung.	21
Abbildung 6: Histogramm der Pixelverteilung der Luminosity für alle Dächer im Untersuchungsgebiet; eigene Darstellung.....	22
Abbildung 7: Histogramm der Pixelverteilung der Luminosity für die kartierten Gründächer im Untersuchungsgebiet; eigene Darstellung	22
Abbildung 8: Boxplot der Median-Verteilung der Luminosity pro Gründach, eigene Darstellung.....	22
Abbildung 9: Histogramm der Pixelverteilung des NDVI für alle Dächer im Untersuchungsgebiet; eigene Darstellung.....	23
Abbildung 10: Histogramm der Pixelverteilung des NDVI für die kartierten Grünflächen im Untersuchungsgebiet; eigene Darstellung.	23
Abbildung 11: Boxplot der NDVI-Mediane pro kartiertem Gründach, eigene Darstellung.	24
Abbildung 12: Beispiel für die Abgrenzung vegetationstypischer Pixel (pink) auf einer heterogenen Dachfläche, eigene Darstellung.....	25
Abbildung 13: Confusion Matrix zur Validierung der vegetationstypischen Pixelklassifizierung, eigene Darstellung.	26
Abbildung 14: Vereinfachtes Fließschema der Verarbeitungsschritte im R-Skript der univariaten logistischen Regressionsanalyse, eigene Darstellung.....	Fehler! Textmarke nicht definiert.
Abbildung 15: Vereinfachtes Fließschema der pixelbasierten Methodik zur näherungsweisen Ermittlung des prozentualen Grünflächenanteils, eigene Darstellung.	33
Abbildung 16: Screenshot der Modellzusammenfassung des univariaten logistischen Regressionsmodells, eigene Darstellung.....	36

Abbildung 17: ROC-Kurve des univariaten logistischen Modells anhand des NDVI-Medians pro Dachfläche, eigene Darstellung.....	37
Abbildung 18: Regressionskurve der univariaten logistischen Regression anhand des NDVI-Medians pro Dachfläche mit eingezeichnetem Youden-Schwellenwert, eigene Darstellung.....	38
Abbildung 19: Confusion Matrix der univariaten Regressionsanalyse anhand des NDVI-Medians pro Dachfläche; jeweils anhand eines Schwellenwerts von 0,6 und dem ermittelten Youden-Schwellenwert; ergänzt sind die Prozentangaben pro Klasse relativ zur tatsächlichen Klasse im Ground Truth; eigene Darstellung.....	38
Abbildung 20: Beispielhafter Ausschnitt der klassifizierten Gründächer anhand der univariaten logistischen Regression und dem Youden-Schwellenwert von 0,567; zusätzlich sind die ursprünglichen Gründachkartierungen (rot) eingezeichnet, eigene Darstellung.....	40
Abbildung 21: Screenshot der Modellzusammenfassung des multivariaten logistischen Regressionsmodells, eigene Darstellung.....	41
Abbildung 22: ROC-Kurve des multivariaten logistischen Modells, eigene Darstellung.	42
Abbildung 23: Regressionskurve des multivariaten Regressionsmodells mit eingezeichnetem Youden-Schwellenwert bei 0,476 und dem zugehörigen Modell-Score von -0,1, eigene Darstellung. ...	43
Abbildung 24: Partielle Regressionskurven der einzelnen Eingabeparameter der Bänder RGBI und des NDVI anhand der normalisierten Medianwerte, eigene Darstellung.....	44
Abbildung 25: Confusion Matrix der multivariaten Regressionsanalyse anhand der RGBI- und NDVI-Mediane pro Dachfläche; jeweils anhand eines Schwellenwerts von 0,6 und des ermittelten Youden-Schwellenwerts von 0,476; ergänzt sind die Prozentangaben relativ zur tatsächlichen Klasse, eigene Darstellung.....	44
Abbildung 26: Beispielhafter Ausschnitt der klassifizierten Gründächer anhand einer multivariaten logistischen Regression und dem Youden-Schwellenwert von 0,476; zusätzlich sind die ursprünglichen Gründachkartierungen eingezeichnet, eigene Darstellung.....	46
Abbildung 27: Confusion Matrix zur Validierung der multivariaten Klassifikation und Youden-Index aller Dachflächen im Untersuchungsgebiet, eigene Darstellung.	49
Abbildung 28: Klassifizierte Gründächer anhand der multivariaten logistischen Regression mit einem Youden-Index von 0,476; klassifiziert anhand ihres Grünflächenanteils in Prozent; zusätzlich blau eingezeichnet sind die ursprünglichen Gründachkartierungen zum Abgleich, eigene Darstellung.	51
Abbildung 29: Klassifizierte Gründächer anhand einer multivariaten logistischen Regression mit einem Entscheidungsschwellenwert von 0,476; klassifiziert anhand ihres Grünflächenanteils in Prozent, überlagert mit der vegetationstypischen Pixel-Maske aus NDVI und Luminosity, eigene Darstellung.	52

Tabellenverzeichnis

Tabelle 1: Zusammenfassung der Grundlagensätze.....	14
Tabelle 2: Zusammenfassung der methodischen Schritte anhand ihrer aufeinander aufbauenden Reihenfolge	16
Tabelle 3: Zusammenfassung der Evaluationsmetriken des univariaten logistischen Regressionsmodells.....	39
Tabelle 4: Zusammenfassung der Evaluationsmetriken des multivariaten logistischen Regressionsmodells.....	45
Tabelle 5: Gegenüberstellung der Evaluationsmetriken von univariatem und multivariatem Modelllauf.	47
Tabelle 6: Absolute Dachflächenzahl nach prozentualem Grünflächenanteil basierend auf der multivariaten Klassifikation anhand Youden-Schwellenwert.....	50

Abkürzungsverzeichnis

AUC	Area Under Curve
DL	Deep Learning
DLM	Digitales Landschaftsmodell
DOM	Digitales Oberflächenmodell
ETRS	Europäisches Terrestrisches Referenzsystem
GLR	Generalised Linear Regression
glm	General Linear Modell
IQR	Interquartile Range
LR	Logistische Regression
MGI	Militärgeografisches Institut
ML	Machine Learning
nDOM	Normalisiertes Digitales Oberflächenmodell
NDVI	Normalized Difference Vegetation Index
NIR	Nah-Infrarot
NPV	Negative Predictive Value
NTv2	National Transformation Version 2
RGBI	Orthofotos mit den Kanälen Rot, Grün, Blau und Nah-Infrarot
ROC	Receiver Operating Characteristic
SAR	Synthetic Aperture Radar
SNDVI	Supervised NDVI Composite Thresholding
VCI	Vegetation Condition Index

1 Einleitung

Im Jahr 2026 lebt mehr als die Hälfte der Weltbevölkerung in Städten (Cohen 2006). Hohe bauliche Dichte, wenige Grünflächen und ein hoher Anteil an versiegelten Flächen machen Städte zu extremen Lebensräumen, in denen Umweltstressoren intensiver auftreten als im Umland (Li et al. 2024). Im Zuge des Klimawandels nehmen auch in gemäßigten Breiten Hitzewellen und Starkregenereignisse zu, wodurch Städte zunehmend vor neue Herausforderungen in der Klimaanpassung gestellt werden (Seneviratne et al. 2021; Kabisch et al. 2024). Ein zentrales Phänomen in diesem Zusammenhang ist der urbane Hitzeinseleffekt, der die deutlich höheren Temperaturen innerhalb von Städten im Vergleich zum Umland beschreibt (Mohajerani et al. 2017). Ausmaß und Intensität dieses Effekts werden maßgeblich durch die Gebäudegeometrie und die thermischen Eigenschaften der Bausubstanz beeinflusst und sind folglich Stellschrauben zur Resilienzstärkung und Klimawandelfolgenanpassung von Städten (Mohajerani et al. 2017; Kabisch et al. 2024).

Der gezielte Einsatz von Vegetation im verdichteten Stadtraum stellt für die Reduktion thermischer Belastungen und die Schaffung von Retentionsräumen ein wirksames Instrument dar (Susca et al. 2011; Sánchez-Cordero et al. 2025). Neben Grünflächen am Boden kommen insbesondere Gründächer als multifunktionale Maßnahme zum Einsatz, da sie bereits versiegelte Fläche nutzbar machen. Gründächer tragen sowohl zur Temperaturregulation als auch zur Verzögerung des Oberflächenabflusses bei, sie dienen als Erholungsort für AnwohnerInnen und bieten Habitate für die urbane Flora und Fauna (Cristiano et al. 2020; Barriuso & Urbano 2021; Kim et al. 2025). Studien zeigen, dass selbst extensive, also nicht aktiv gepflegte und bewässerte Begrünungen, insbesondere während nächtlicher Hitzephasen eine messbare Kühlwirkung entfalten können (Solcerova et al. 2016). Als ökologische Trittsteine bzw. Mosaikhabitate leisten sie einen Beitrag zum Erhalt und zur Förderung urbaner Biodiversität, indem sie strukturreiche, vegetationsbedeckte Lebensräume in ansonsten stark versiegelten Stadtlandschaften schaffen (Oberndorfer et al. 2007). So können isolierte Populationen vernetzt, Nahrungs- und Nistmöglichkeiten bereitgestellt und der genetische Austausch sowie die Artenvielfalt im urbanen Raum gefördert werden (Christiano et al. 2020; Lundholm 2015; Oberndorfer et al. 2007). Williams et al. (2019) und Zhuo et al. (2025) belegen darüber hinaus psychologische Vorteile von begrünten Dächern in Städten, darunter eine verbesserte Konzentration. Die AutorInnen zeigen, dass im Vergleich zu klassischen Betonflächen begrünte Dächer tendenziell als angenehmer und psychologisch förderlicher wahrgenommen werden.

Nach Nurmi et al. (2016) werden Gründächer als Dächer definiert, welche teilweise oder vollständig begrünt sind. Louis-Lucas et al. (2021) definieren ihren Untersuchungsgegenstand als „Dächern, die ganz oder teilweise mit einer Schicht aus angepflanzter Vegetation auf einem Substrat bedeckt sind“. Bei dieser Definition wird auf eine beabsichtigte bzw. bewusste Begrünung in Abgrenzung zu

Spontanbegrünung verwiesen. Auch für die behandelten Gründächer dieser Masterarbeit soll die Definition von Louis-Lucas et al. (2021) gelten. Je nach Aufbau, Bepflanzung und Pflegeaufwand lassen sich grundsätzlich intensive und extensive Dachbegrünungen unterscheiden. Intensive Gründächer weisen eine aufwändige Bepflanzung mit Stauden, Sträuchern oder kleineren Gehölzen auf und erfordern eine regelmäßige Pflege sowie eine gezielte Wasser- und Nährstoffversorgung. Extensive Gründächer hingegen sind so konzipiert, dass sie sich weitgehend selbst erhalten und nur einen geringen Pflegeaufwand benötigen. Sie werden vorwiegend mit Kräutern, Gräsern, Moosen und Sedumarten bepflanzt und kommen ohne zusätzliche Bewässerung aus (Razzaghmanesh & Beecham 2014).

Um die angeführten positiven Wirkungen von Gründächern planerisch nutzbar zu machen, ist eine systematische und flächendeckende Kartierung begrünter Dachflächen unerlässlich. Eine solche Kartierung bildet die Datengrundlage für Regenwassermanagement, Stadtklimaanalyse und Biodiversitätsförderung. Ohne eine aktuelle, systematische Übersicht über vorhandene Gründächer bleibt ihr Beitrag zu stadtökologischen Leistungen weitgehend unsichtbar und kann weder gezielt gefördert noch wirksam gesteuert werden. Die Gründachkartierung stellt somit eine zentrale Voraussetzung für eine evidenzbasierte, nachhaltige Stadtentwicklung dar. Dobrinić et al. (2025) betonen in diesem Zusammenhang die wachsende Bedeutung präziser und zeitnaher Kartierungen grüner Infrastruktur im Zeitalter von Big Data.

So entwickelte die Stadt Berlin bereits in den 1990er Jahren den sogenannten Biotopflächenfaktor, der den Anteil eines Grundstücks beschreibt, welcher als Vegetationsfläche oder zur Erfüllung ökologischer Funktionen dient (Belz 2010; Pauligk 2022). Darauf aufbauend führt die Stadt Berlin ein regelmäßiges Gründach-Monitoring durch, um den bestehenden Bestand in einem Gründachkataster zu erfassen und darauf aufbauend gezielte Strategien zur Förderung von Dachbegrünungen entwickeln zu können (Coenradie et al. 2016; Senatsverwaltung für Stadtentwicklung, Bauen und Wohnen Berlin 2020; Pauligk 2022). Andere europäische Metropolen wie Paris verfolgen ähnliche Ansätze und untersuchen gezielt die von Gründächern bereitgestellten Ökosystemleistungen (Awada 2022).

Bisher fehlt es in Österreich an flächendeckenden Daten zur Lokalität von Gründächern. Zwar bietet die „Green Transition Information Factory“ (GTIF) als Portal der European Space Agency (ESA) eine interaktive Plattform für Klima-, Energie- und Umweltindikatoren auch mit einem Layer zur Gründachvisualisierung, allerdings sind die Daten nicht frei verfügbar und müssen kostenpflichtig bezogen werden (Green Transition Information Factory 2022). Die Abteilung Raumplanung und Baurecht des Landes Vorarlberg stellt im Onlinetool „Raumbeobachtung“ eine Reihe von raumplanungsbezogenen Datensätzen zur Verfügung, darunter auch einen Gründachdatensatz. Dabei

handelt es sich um eine visuelle Kartierung anhand von Orthofotos (Amt der Vorarlberger Landesregierung 2023). Aufgrund der manuellen Datenerhebung ist die Erweiterung dieses Datensatzes auf andere Bundesländer allerdings mit erheblichem Arbeitsaufwand verbunden. 2010 hat die Stadt Wien eine Grünraumanalyse bezüglich der Wiener Dachbegrünung veröffentlicht (Hoffert & Lumasegger 2010). Die Methode dieser automatisierten Gründachkartierung besteht aus einer einfachen Klassifizierung anhand von NDVI-Schwellenwerten. Diese Gründachbestandsaufnahme wurde bislang nicht als regelmäßiges Monitoring fortgeführt.

Um dem Bedarf einer zugänglichen und übertragbaren Gründacherhebung nachzukommen, ist die Erarbeitung einer niederschweligen Methodik zur Erfassung von Gründächern Ziel dieser Masterarbeit. Als grundlegende Bilddaten stehen hochaufgelöste RGBI-Orthofotos sowie Vektordaten der Gebäudeumringe zu Verfügung.

Für die fernerkundliche Erfassung von Gründächern existiert keine einheitliche oder standardisierte Methodik. Vielmehr haben sich sowohl die methodischen Ansätze als auch die Datengrundlagen im Laufe der Jahre kontinuierlich weiterentwickelt. Zu Beginn der Gründachkartierung stand die manuelle Datenerhebung im Vordergrund. Dieses Vorgehen ist jedoch mit einem hohen Zeit-, Personal- und Arbeitsaufwand verbunden und muss für jedes Untersuchungsgebiet erneut durchgeführt werden (Belz 2010). Mit der Weiterentwicklung fernerkundlicher Methoden verlagerte sich der Fokus daher zunehmend auf automatisierte und teilautomatisierte Verfahren. Ausgehend von einfachen Schwellenwertverfahren (Hoffert & Lumasegger 2010; Santos et al. 2016) etablierten sich mechanistische bzw. statistische Klassifikationsansätze, wie beispielsweise Clustering, logistische Regressionsmodelle, Entscheidungsbäume oder Support Vector Machines (Griffith & Hay 2018; Degerickx et al. 2020; Lange 2020; Khalil et al. 2024). Dabei wird zwischen unüberwachten und überwachten Verfahren unterschieden, wobei letztere auf zuvor definierte Klassenmerkmale anhand von Trainingsdaten zurückgreifen (Lange 2020).

Anders als Klassifikationsverfahren anhand von festen Schwellenwerten passen sich statistische Verfahren individuell und flexibel an einen speziellen Datensatz an. Im Vergleich zu Deep Learning-Verfahren sind mechanistische Ansätze leichter aufzusetzen und in ihren einzelnen Klassifikationsschritten vollständig nachvollziehbar, da die Entscheidungsregeln explizit formuliert sind (Dreiseitl & Ohno-Machado 2002). Durch die individuelle Anpassung auf einen konkreten Datensatz ist die Übertragbarkeit allerdings nur eingeschränkt gewährleistet. Bei der Modellübertragung auf Bilddaten anderer Untersuchungsgebiete muss unbedingt auf die vergleichbaren Aufnahmebedingungen geachtet werden, und das Klassifikationsmodell muss ggf. neu kalibriert werden (Dobrinić et al. 2025). Zudem setzen statistische Klassifikationsmethoden häufig

Modellannahmen (z. B. Linearität oder Normalverteilung der Variablen) über die Zusammenhänge der Parameter voraus, die für eine gute Modellleistung erfüllt sein müssen (Lange 2020).

Ergänzend dazu wurden in den letzten Jahren zunehmend Deep Learnig-Ansätze integriert (Vgl. Simpson et al. 2023; Falcao et al. 2025; Kim et al. 2025; Li et al. 2025; Ma et al. 2025). Sie bieten den Vorteil einer automatisierten Mustererkennung und funktionieren besonders gut bei komplexen, nicht-linearen Zusammenhängen (Dreiseitl & Ohno-Machado 2002). Dem gegenüber steht jedoch ein hoher Bedarf an Trainingsdaten, eine längere Trainingszeit, ein hoher Rechenaufwand sowie eine geringe Transparenz der Modellstruktur (Lang 2020). Dreiseitl und Ohno-Machado (2002) betonen, dass „Artificial Neural Networks“ in vielen publizierten Studien keine signifikant bessere Performance als z. B. logistische Regressionsanalysen zeigen, insbesondere bei begrenzten Trainingsdaten.

Für die überwachte Vorhersage zweier Klassen, wie im Falle der Gründachklassifizierung, stellt die logistische Regressionsanalyse eine geeignete Methodik dar, da sie speziell für binäre Zielvariablen konzipiert ist, Wahrscheinlichkeiten für Klassenzugehörigkeiten modelliert und eine gute Interpretierbarkeit der Einflussgrößen bei gleichzeitig geringer Modellkomplexität bietet. Zudem stellt sie geringe Anforderungen an die Datenstruktur und ermöglicht eine stabile Schätzung der Effekte einzelner Prädiktoren (Dreiseitl & Ohno-Machado 2002; Menard 2002). Als Grundlage dieser Arbeit dient eine bestehende Kartierung von Gründächern, die als Trainingsdaten genutzt werden soll.

Zur Differenzierung zwischen Vegetation und anderen Oberflächen im Klassifikationsverfahren wird das unterschiedliche Reflexionsverhalten der physikalisch verschiedenen Oberflächen genutzt, um materialspezifische spektrale Signaturen zu identifizieren (Lange 2020; Ansel et al. 2025). Diese Signaturen können sowohl auf Objekt- bzw. Dachflächenebene als auch auf Pixelebene analysiert werden. Eine pixelbasierte Analyse ist insbesondere dann sinnvoll, wenn heterogene Strukturen innerhalb eines Objekts differenziert erfasst werden sollen. Allerdings bleibt hierbei der räumliche Zusammenhang zwischen benachbarten Pixeln unberücksichtigt (Lange 2020). Sollen hingegen funktionale Einheiten abgebildet werden, bietet sich ein objektbasierter Ansatz auf Grundlage von Gebäudeumringen an. Durch die Aggregation der Pixelwerte auf Dachflächenebene, beispielsweise mittels Medianbildung, können Ausreißer reduziert und die Stabilität der Klassifikation erhöht werden.

Für die spezifische Erfassung von Vegetation stehen verschiedene Vegetationsindizes zur Verfügung. Der NDVI ist einer der meistgenutzten Vegetationsindizes und ermöglicht die Abgrenzung von vitaler Vegetation zu anderen Oberflächenmaterialien (Kriegler et al. 1969; Jiang et al. 2006; Huang et al. 2021). In dieser Arbeit soll untersucht werden, inwieweit der NDVI als alleiniger Prädiktor bereits eine zuverlässige Klassifizierung von Gründächern erlaubt oder ob die zusätzliche Einbeziehung der

einzelnen Spektralbänder (Rot, Grün, Blau und Nahinfrarot) die Vorhersagegenauigkeit verbessern kann.

In Ausnahmefällen werden dunkle, verschattete Bereiche anhand des NDVI als Grünflächen interpretiert (Hoffert & Lumasegger 2010). Daher kann zusätzlich ein Maß für die Helligkeit, hier Luminosity genannt, hinzugezogen werden, um Fehler in verschatteten Bereichen zu vermeiden (Marmy et al. 2025).

Für die Modellierung mittels logistischer Regression ist eine ausgewogene Klassenverteilung in den Trainingsdaten von großer Bedeutung. Eine starke Klassenungleichverteilung führt dazu, dass das Modell vorwiegend anhand der Mehrheitsklasse lernt und die Minderheitsklasse entsprechend schlechter vorhersagt. In der Realität treten Gründächer deutlich seltener auf als Dächer ohne Begrünung, wodurch in den Rohdaten ein ausgeprägtes Klassenungleichgewicht besteht. Um zu vermeiden, dass die seltene Klasse der Gründächer im Modelltraining unterrepräsentiert ist, muss ein geeigneter Ansatz gefunden werden, dieses Ungleichgewicht in den Eingabedaten auszugleichen (Maalouf & Siddiqi 2014).

Eine weitere Herausforderung ergibt sich aus der heterogenen Beschaffenheit der Dachflächen, welche als einheitliches Objekt interpretiert werden sollen. In der Realität sind allerdings meist nur Teilflächen innerhalb der Gebäudeumringe begrünt oder die Gründachfläche ist durchsetzt mit Dachaufbauten, Photovoltaikanlagen, Fenstern oder anderen Strukturen. Die Einordnung als ein Gründach ist daher nicht immer eindeutig. Aufbauend auf den Ergebnissen der logistischen Regressionanalyse ist es zudem von Interesse, den tatsächlichen Grünflächenanteil pro klassifiziertem Gründach näherungsweise zu bestimmen, um Aussagen zur Qualität im Sinne der Grünflächengröße treffen zu können.

Output des logistischen Regressionsmodells ist eine Wahrscheinlichkeitsangabe pro Dach für die Zugehörigkeit zur Zielklasse („Gründach“). Für die eigentliche Klassifikation muss diese anschließend anhand eines Entscheidungsschwellenwertes bzw. „Cut-offs“ in diskrete Klassen überführt werden. Die Wahl dieses Entscheidungsschwellenwertes ist vom Ziel der Klassifizierung abhängig. Sollen keine Gründächer übersehen werden, kann der „Cut-off“ so niedrig angesetzt werden, dass zwar alle Gründächer als solche erkannt werden, aber auch viele falsch-positive Nicht-Gründächer in der Klassifikation enthalten sind. Ein sehr hoher Schwellenwert reduziert hingegen falsch-positive Ergebnisse, führt jedoch dazu, dass manche tatsächlich vorhandene Gründächer ausgeschlossen werden. Um den optimal ausgewogenen Entscheidungsschwellenwert zu finden, muss einen Kompromiss aus Sensitivität (Richtig-Positiv-Rate) und Spezifität (Richtig-Negativ-Rate) eingegangen werden. Ein Schwellenwert, welcher diesen Kompromiss wiedergibt, kann mithilfe einer Receiver-Operating-Characteristics (ROC) -Kurve bestimmt werden, indem Sensitivität und Spezifität für

verschiedene Cut-off-Werte analysiert werden. Der Youden-Index identifiziert dabei den Punkt, an dem die Summe aus Sensitivität und Spezifität maximiert wird (Fluss et al. 2005; Perkins & Schisterman 2005).

Im Fokus der Arbeit stehen daher folgende Fragestellungen:

1. Wie zuverlässig lassen sich Gründächer objektbasiert auf Grundlage von RGBI-Orthofotos identifizieren und mit Hilfe eines logistischen Regressionsmodells klassifizieren?
2. Anhand welcher NDVI- und Luminosity-Schwellenwerte lassen sich vegetationstypische Pixel innerhalb von Dachflächen abgrenzen, spezifisch für das Untersuchungsgebiet?
3. Wie kann das starke Klassenungleichgewicht zwischen seltenen Gründächern und zahlreichen Nicht-Gründächern relativiert werden, sodass die Gründach-Klasse im Modelltraining angemessen berücksichtigt wird?
4. Welcher Entscheidungsschwellenwert zur Klassentrennung von Gründächern und Nicht-Gründächern bietet den besten Kompromiss zwischen Sensitivität und Spezifität?
5. Wie groß ist der begrünte Flächenanteil pro klassifiziertem Gründach näherungsweise?

Diese Forschungsfragen sind Kernaspekte in der Herleitung und Bewertung der Methodik zur Gründachkartierung. Das Ergebnis der Gründachklassifikation soll eine Datengrundlage für weiterführende Monitoringprojekte und Fragestellungen bieten und als Entscheidungsgrundlage für die Auswahl geeigneter Versuchsflächen dienen. Durch die Anwendung der Methodik auf neue Untersuchungsgebiete können zudem weitere Datengrundlagen erschlossen werden. Darüber hinaus lassen sich aus dem methodischen Workflow Empfehlungen für zukünftige Kartierungsprojekte ableiten.

2 Forschungsstand methodischer Ansätze zur fernerkundlichen Erfassung von Gründächern

Um die Methodik dieser Arbeit in den Forschungskontext einzubetten, soll an dieser Stelle noch einmal auf die zugrundeliegenden Parameter und Zusammenhänge eingegangen und anhand bestehender Arbeiten die Entwicklung mechanistischer Vorgehensweisen zur Gründachkartierung dargelegt werden.

Der Normalized Difference Vegetation Index (NDVI) ist einer der meistgenutzten Vegetationsindizes in der Fernerkundung und basiert auf der Abgrenzung der spektralen Vegetationssignatur in den Kanälen des sichtbaren roten und des nahinfraroten Lichts zu anderen Materialien (Kriegler et al. 1969; Jiang et al. 2006; Lange 2020; Huang et al. 2021; Balata et al. 2022). Gesunde Pflanzen mit einem hohen Chlorophyllgehalt absorbieren einen Großteil des roten Lichts und reflektieren nah-infrarotes Licht (NIR). Durch dieses Verhältnis entsteht zwischen dem roten und dem nah-infraroten Spektralbereich der sogenannte „Red Edge“-Bereich (ca. 690–750 nm), welcher den Übergang zwischen starker Absorption von rotem Licht und starker Reflexion von nah-infrarotem Licht durch Vegetation markiert. Aufgrund dieses schnellen Anstiegs des Reflexionsgrades kann gesunde Vegetation von anderen Oberflächen abgegrenzt werden (Delegido 2013). Der Verlauf der Reflexionsgrade ist in Abbildung 1 exemplarisch für vitale Vegetation, Wasser und Boden dargestellt.

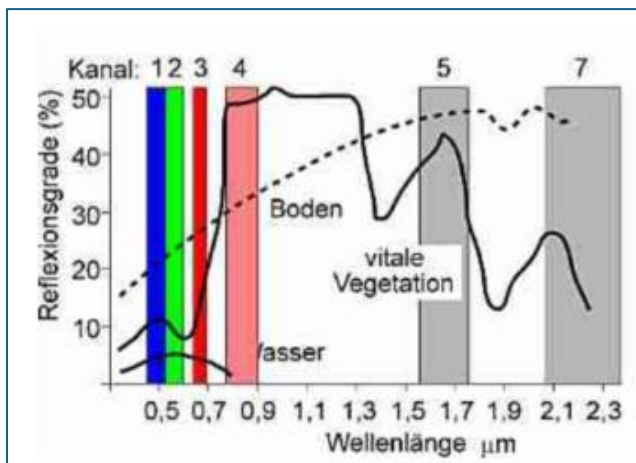


Abbildung 1: Signaturkurven dreier Oberflächen von Landsat-TM-Kanälen, Kanal 1 entspricht dem blauen Band, Kanal 2 dem grünen und Kanal 3 dem roten Band, Kanal 4 entspricht dem nah-infraroten Band (Lange 2020, S. 483).

NDVI-Werte liegen zwischen -1 und 1. Die Formel für die Berechnung lautet wie folgt (Ansel et al. 2015; Lange 2020):

$$NDVI = \frac{NIR - Rot}{NIR + Rot}$$

„Rot“ steht dabei für das Farbband des roten Lichtspektrums und „NIR“ für das nah-infrarote Band.

Eine eindeutige Interpretation von NDVI-Werten ist jedoch schwierig, da diese stets im Kontext der jeweiligen Bildaufnahmebedingungen erfolgen muss (Lange 2020). Abhängig von räumlicher Auflösung, Aufnahmezeitpunkt, Sensortyp, Lichtverhältnissen, Qualitätskontrollmaßnahmen, verwendeten Zusammensetzungsalgorithmen sowie angewandten Korrekturen können die resultierenden NDVI-Wertebereiche variieren (Jiang et al. 2006; Huang et al. 2021; Zeng et al. 2022). Auch die häufig getroffene Annahme, dass negative NDVI-Werte keine vitale Vegetation repräsentieren, kann sich im Einzelfall als unzutreffend erweisen.

Schwellenwerte lassen sich daher nicht direkt übertragen und müssen jeweils anhand der spezifischen statistischen Verteilung ermittelt werden. So nutzen Ansel et al. (2015) beispielsweise einen Wertebereich von 0,08 bis 0,3 für typische Dachvegetation. Werte kleiner als 0,08 werden als vegetationsfrei eingestuft, während Werte über 0,3 ein zu starkes Vegetationssignal aufweisen, welches eher für Bäume charakteristisch ist. Im Gegensatz dazu legen Massy et al. (2011) und Louis-Lucas et al. (2021) in ihren Analysen von Dachbegrünung eine untere NDVI-Schwelle im negativen Bereich (-0,08) fest. Dies begründen sie damit, dass typische Arten wie Fetthenne und Mauerpfeffer häufig nur ein geringes Vegetationssignal aufweisen. Auf diese Weise soll vermieden werden, dass tatsächlich vorhandene Gründächer „übersehen“ werden. Santos et al. (2016) wählen hingegen einen NDVI-Schwellenwert von 0,03 für die Ermittlung des Gründflächenpotenzials in Lissabon. Diese Beispiele verdeutlichen, dass NDVI-Wertebereiche stark von den jeweiligen Bilddaten und Untersuchungsbedingungen abhängen.

Massy et al. (2011), Louis-Lucas et al. (2021) und Marmy et al. (2025) ziehen für die Unterscheidung von Oberflächen zusätzlich zum NDVI ebenfalls die „overall brightness“, „Luminosity“ oder Helligkeit hinzu, welche aus einer einfachen Addition der Farbbänder Rot, Grün und Blau berechnet wird. Die Summierung der RGB-Bänder zu einem Luminosity-Raster dient der Ableitung eines Maßes für die Gesamtreflexion im sichtbaren Spektralbereich und ermöglicht damit eine Einstufung der Helligkeitseigenschaften von Oberflächen. Gerade tief verschattete Bildbereiche weisen öfter vegetationsstypische NDVI-Werte auf. Die Luminosity kann hierbei als weiteres Merkmal die richtige Differenzierung unterschiedlicher Materialien und Vegetation unterstützen. Damit zeigt sich bereits auf Ebene einfacher spektraler Indizes, dass die Kombination mehrerer Merkmale notwendig ist, um die Trennschärfe gegenüber komplexen Oberflächen zu erhöhen.

Aktuelle Studien zeigen, dass die automatische Identifikation von Gründächern weiterhin mit erheblichen Herausforderungen verbunden ist. Louis-Lucas et al. (2025) weisen darauf hin, dass bislang keine einfach übertragbare Methode zur zuverlässigen Erkennung begrünter Dächer existiert. Als zentrale Schwierigkeiten nennen sie das starke Klassenungleichgewicht (wenige Gründächern gegenüber vielen Nicht-Gründächern) sowie Störeinflüsse durch Verschattung, Materialvielfalt und

geometrische Verzerrungen in Luftbildern. Zur Verbesserung der Klassifikation werden daher häufig zusätzliche Datensätze wie LiDAR-Daten herangezogen, die eine dreidimensionale Erfassung von Dach- und Vegetationsstrukturen ermöglichen, jedoch aufgrund hoher Kosten meist auf projektbezogene Anwendungen beschränkt bleiben (Louis-Lucas et al. 2025).

Diese Herausforderungen erklären zugleich, warum einfache schwellenwertbasierte Ansätze allein häufig nicht ausreichen und zunehmend durch kombinierte Verfahren ergänzt werden, die hochwertige Geobasisdaten, hochaufgelöste Orthofotos sowie Informationen zu Dachform, Dachneigung und Nutzung mit (halb-) automatisierten Klassifikationsverfahren kombinieren. Die Arbeit von Massy et al. (2011) ist ein Beispiel für ein deskriptiv-selektierendes Vorgehen anhand fester Schwellenwerte. Sie nutzten hochaufgelöste Vierkanal-Orthofotos, um eine halbautomatisierte Kartierung von Gründächern im Genfer Stadtgebiet zu entwickeln. Ihre Methodik basierte auf vier Kriterien: Dachneigung, Helligkeit, Vegetationssignal (NDVI) und Dachfläche. Für jede Variable wurden typische Wertebereiche definiert. Die Grenzwerte wurden bewusst großzügig gewählt, um möglichst wenige Gründächer zu übersehen, was von den Autoren selbst als „optimistische Kartierung“ bezeichnet wird (Massy et al. 2011). Allerdings führte dieser Ansatz zu einer hohen Zahl von Fehlklassifikationen. Nur etwa 21 Prozent der identifizierten Gründächer waren tatsächlich begrünt. Dieses Beispiel verdeutlicht sowohl das Potenzial als auch die Grenzen rein regelbasierter Verfahren. Betrachtet man die Methodik von Massy et al. (2011) als Ergänzung zu einer manuellen Kartierung, bedeutet sie dennoch eine deutliche Reduzierung des Arbeitsaufwandes.

Auch Ansel et al. (2015) verfolgen eine Kombination aus fest definierten NDVI-Schwellenwerten auf Pixelebene und einem Ausschlussverfahren pro Objekt anhand von Dachneigung, Material und Flächengröße. So kann jeder Dachfläche eine Reihe von beschreibenden Attributen zugewiesen werden, anhand derer die Dachfläche klassifiziert werden kann. Dem ähnelt das Vorgehen von Büschner & Mütterthis (2021), die ebenfalls anhand von NDVI und Minstdachfläche eine Klassifizierung vornehmen. Diese Ansätze bleiben zwar im Kern regelbasiert, erweitern jedoch die Entscheidungslogik durch objektbasierte Attribute und nähern sich damit schrittweise hybriden Klassifikationsstrategien an.

Zur Erhebung und Aufbereitung von Informationen zum Gründachbestand in Berlin verfolgen Coenradie et al. (2016) einen zweistufigen Kartieransatz aus einer automatisierten Vorkartierung, welche eine spektrale Klassifizierung der digitalen Orthophotos über den NDVI mit einer regelbasierten Klassifizierung unter Einbeziehung von Gebäude- und Fachplandaten kombiniert. Hierbei wurden Referenzflächen definiert, Vegetationssegmente gebildet und eine unüberwachte Clusteranalyse zur Unterscheidung in „sicher Vegetation“, „unsicher Vegetation“ und „sicher keine Vegetation“ angewendet. Ergänzend flossen Informationen über Gebäudegeschosse,

Vegetationshöhen und Flächentypen ein, um Fehlklassifikationen durch Baumkronen, Dachschrägen oder Reflexionen zu reduzieren. Nach dieser automatisierten Stufe erfolgte die Nachkartierung mittels visueller Luftbildinterpretation, bei der die Vektorsegmente geprüft, korrigiert und fehlende Gründächer ergänzt wurden. Dieser Ansatz zeigt exemplarisch die Bedeutung manueller Nachbearbeitung, um die Grenzen algorithmischer Klassifikation im urbanen Kontext auszugleichen.

Ein Beispiel für die Weiterentwicklung schwellenwertbasierter Verfahren bieten Khali et al. (2024) mit einem „Supervised NDVI Composite Thresholding“ (SNDVI) zur Kartierung von Vegetationsflächen in ariden Regionen. Dabei werden statt fester NDVI-Werte lerngestützte, standortspezifische NDVI-Schwellenwerte aus Trainingsproben verwendet, um zwischen Vegetation, Wasser und unbedecktem Boden zu unterscheiden. Grundlage sind Sentinel-2-Bilder und aus ihnen berechnete Vegetation Condition Index (VCI)-Werte, aus denen mithilfe von Trainingspunkten vier verschiedene Schwellenstrategien abgeleitet werden. Die Ergebnisse zeigen, dass dieser Ansatz hohe Genauigkeitswerte liefert, mit einer Accuracy bis zu 98 Prozent.

Marmy et al. (2025) nutzen sowohl einen klassischen Machine-Learning-Workflow als auch ein Deep-Learning-Modell, um binäre Erkennung (begrünt vs. nicht begrünt) und auch mehrklassige Vegetationsklassen zu adressieren. Es wurden statistische Pixel-Deskriptoren (NDVI und Luminosity) berechnet und anschließend sowohl ein Random Forest-Modell als auch ein logistisches Regressionsmodell trainiert. Diese Modellkombination erreichte auf dem Testdatensatz einen Recall von 0,87 für die Klasse „begrünt“ und einen F1-Score von 0,85 über alle Dächer. NDVI und grüne Farbwerte waren die wichtigsten Prädiktoren. Schwierigkeiten traten vor allem bei stark heterogenen Dachbegrünungen auf, etwa bei Mischformen aus Rasen, extensiver Vegetation und Terrassen. Für die Klassifizierung mehrerer Klassen wurde ein angepasstes DeepNet-Modell implementiert, das mehrere Begrünungskategorien unterscheidet. Die Deep-Learning-Variante erzielte für einige Klassen insbesondere im binären Setup sehr hohe Gütemaße, zeigte aber bei detaillierteren Klassen moderatere Ergebnisse. Die Studie zeigt, dass kombinierte Machine Learning (ML)- und Deep Learning (DL)-Ansätze eine automatisierte, skalierbare Erkennung von Begrünungsflächen erlauben, wobei Deep-Learning-Modelle Vorteile bei der Klassifikation komplexer Vegetationstypen bieten. Weitere Deep Learning-Ansätze zur Klassifizierung von Grünflächen finden sich bei Falcao et al. (2025), Kim et al. (2025), Li et al. (2025), Ma et al. (2025) und Simpson et al. (2023). Im Vergleich zu den zuvor beschriebenen Ansätzen markieren diese Verfahren einen deutlichen Paradigmenwechsel hin zu datengetriebenen Modellen, die insbesondere bei komplexen und heterogenen Dachstrukturen ihre Stärken zeigen.

Anhand dieser Beispiele methodischer Kombinationen zur fernerkundlichen Klassifikation von Gründächern oder -flächen lässt sich zusammenfassen, dass diese meist gute Ergebnisse liefern,

jedoch keine vollständige Erfassung garantieren. Vielmehr zeigt sich, dass die Wahl der Methode stets einen Kompromiss zwischen Genauigkeit, Übertragbarkeit, Datenverfügbarkeit und Rechenaufwand darstellt.

In der Metastudie von Dobrinić et al. (2025) wurde untersucht, welche Bilddaten vorrangig für die Kartierung von Grünflächen genutzt werden. Demnach werden optische Satellitendaten (z. B. Sentinel, Landsat) und hochaufgelöste Luftbilder am häufigsten verwendet. Synthetic Aperture Radar (SAR)-Daten dienen meist in Kombination mit Luftbilddaten der Ergänzung struktureller Informationen. LiDAR-Daten aus Airborne oder Mobile Laser Scanning ermöglichen die dreidimensionale Erfassung von Vegetationsstrukturen, während hyperspektrale Daten zur detaillierten Klassifikation urbaner Vegetationsmuster eingesetzt werden. Luftbilder mit einer räumlichen Auflösung von weniger als einem Meter wurden hauptsächlich für Deep-Learning-basierte Kartierung verwendet, während sie in einer geringeren Anzahl in Forschungsarbeiten mit mechanistischen Modellen eingesetzt wurden (Dobrinić et al. 2025). Die Auflösung der Bilddaten beeinflusst zudem maßgeblich die räumliche Ausdehnung des Untersuchungsgebiets. Während bei grob aufgelösten Bilddaten entsprechend großflächige Untersuchungsgebiete erforderlich und sinnvoll sind, kann die hohe Datendichte hochaufgelöster Orthofotos den untersuchbaren Raum deutlich begrenzen. Die Wahl der Datengrundlage steht dabei in engem Zusammenhang mit den eingesetzten Methoden und beeinflusst maßgeblich deren Leistungsfähigkeit, sowie den räumlichen Anwendungsbereich.

Zur Bestimmung eines geeigneten Entscheidungsschwellenwerts innerhalb einer logistischen Regressionsanalyse kann auf etablierte Gütemaße zurückgegriffen werden, die eine ausgewogene Bewertung der Modellleistung ermöglichen. Der Youden-Index ($J = \text{Sensitivität} + \text{Spezifität} - 1$) wird vor allem in der diagnostischen Modellierung genutzt, um einen passenden „Cut-off“ für ein Vorhersagemodell zu bestimmen. Er kombiniert Sensitivity und Specificity zu einer einzigen Kennzahl und zeigt an, bei welchem Schwellenwert die Unterscheidung zwischen positiven und negativen Fällen am besten gelingt. In der Arbeit von Fluss et al. (2005) wird beschrieben, wie man den Youden-Index berechnet und statistisch absichert. Der optimale Cut-off ist dabei der Punkt auf der ROC-Kurve, an dem der Abstand zur Zufallslinie am größten ist bzw. dort, wo das Modell am stärksten zwischen den beiden Gruppen unterscheidet. Martínez-Cambor & Pardo-Fernández (2019) erweitern diesen Ansatz, indem sie flexiblere ROC-Modelle verwenden, die auch bei komplexeren Daten gut funktionieren. Maghami-Mehr et al. (2025) gehen noch einen Schritt weiter und zeigen, wie der Youden-Index unter Berücksichtigung zusätzlicher Einflussfaktoren modelliert werden kann. Dadurch lassen sich sogar gruppenspezifische oder individuell angepasste Schwellenwerte bestimmen. Insgesamt zeigen diese Arbeiten, dass der Youden-Index nicht nur ein einfaches Maß zur Bewertung eines Modells ist, sondern gezielt in statistische Modelle eingebunden werden kann, um sinnvolle

und praxisnahe Entscheidungsgrenzen festzulegen. Alternativ kann der Cut-off auch über andere Kriterien bestimmt werden, etwa durch Maximierung der Gesamtgenauigkeit (Accuracy), Minimierung einer Kostenfunktion bei bekannten Fehlklassifikationskosten, Festlegung einer gewünschten Sensitivität oder Spezifität (z. B. in Screening-Situationen), Verwendung des minimalen Abstands zum linken oberen Punkt der ROC-Kurve (siehe beispielsweise Abbildung 17 und Abbildung 22) oder durch entscheidungstheoretische Ansätze wie Net Benefit bzw. Decision Curve Analysis (Rousson & Zumbunn 2011). Es wird deutlich, dass die Modellbewertung und Schwellenwertwahl integrale Bestandteile des Klassifikationsprozesses sind und die Vergleichbarkeit verschiedener methodischer Ansätze maßgeblich beeinflussen.

Trotz der Vielzahl an methodischen Ansätzen zur fernerkundlichen Erfassung von Gründächern zeigt sich, dass bislang kein Verfahren eine zugleich hohe Genauigkeit, Übertragbarkeit und Effizienz gewährleistet. Während schwellenwertgestützte Ansätze durch ihre einfache Implementierbarkeit und geringe Datenanforderungen überzeugen, weisen sie insbesondere in heterogenen urbanen Strukturen eine hohe Anfälligkeit für Fehlklassifikationen auf. Demgegenüber bieten Machine-Learning- und Deep-Learning-Methoden zwar eine deutlich verbesserte Modellierungsfähigkeit komplexer Zusammenhänge, sind jedoch häufig mit erhöhten Anforderungen an Trainingsdaten, Rechenressourcen und Modellinterpretierbarkeit verbunden.

Vor diesem Hintergrund besteht Forschungsbedarf in der Entwicklung von methodisch schlanken, zugleich aber leistungsfähigen Klassifikationsansätzen, die auf standardisierten Geodaten basieren und eine gute Balance zwischen Modellgüte, Interpretierbarkeit und Übertragbarkeit bieten. Insbesondere die Anwendung logistischer Regressionsmodelle stellt hierbei einen vielversprechenden Ansatz dar, da hierbei eine nachvollziehbare Modellstruktur mit vergleichsweise geringen Datenanforderungen kombiniert wird. Ziel der vorliegenden Arbeit ist es daher, die Leistungsfähigkeit einer logistischen Regression zur Klassifizierung von Gründächern auf Basis von RGBI-Orthofotos und amtlichen Gebäudeumringen kritisch zu evaluieren und deren Potenziale sowie Grenzen herauszuarbeiten.

3 Die Stadt Innsbruck als Untersuchungsgebiet

Innsbruck, Landeshauptstadt von Tirol liegt im Inntal im Westen Österreichs auf etwa 574 m Seehöhe und ist von alpinem Gelände umgeben. Fernerkundlich stellt das Gebiet aufgrund seiner komplexen Topografie eine besondere Herausforderung dar. Starke Höhenunterschiede, Hangneigungen sowie unterschiedliche Expositionen beeinflussen die Sonneneinstrahlung, Schattenwurf und Reflexionseigenschaften der Oberflächen. Zudem sorgt die heterogene Landbedeckung, wie dicht bebauter urbaner Raum, Verkehrsflächen, bewaldete Hänge und alpinen Vegetationszonen für eine hohe spektrale Vielfalt, die bei der Analyse von Orthofotos besondere Beachtung finden muss.

Das spezielle Untersuchungsgebiet richtet sich nach den Blattsschnitten der RGBI-Orthofotos aus dem Jahr 2022 und ist in Abbildung 2 nachzuvollziehen (Blattschnitte: Amt der Tiroler Landesregierung - Abteilung Geoinformation 2022).

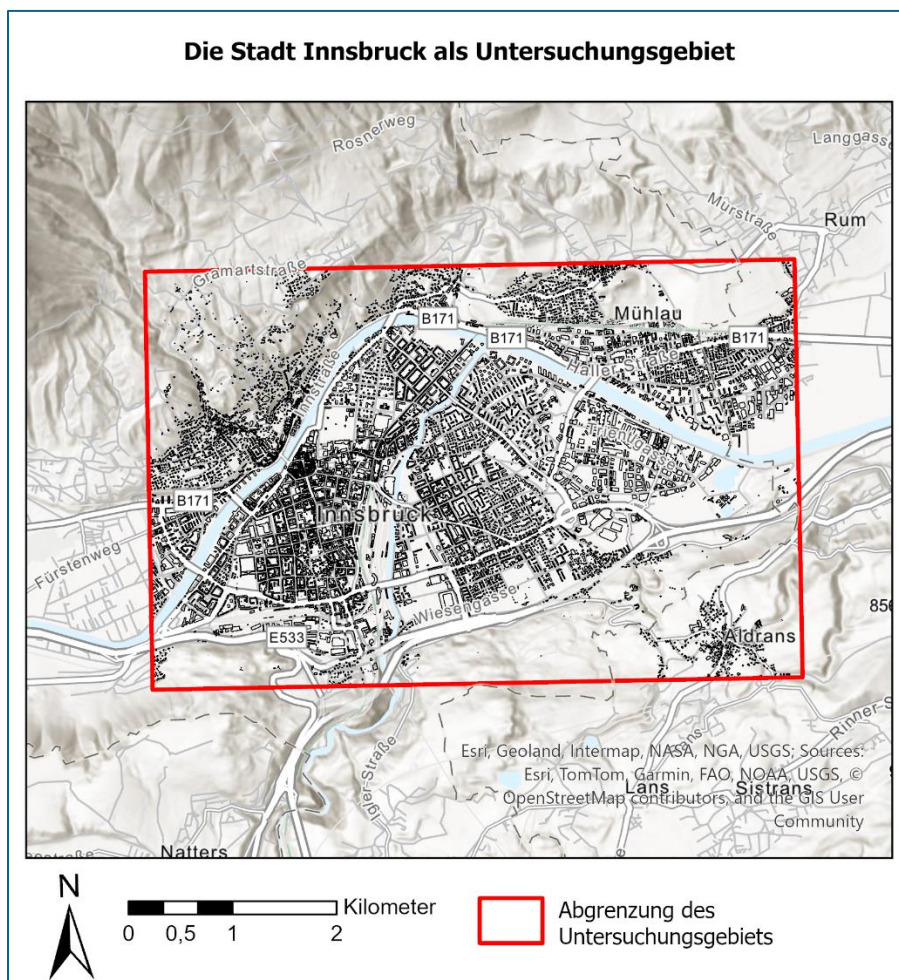


Abbildung 2: Abgegrenztes Untersuchungsgebiet innerhalb des Stadtgebiets Innsbrucks, eigene Darstellung.

4 Grundlagendaten und Koordinatensystem

Für die Durchführung der logistischen Regressionsanalyse werden unterschiedliche Geodaten benötigt, die sowohl die spektralen Oberflächeneigenschaften als auch die räumliche Abgrenzung der Dächer abbilden. Dazu zählen hochauflösende Bilddaten, gelabelte Trainingsdaten sowie Vektordaten der Gebäudeumringe. Eine Übersicht über Bezeichnung, Quelle, Auflösung und Erhebungszeitpunkt der drei verwendeten Datensätze ist in Tabelle 1 dargestellt.

Tabelle 1: Zusammenfassung der Grundlagendatensätze

Datensatz	Quelle	Auflösung	Jahr
RGBI-Orthofotos des Stadtgebiets Innsbruck als GeoTIFF	Abteilung Geoinformation des Landes Tirol	20 cm	September 2022
„Digitales Landschaftsmodell (DLM) Bauwerke Österreich“: österreichweiter Bauwerksbestand in Vektorform	Bundesamt für Eich- und Vermessungswesen	-	November 2024
Vektordaten Gründachkartierung, ausgewählte Stadtgebiete österreichweit	Projekt „Lebensraum Gründach“	-	Juli 2024

Für die Analyse werden Vier-Kanal-Orthofotos genutzt, bestehend aus den Bändern Rot, Grün, Blau und Nah-Infrarot, bereitgestellt durch die Abteilung Geoinformation des Landes Tirol (Amt der Tiroler Landesregierung - Abteilung Geoinformation 2022). Die hohe Auflösung der Orthofotos von 20 mal 20 Zentimeter Pixelgröße bietet das Potential für eine hohe Analysegenauigkeit. Die Arbeit mit Orthofotos bringt allerdings auch potenzielle Fehlerquellen mit sich. Durch die Vogelperspektive werden Dachflächen oft von gebäudenahen Bäumen überschirmt, sodass nicht die NDVI-Werte der Dachfläche, sondern die der Baumkrone extrahiert werden. Dies kann zu einer Fehlinterpretation der Dacheigenschaften führen (Hoffert & Lumasegger 2010; Ansel et al. 2025). Weiterhin entstehen bei Luftbildaufnahmen Verzerrungen durch die perspektivische Abbildung aus einem zentralen Kamerastandpunkt sowie durch Reliefunterschiede im Gelände (Hoffert & Lumasegger 2010). Die verwendeten Orthofotos sind zwar anhand eines Geländemodells entzerrt, dennoch sind alle Bildelemente, die nicht am Boden liegen, abhängig von Objekthöhe und Aufnahmebereich mehr oder weniger lageversetzt, was als Verkipfungseffekt bezeichnet wird. Eine Überlagerung mit den digitalen Gebäudeumringen ist deshalb mit Abweichungen verbunden. Je nach Sonnenstand zum Aufnahmezeitpunkt können auf den Bildern außerdem tief verschattete Areale auftreten, was die Bildinterpretation in diesen Bereichen einschränken kann (Hoffert & Lumasegger 2010).

Die bereitgestellten Orthofotokacheln des Stadtgebiets Innsbruck, sowie die Gebäudegrundrisse liegen original im Koordinatenbezugssystem EPSG: 31254 MGI / Austria GK West (im Projektionssystem Gauß-Krüger) vor. MGI steht dabei für „Militärgeografisches Institut“ und wird historisch in Österreich und Teilen des Balkans verwendet (Otter 2015). Allerdings ist das MGI-System zunehmend weniger in Gebrauch, da es in einer europaweiten ganzheitlichen Betrachtung von räumlichen Fragestellungen wenig Übertragbarkeit bietet. Daher wird in dieser Arbeit das System ETRS89/UTM mit der Zone 32N genutzt, in welcher sich das Untersuchungsgebiet befindet. Das UTM-System entwickelt sich zu einem europaweiten Standard und bietet eine gewisse Einheitlichkeit und Geläufigkeit (Bundesamt für Eich- und Vermessungswesen 2021b). Alle Datensätze wurden in ETRS UTM Zone 32N projiziert. Im Projektionsprozess wurde das Transformationsverfahren „NTv2“ (National Transformation Version 2) genutzt. Dieses gitternetzbasierende Verfahren dient der Transformation zwischen dem nationalen Österreichischen System MGI und dem europäischen Referenzsystem ETRS89 und gewährleistet eine höchst mögliche Genauigkeit (Bundesamt für Eich- und Vermessungswesen 2021a).

Das digitale Landschaftsmodell (DLM) der Bauwerke dient zur Visualisierung der Gebäudeumringe, welche mit den Dachflächen gleichgesetzt werden (Bundesamt für Eich- und Vermessungswesen 2024). In den Daten kommt es teilweise vor, dass die bebaute Fläche über Dachabschnitte hinweg zusammengefasst wird. Dächer, die auf den Orthofotos getrennte Einheiten darstellen, sind im DLM als ein Polygon zusammengefasst. Dies erschwert die Abgrenzung von unterschiedlichen Teilflächen.

Die Gründach-Kartierung durch das Projekt „Lebensraum Gründach“ umfasst ausgewählte Siedlungsgebiete auf ganz Österreich verteilt, woraus die Kartierungen für das Untersuchungsgebiet des Stadtgebiets Innsbruck entnommen werden. Diese Kartierung bildet die Grundlage für die Erstellung der gelabelten Datensätze für Gründächer (Label 1) und Nicht-Gründächer (Label 0). Da es sich um eine händische, wenig systematische Kartierung handelt, welche von verschiedenen KartiererInnen erstellt wurde, besteht kein Anspruch auf Vollständigkeit oder Einheitlichkeit und manche Zuweisungen müssen ggf. bereinigt werden. Die händisch gezeichneten Polygone stimmen nicht mit den Gebäudeumringen überein. „Lebensraum Gründach“ ist ein transdisziplinäres Projekt, das in enger Zusammenarbeit zwischen der Universität Innsbruck, den Tiroler Landesmuseen, inatura in Vorarlberg, drei Partnerschulen sowie zahlreichen weiteren externen Kooperationspartnern umgesetzt wurde (Universität Innsbruck 2024).

5 Methodik

Die Methodik zur Gründachklassifizierung besteht aus einer Folge von Datenverarbeitungsschritten, welche zwischen den Programmen ArcGIS Pro (Version 3.4.0) und RStudio (Version 2025.05.0 unter Verwendung der Programmiersprache R, Version 4.5.1) pendeln, wobei die Modelleingabedaten in Excel formatiert werden. Die Integration von Pixel- und Objektebene ermöglicht die Informationskombination aus einzelnen Bildpixeln und den strukturellen Objektdaten im Sinne der einzelnen Dächer. Die Methodik stellt einen schrittweise aufgebauten Workflow dar, der sowohl eine differenzierte Datenaufbereitung umfasst als auch eine nachvollziehbare Modellierung der Gründachwahrscheinlichkeiten erlaubt.

In Tabelle 2 sind die aufeinander aufbauenden Datenverarbeitungsschritte aufgeführt, welche den pixelbasierten Klassifikationsansatz, die Erstellung der Modelleingabe und die Durchführung der logistischen Regressionsanalyse bündeln. Blau hinterlegte Abschnitte beziehen sich auf den pixelbasierten Workflow, orangene Bereiche betreffen die objektbasierte Datenverarbeitung. Die jeweiligen Arbeitsschritte werden in den zugehörigen Kapiteln weiter erläutert.

Tabelle 2: Zusammenfassung der methodischen Schritte anhand ihrer aufeinander aufbauenden Reihenfolge

Arbeitsschritt	Daten und Datenverarbeitung	Plattform
1. Verschneidung und Bufferung	<ul style="list-style-type: none"> - Verschneiden der Orthofotos mit den Gebäudeumringen - Bufferung der Gebäudeumringe um -1 Meter - Zuweisung von Dach-IDs 	ArcGIS Pro
2. Pixelbasierte Klassifizierung zur Ermittlung vegetationstypischer Pixel pro Dach	<ul style="list-style-type: none"> - Berechnung des NDVI- und Luminosity-Rasters - Schwellenwertermittlung vegetationstypischer Wertebereiche: Auswertung von NDVI- und Luminosity-Verteilung auf Gründächern <ul style="list-style-type: none"> → NDVI > 0 → Luminosity von 9.800 bis 109.800 → Pixelmaskierung aller nicht-vegetationstypischer Pixel auf allen Dachflächen im Untersuchungsgebiet - Validierung der vegetationstypischen Pixelklassifikation 	ArcGIS Pro
3. Erstellen der Modelleingabe	<ul style="list-style-type: none"> - Auswahl Modelleingabe-Dächer Label 0 → Dächer ohne Vegetationspixel - Auswahl Modelleingabe-Dächer Label 1 → kartierte Teilgrünflächen - jeweilige Extraktion der Statistiken: Median pro Dachfläche 	ArcGIS Pro und Excel
Logistische Regression (LR) in RStudio		
4. Logistische Regressionsanalyse: univariat und	<ul style="list-style-type: none"> - Einlesen der Werte pro Dachfläche, getrennt nach Gründach und Nicht-Gründach - Zuweisung von Label 1 für Gründach; Label 0 für Nicht-Gründach 	RStudio

Arbeitsschritt	Daten und Datenverarbeitung	Plattform
multivariat	<ul style="list-style-type: none"> - Zusammenführen der Datensätze → Analysedatensatz - Aufteilung in Trainings- (70%) und Testdaten (30%) - Gewichtung: Überbetonung von seltenen Gründächern - Training des Regressionsmodells - Modellvalidierung anhand der Testdaten: ROC-Kurve → AUC - Setzen von Entscheidungsschwellenwerten: 0,6 & Ermittlung des Youden-Schwellenwerts - Darstellen der Klassifikation anhand von Confusion Matrices - Ausgabe der modellinternen Evaluationsmetriken: Accuracy, Recall, Precision, F1- und F2-Score 	
	<ul style="list-style-type: none"> - Modellanwendung auf alle Dachflächen des Untersuchungsgebiets - Ausgabe der .csv-Datei mit Wahrscheinlichkeiten pro Dachfläche abhängig vom Schwellenwert für Zielvariable Gründach (Label 1) 	
	<ul style="list-style-type: none"> - Visualisierung & Validierung der Modellanwendung auf alle Dachflächen im Untersuchungsgebiet 	ArcGIS Pro
5. pixelbasierte Ermittlung des Grünflächenanteils auf klassifizierten Gründächern	<ul style="list-style-type: none"> - Zonal Statistik der vegetationstypischen Pixel pro klassifiziertem Gründach - Berechnung des absoluten und relativen Grünflächenanteils 	ArcGIS Pro
Output	<p>Datensatz mit klassifizierten Gründächern im Stadtgebiet Innsbruck abhängig von Modelleingabe und Entscheidungsschwellenwert</p> <p>Angaben über Grünflächenanteil pro Dachfläche und prozentuale Einteilung</p>	ArcGIS Pro

Abbildung 3 veranschaulicht vereinfacht den methodischen Aufbau des objektbasierten Methodenteils. In Grün sind die Eingabedatensätze sowie die erzeugten Datensätze gekennzeichnet. Violett steht für die Verarbeitungsschritte, während Blau die Ergebnisse der Klassifizierung repräsentiert.

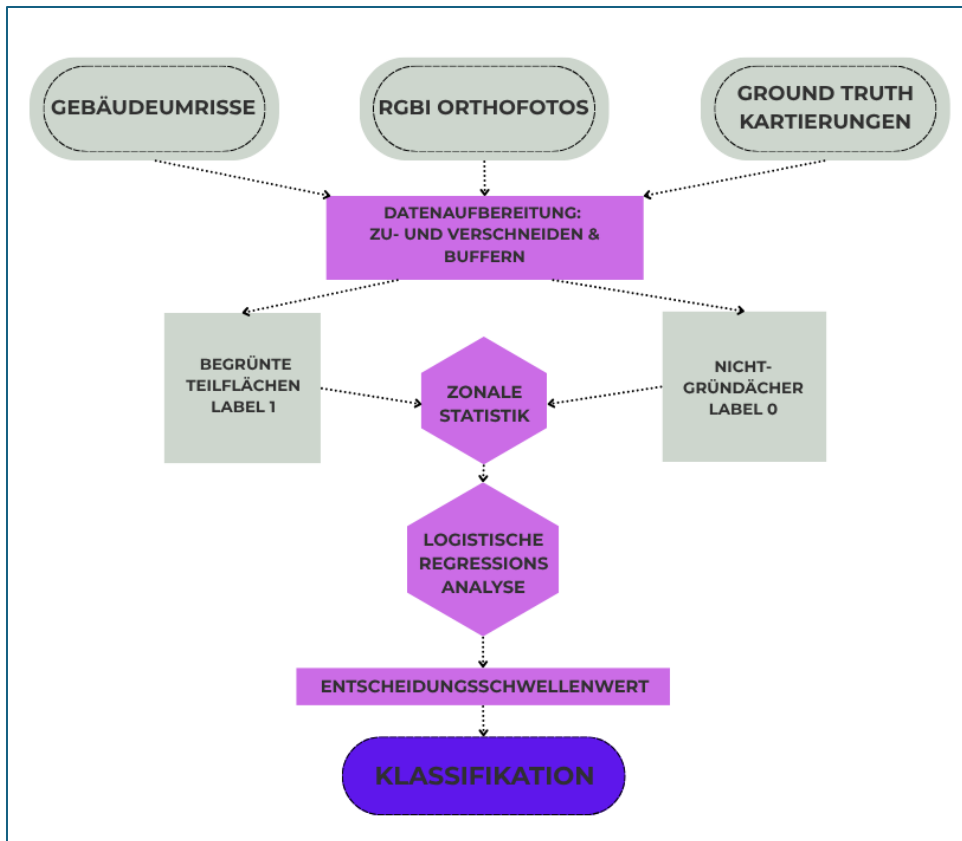


Abbildung 3: Vereinfachtes Fließschema des objektbasierten Methodenteils, eigene Darstellung.

5.1 Verschneidung und Bufferung

In einem ersten Datenverarbeitungsschritt werden die Orthofotos des Untersuchungsgebiets mit den amtlichen Gebäudeumringen verschnitten, um nur mehr die Dachflächen auf den Orthofotos zu betrachten. Wie bei Marmy et al. (2025) werden die Gebäudeumringe mit einem Buffer von minus einem Meter versehen, da angenommen wird, dass die meisten Fehlerquellen im Bereich der Dachränder auftreten. In den Randarealen kommt es am ehesten vor, dass Bäume über die Dachfläche wachsen und die spektralen Werte verändern oder dass durch Verkippungseffekte der amtliche Gebäudeumriss nicht genau mit dem Orthofoto übereinstimmt.

Im Datensatz der amtlichen Gebäudeumringe wird jedem Polygon eine Dach-ID zugewiesen. Insgesamt enthalten sind 12.103 Dachflächen im Untersuchungsausschnitt des Stadtgebiets Innsbruck.

5.2 Pixelbasierte Klassifizierung zur Ermittlung vegetationstypischer Pixel pro Dachfläche

Für die Erstellung von sinnvollen Trainingsdatensätzen für die logistische Regressionsanalyse, müssen die Eingabeobjekte fehlerfrei gelabelt sein. Das bedeutet, im Datensatz der Nicht-Gründächer dürfen keine unerkannten Gründächer enthalten sein und die Klasse der Gründächer soll ausschließlich korrekt gelabelte Grünflächen umfassen. Sollten die Trainingsdaten fehlerbehaftet sein, wirkt sich dies auf die Vorhersagegenauigkeit und die allgemeine Modellleistung aus. Da nicht davon ausgegangen werden kann, dass die Gründachkartierung des Projekts „Lebensraum Gründach“ ausnahmslos alle Gründächer erfasst hat, kann der Datensatz der Nicht-Gründächer (Label 0) nicht über ein einfaches Ausschlussverfahren erstellt werden. Es braucht ein weiteres Ausschlusskriterium für die Auswahl von Nicht-Gründächern. Darüber hinaus handelt es sich bei der Mehrzahl der Gründächer nicht um homogene Flächen, welche durchgehend begrünt sind, sondern um ein Mosaik aus verschiedenen Dachaufbauten, -fenstern, Kies- und Grünflächen. Daher muss ein Weg gefunden werden, den tatsächlichen Grünflächenanteil innerhalb eines Dach-Polygons zu bestimmen.

Für die Abgrenzung der Nicht-Gründächer und die Ermittlung des tatsächlichen Grünflächenanteils auf Gründächern wird der objektbasierten Klassifizierung eine Klassifizierung auf Pixelebene vorangestellt. So können objektintern vegetationstypische Pixel von anderen Oberflächen abgegrenzt werden. Zusätzlich zum bewährten NDVI wird die Luminosity nach Marmy et al. (2025) herangezogen, welche die Abgrenzung von vegetationstypischen Pixeln zusätzlich schärfen soll.

So werden die typischen spektralen Werte von NDVI und Luminosity auf Grundlage der gegebenen Orthofotos statistisch ermittelt und anschließend Schwellenwerte festgelegt, welche eine Abgrenzung von Vegetation zu anderen Dachoberflächen ermöglichen. Aus den ermittelten Schwellenwerten von NDVI und Luminosity wird ein vegetationstypischer Wertebereich kombiniert und daraus eine „Pixelmaske“ erstellt. Bildpixel, welche außerhalb des kombinierten Wertebereichs liegen, werden ausgeschlossen, vegetationstypische Pixel im Wertebereich bleiben bestehen.

5.2.1 Berechnung des NDVI-Rasters

Für die Berechnung des NDVI-Rasters werden in ArcGIS Pro die Farbbänder Rot und Nah-Infrarot aus dem Orthofoto extrahiert (mit dem Tool „Make Raster Layer“). Anhand der NDVI-Formel (siehe Kapitel 2) wird mit Hilfe des Tools „Raster Calculator“ das NDVI-Raster berechnet. Das erzeugte Raster enthält pro Pixel einen NDVI-Wert, welche speziell für diese Orthofotos einen Wertebereich von -0,46 bis 0,59 abdecken. Die gelb bis rot gefärbten Teilflächen in Abbildung 4 lassen schon einen Hinweis auf Dachvegetation erkennen.




Abbildung 4: Ausschnittsweise Visualisierung des NDVI-Rasters im Untersuchungsgebiet, eigene Darstellung.

5.2.2 Berechnung des Luminosity-Rasters

Das Luminosity-Raster wird durch Addition der drei Bänder Rot, Grün, Blau berechnet. Der Wertebereich des Luminosity-Rasters hängt vom Bildformat bzw. von der Pixeltiefe ab. Die in diesem Fall genutzten Orthofotos verfügen über eine Tiefe von 16 Bit. Dementsprechend kann der Wertebereich von 0 bis 196.605 reichen. Das erzeugte Raster weist einen Wertebereich von 28.964 bis 196.605 für das Untersuchungsgebiet auf. In Abbildung 5 zeigt sich, dass z. B. Glasoberflächen oder heller Beton besonders gut reflektieren. Die zusätzlichen Informationen über die Pixelhelligkeit unterstützen die Differenzierung von vegetationstypischen Flächen z. B. durch das Ausschließen sehr dunkler Flächen (Louis-Lucas et al. 2021; Marmy et al. 2025).

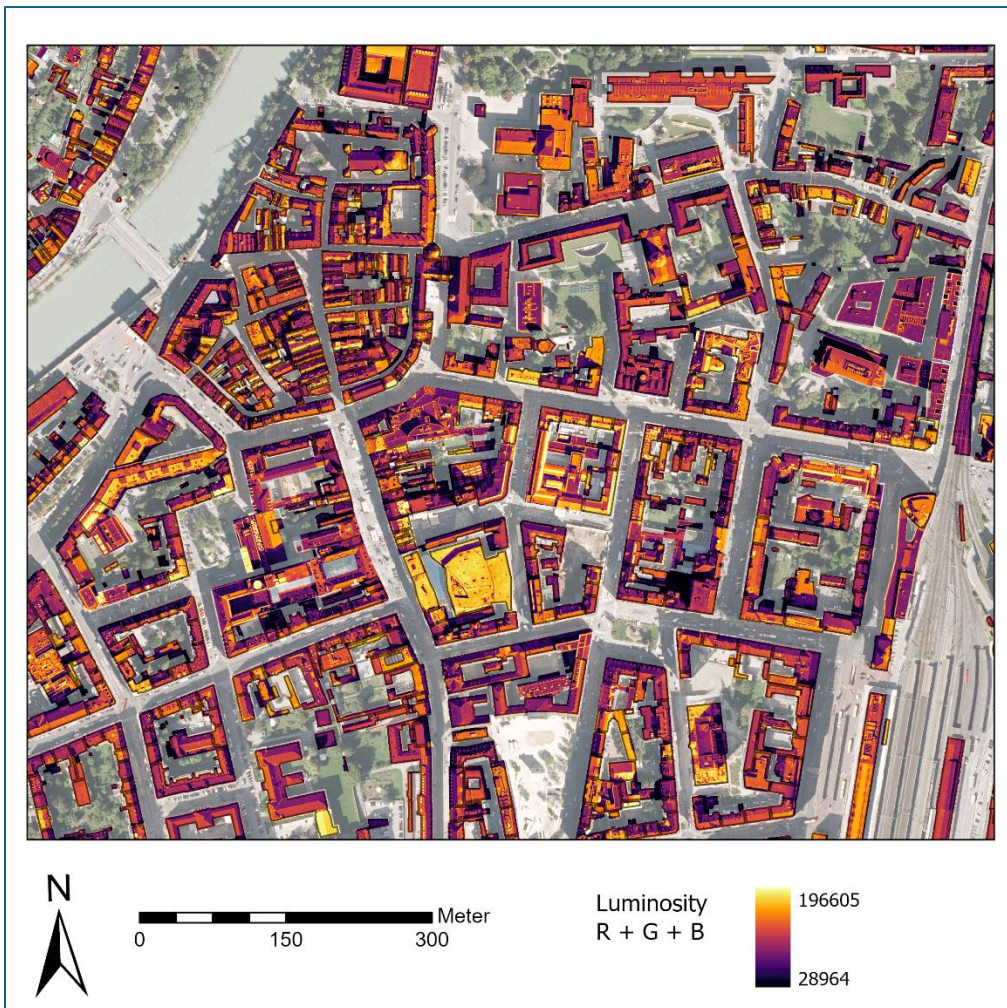


Abbildung 5: Ausschnittsweise Visualisierung des Luminosity-Rasters im Untersuchungsgebiet, eigene Darstellung.

5.2.3 Schwellenwertermittlung zur Abgrenzung vegetationstypischer Pixel

Um die vegetationstypischen Wertebereiche von Luminosity und NDVI statistisch fundiert festlegen zu können, werden in ArcGIS die jeweiligen Pixelverteilungen in einem Histogramm visualisiert und in RStudio die Verteilungen der NDVI- und Luminosity-Mediane pro Dachfläche ermittelt. Auf diese Weise werden die vegetationstypischen Wertebereiche für die anschließende Pixelmaske abgegrenzt.

5.2.3.1 Vegetationstypischer Luminosity-Wertebereich

Wie in Abbildung 6 nachzuvollziehen reicht der Luminosity-Wertebereich aller Dachflächen von 28.964 bis 196.605. Der Wertebereich der kartierten Gründächer dagegen umfasst Werte von 40.218 bis 196.589 (siehe Abbildung 7). Der Wertebereich der Gründächer setzt höher an, aber gleicht in seinem Maximum dem Wertebereich aller Dächer. Anhand der zwei Histogramme lässt sich erkennen, dass der vegetationstypische Luminosity-Durchschnitt unter dem Durchschnittswert aller Dachflächen liegt.




Abbildung 6: Histogramm der Pixelverteilung der Luminosity für alle Dächer im Untersuchungsgebiet; eigene Darstellung




Abbildung 7: Histogramm der Pixelverteilung der Luminosity für die kartierten Gründächer im Untersuchungsgebiet; eigene Darstellung

Um den vegetationstypischen Luminosity-Wertebereich auf Objektebene zu untersuchen, wird mit „Zonal Statistics“ der Luminosity-Median pro kartierter Gründachfläche ermittelt und anschließend in RStudio die statistische Verteilung in einem Boxplot visualisiert. Es ergibt sich ein Interquartilsbereich (IQR) zwischen dem ersten Quartil bei 98.897 und dem dritten Quartil bei 109.774 (siehe Abbildung 8). Fünfzig Prozent aller Gründach-Luminosity-Werte liegen innerhalb dieses Intervalls. Der Bereich der gerundeten Schwellenwerte von 98.900 bis 109.800 wird im Folgenden als vegetationstypisch angenommen.




Abbildung 8: Boxplot der Median-Verteilung der Luminosity pro Gründach, eigene Darstellung.

5.2.3.2 Vegetationstypischer NDVI-Wertebereich

Für die Herleitung eines vegetationstypischen NDVI-Wertebereichs, spezifisch für die verwendeten Orthofotos, wurde ebenfalls die Pixelverteilungen als Histogramm visualisiert. In Abbildung 9 ist die Verteilung der NDVI-Pixelwerte aller Dachflächen im Untersuchungsgebiet dargestellt. In Abbildung 10 findet sich die NDVI-Pixelverteilung aller kartierten Grünflächen. Betrachtet man alle Dachflächen ungefiltert, reicht der Wertebereich von -0,46 bis 0,62, mit einem Hochpunkt bei ca. -0,05 (siehe Abbildung 9). Betrachtet man die Pixelverteilung nur auf den kartierten Gründächern so beginnt der Wertebereich erst bei -0,28 und endet bei 0,59. Es sind zwei Hochpunkten zu erkennen, jeweils bei -0,04 und 0,12 (siehe Abbildung 10).




Abbildung 9: Histogramm der Pixelverteilung des NDVI für alle Dächer im Untersuchungsgebiet; eigene Darstellung.




Abbildung 10: Histogramm der Pixelverteilung des NDVI für die kartierten Grünflächen im Untersuchungsgebiet; eigene Darstellung.

Eine Erklärung für die Verteilung mit zwei Hochpunkten der Gründach-NDVI-Pixelwerte ist die heterogene Oberflächenbeschaffenheit der kartierten Gründächer. Es muss davon ausgegangen werden, dass die kartierten Bereiche die Teilgrünflächen nicht vollkommen sauber abgrenzen. Der Hochpunkt im negativen NDVI-Bereich bildet sich durch all jene Pixel aus, welche keine Vegetation abbilden, aber dennoch auf einer als „grün“ kartierten Dachfläche liegen. Der zweite Hochpunkt in der Pixelverteilung im positiven NDVI-Bereich wird durch die höheren NDVI-Werte vitaler Vegetation abgebildet.

Um auch die NDVI-Verteilung auf Objektebene zu untersuchen, wird in RStudio ein Boxplot der NDVI-Mediane pro kartiertem Gründach erstellt (siehe Abbildung 11). Die statistische Auswertung ergibt

einen Median von 0,083 und einen Mean von 0,08. Der Bereich zwischen erstem und drittem Quartil (IQR) reicht von 0,0327 – 0,1298 und liegt damit im positiven Bereich.




Abbildung 11: Boxplot der NDVI-Mediane pro kartiertem Gründach, eigene Darstellung.

Im Vergleich zu NDVI-Wertebereichen aus der Literatur wie z. B. bei Aryal et al. (2022) oder Coenradie et al. (2016) erscheint der ermittelte NDVI-Interquartilbereich anhand der Orthofotos vergleichsweise niedrig. Dies kann durch eine niedrige Pflanzenvitalität zustande kommen. Wie bereits erwähnt, handelt es sich bei der typischen extensiven Gründachvegetation meist um Pflanzenarten, welche an den Extremstandort Dach angepasst sind und ein eher schwaches Vegetationssignal aufweisen. Hinzu kommt die Exposition bei Sonne und Trockenheit, was die Vitalität der Dachvegetation zusätzlich schwächt. Die zugrunde liegenden Orthofotos wurden im September 2022 aufgenommen, es ist daher anzunehmen, dass der Einfluss der zurückliegenden Sommerperiode die dargestellten Oberflächenmerkmale geprägt hat.

5.2.4 Maskierung von nicht-vegetationstypischen Pixeln

Aus den ermittelten Wertebereichen von NDVI und Luminosity wird eine vegetationstypische „Pixelmaske“ abgeleitet. Luminosity-Werte unter 98.900 repräsentieren wahrscheinlich andere Oberflächenmaterialien als Vegetation oder kommen durch Schatten zustande. Pixelwerte über 109.800 können stark reflektierende Oberflächen oder z. B. PV-Module sein. Alle Pixelwerte außerhalb dieses Wertebereichs werden auf „NoData“ gesetzt (in ArcGIS Pro mit Hilfe des Tools „Raster Calculator“).

Der NDVI-Interquartilbereich zwischen 0,033 und 0,129 ist im Vergleich zu Werten aus der Literatur sehr eng und es besteht die Gefahr, zu viele vegetationstypische Pixel auszuschließen. Ein Schwellenwert von Null stellt einen Kompromiss aus den NDVI-Werten aus der Literatur und den tatsächlichen, recht niedrigen Werten anhand der zugrundeliegenden Orthofotos dar. Eine obere

Schwelle wird nicht gesetzt, da kein Vegetationssignal verloren gehen soll. Dieses Vorgehen deckt sich mit Marmy et al. (2025), welche ebenfalls einen NDVI-Schwellenwert von Null setzen.

In Abbildung 12 wird die Wirkung dieser kombinierten Bedingung anschaulich dargestellt. Auf der beispielhaften heterogenen Dachoberfläche werden Fenster und andere Dachaufbauten deutlich als nicht-vegetationstypisch ausgeschlossen. Die erzeugte Pixelmaske (pink) lässt nur Pixel zu, welche einen NDVI über Null und einen Luminosity-Wert größer 98.900 und kleiner 109.800 aufweisen.

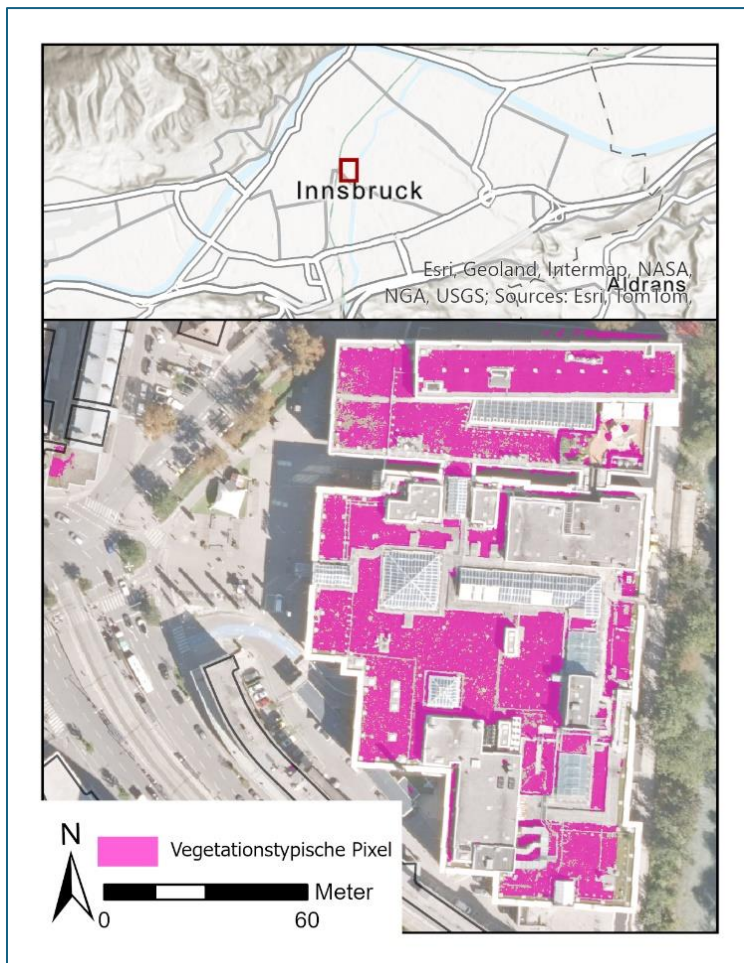


Abbildung 12: Beispiel für die Abgrenzung vegetationstypischer Pixel (pink) auf einer heterogenen Dachfläche, eigene Darstellung.

5.2.5 Validierung der vegetationstypischen Pixelklassifikation

Für die Validierung dieser pixelbasierten Klassifizierung werden die Pixel, welche laut der kombinierten Maske aus NDVI und Luminosity vegetationstypisch sind, in ArcGIS Pro zu Flächen vektorisiert. Mit dem Tool „Create Random Points“ werden insgesamt 500 Punkte zufällig innerhalb der Gebäudeumringe des Untersuchungsgebiets verteilt, wobei jeweils 250 Punkte innerhalb der vektorisierten vegetationstypischen Flächen und 250 außerhalb dieser liegen. Anschließend werden die Punkte anhand der Orthofotos händisch überprüft. Punkten, welche auf dem Orthofoto innerhalb

einer Grünfläche liegen, wird die Klasse 1 zugewiesen. Punkte, welche außerhalb einer Grünfläche liegen, bekommen die Klasse 0. Die abschließende Validierung erfolgt, indem die klassifizierten Kontrollpunkte mit der Lage innerhalb oder außerhalb der vegetationstypischen Maske abgeglichen werden.

In Abbildung 13 ist die Verteilung der validierten Punkte anhand einer Confusion Matrix dargestellt. 116 Punkte (True Positives TP), welche laut Orthofoto auf einer Grünfläche liegen, stimmen auch mit der Lage innerhalb einer vegetationstypischen Maskenfläche überein und 244 als nicht-vegetationstypisch klassifizierte Punkte (True Negatives TN) liegen tatsächlich außerhalb der vegetationstypischen Maskenfläche. 134 der Punkte, welche laut der händischen Zuweisung nicht auf einem Grünflächenpixel liegen, entsprechen laut Maske einem vegetationstypischen Pixel (False Positives FP). In nur sechs Fällen liegt ein Punkt laut Orthofoto auf einer Grünfläche, wird laut der vegetationstypischen Maskierung aber nicht als grün erkannt (False Negative FN).




Abbildung 13: Confusion Matrix zur Validierung der vegetationstypischen Pixelklassifizierung, eigene Darstellung.

Im Fall der Pixel-Validierung beträgt der Negative Vorhersagewert 0,97, welcher den Anteil der korrekt als negativ klassifizierten Ergebnisse (TN) gemessen an der Summe aller negativ klassifizierten Ergebnisse (TN + FN) wiedergibt. Daraus kann geschlossen werden, dass die pixelbasierte Abgrenzung von vegetationstypischer Fläche sehr gut dafür geeignet ist, die Klasse der Nicht-Gründächer (Label 0) für die Modelleingabe abzuleiten, da es nur zu einer sehr geringen Zahl an falsch-negativer Zuweisungen kommt. Das Vorgehen eignet sich allerdings nicht für die Abgrenzung der positiven Gründach-Klasse, da eine Vielzahl von falsch-positiven Zuweisungen auftritt.

5.3 Erstellung der Modelleingabe

Das logistische Regressionsmodell wird anhand gelabelter Daten trainiert, d. h. Daten mit der Zuordnung zu Klasse 1 „Gründach“ und Daten mit der Zuordnung zu Klasse 0 „Nicht-Gründach“. Folgend wird die Erstellung des Modelleingabedatensatzes für Nicht-Gründächer und Gründächer erläutert.

5.3.1 Erstellung des Modelleingabedatensatzes der Nicht-Gründächer (Label 0)

Für die Erstellung der Modelleingabedaten der Nicht-Gründach-Klasse wird die vegetationstypische Pixelmaskierung aus Kapitel 5.2.4 angewendet und in ArcGIS Pro die Summe der vegetationstypischen Pixel pro Dachfläche mit dem Tool „Zonal Statistics Table“ addiert. Dachflächen, bei welchen die vegetationstypische Pixel-Summe gleich Null ist, können als Nicht-Gründächer angenommen werden. Diese Dachflächen werden in einen neuen Layer exportiert und dienen als Modelleingabe der Nicht-Gründächer (Label 0). Der Datensatz umfasst 3.043 Dachflächen.

5.3.2 Erstellung des Modelleingabedatensatzes der Gründächer (Label 1)

Für die Modelleingabe der Gründächer (Label 1) dient die Kartierung des Projekts „Lebensraum Gründach“ als Grundlage. Zur Verknüpfung dieser Informationen mit den amtlichen Gebäudeumringen erfolgt eine räumliche Selektion mit dem Datensatz aller amtlichen Umrisse (in ArcGIS Pro über das Tool „Select Layer by Location“). Da die manuell erfassten Flächen nicht exakt mit den amtlichen Umringen übereinstimmen, können die Polygone über die tatsächlichen Grünflächen hinausreichen und benachbarte Dachbereiche einschließen. In der Folge entstehen fehlerhafte Zuordnungen, bei denen auch nicht begrünte Dächer als Gründach klassifiziert sind. Zur Vermeidung solcher Fehlzugeisungen wird der verschnittene Datensatz anhand der amtlichen Umrisse manuell überprüft und bereinigt. Auf diese Weise lassen sich 120 fehlerhaft zugewiesene Dachflächen korrigieren. Der anschließende Verschnitt beider Datensätze liefert einen Layer mit kartierten Gründächern auf Basis der amtlichen Umringe. Abschließend erfolgt die Übertragung der Dach-IDs in ArcGIS Pro mithilfe des Tools „Spatial Join“.

Für die Extraktion der statistischen Werte pro Gründach soll nicht die gesamte Dachfläche, sondern nur die kartierte Teilfläche betrachtet werden, da das Vegetationssignal andernfalls abgeschwächt werden könnte. Daher wird die Original-Kartierung noch einmal anhand der bereinigten amtlichen Gründachumrisse ausgeschnitten. Wiederrum mit dem Tool „Spatial Join“ wird die Dach-ID der Gesamtdachfläche auf die begrünten Teilflächen übertragen. Dabei kann es vorkommen, dass zwei Teilflächen auf derselben Dachfläche dieselbe Dach-ID erhalten. Es gibt 612 Teilgrünflächen auf 472 kartierten Gründächern nach amtlichen Gebäudeumringen.

5.3.3 Extraktion der Statistiken

Für die Modelleingabe auf Objektebene wird der Median pro Dachfläche herangezogen. Anders als bei der Berechnung des Mean wird der Wert pro Fläche so nicht durch Ausreißer verfälscht. Mit dem Tool „Zonal Statistics as Table“ können in ArcGIS Pro die Median-Werte pro Dachfläche und pro Farbband bzw. NDVI berechnet werden. Die einzelnen Tabellen werden für den Input in Rstudio mit dem Tool „Table to Excel“ in ein Excel-Format exportiert. Es ergeben sich insgesamt zehn Excel-Dateien, wobei jeweils getrennte Dateien für die Label 1 und 0 erstellt werden:

- Medianwert pro Dachfläche Band Rot → Label 0 und 1
- Medianwert pro Dachfläche Band Grün → Label 0 und 1
- Medianwert pro Dachfläche Band Blau → Label 0 und 1
- Medianwert pro Dachfläche Band Nah-Infrarot → Label 0 und 1
- Medianwert pro Dachfläche NDVI → Label 0 und 1

5.4 Logistische Regressionanalyse

Anhand der erstellten Eingabedatensätze werden ein univariates und ein multivariates logistisches Regressionsmodell aufgesetzt. Der univariate Ansatz dient zunächst als Prüfung, inwieweit der NDVI als alleiniger Prädiktor belastbare Klassifikationsergebnisse liefert. Im multivariaten Ansatz wird der NDVI um die einzelnen Medianwerte der Bänder Rot, Grün, Blau und Nah-Infrarot ergänzt, um zu prüfen, ob sich die Modellleistung mit mehr Eingabeparametern verbessern lässt. Zur Bestimmung eines geeigneten Entscheidungsschwellenwerts für die binäre Klassifikation wird der optimale Cut-off anhand des Youden-Index ermittelt. Ergänzend wird ein empirisch gewählter Schwellenwert von 0,6 definiert, um eine Klassifikationsregel größer als 0,5 zu berücksichtigen.

5.4.1 Univariante logistische Regression anhand des NDVI

Im Folgenden werden die einzelnen Schritte des RStudio-Skripts dargestellt, welche für den univariaten Modelllauf anhand des NDVI durchgeführt werden. Das gesamte Skript ist in Anhang 3 einsehbar. In Abbildung 14 sind die Datenverarbeitungsschritte des R-Skripts vereinfacht als Fließschema dargestellt.

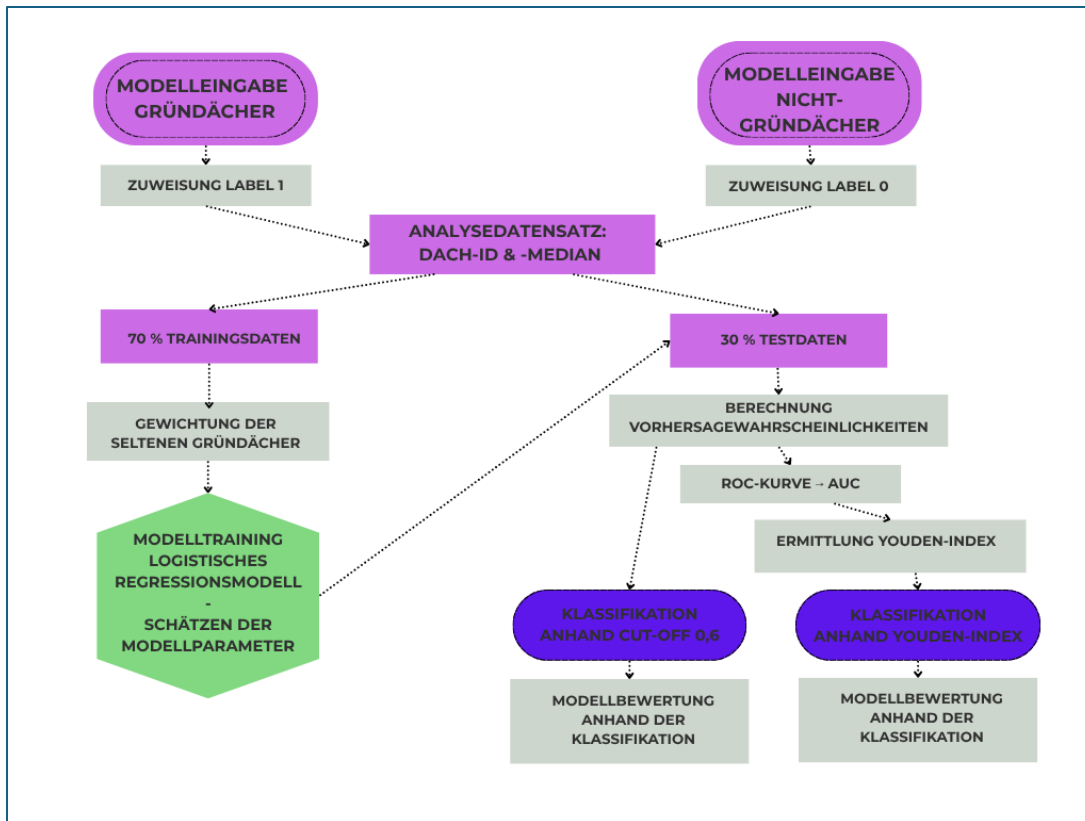


Abbildung 14: Vereinfachtes Fließschema der Verarbeitungsschritte im R-Skript der univariaten logistischen Regressionsanalyse, eigene Darstellung.

Für die Durchführung der Analyse werden verschiedene R-Pakete genutzt. Das Paket „readxl“ wird genutzt, um die Daten aus den Exceldateien in R einzulesen. Es ermöglicht den direkten Import von .xls- und .xlsx-Dateien. Das Paket „pROC“ dient der Analyse und Bewertung der Klassifikationsleistung des Modells. Insbesondere wird es zur Berechnung und Auswertung von „Receiver Operating Characteristic“ (ROC)-Kurven, zur Bestimmung der „Area Under Curve“ (AUC) sowie zur Ermittlung eines optimalen Klassifikationsschwellenwerts mittels Youden-Index eingesetzt (Robin et al. 2025).

Nachdem die Dateipfade der Exceltabellen mit den NDVI-Medianwerten der begrünten oder nicht-begrünten Dachflächen verknüpft und eingelesen sind, wird den einzelnen Dachflächen zunächst das Label 1 für „Gründach“ oder 0 für „Nicht-Gründach“ zugewiesen und ein gemeinsamer Analysedatensatz erstellt, indem die gelabelten Daten beider Gruppen wieder zusammengefasst werden.

Anschließend wird der Analysedatensatz in 70 Prozent Trainings- und 30 Prozent Testdaten aufgeteilt. Das Modell wird auf den 70 Prozent Trainingsdaten trainiert und anschließend auf den 30 Prozent der Daten, welche noch nicht als Modelleingabe genutzt wurden, getestet. So soll ein „Overfitting“ erkannt werden, ein Effekt, bei welchem das Modell die Trainingsdaten zu genau „lernt“ und sich an die zufälligen Schwankungen der Trainingsdaten anpasst. In Falle eines „Overfitting“ zeigt das Modell

auf den Trainingsdaten eine sehr gute Leistung, funktioniert jedoch schlecht auf neuen, unbekanntem Daten.

Gründächer machen ca. 15 bis 20 Prozent aller Dachflächen im Untersuchungsgebiet aus. Um diese seltene Klasse im Trainingsdatensatz angemessen zu berücksichtigen, erfolgt eine höhere Gewichtung der Gründächer. Ohne diese Anpassung würde das Modell primär die Mehrheitsklasse optimieren und Gründächer systematisch unterschätzen. Die Gewichtung erhöht den Einfluss seltener Fälle im Trainingsprozess, wodurch die Sensitivität gegenüber der Zielklasse „Gründach“ steigt. Alternative Verfahren umfassen beispielsweise ein „Oversampling“ der Minderheitsklasse, bei dem Gründachbeispiele dupliziert oder ein „Undersampling“ der Mehrheitsklasse, bei dem Nicht-Gründächer zufällig entfernt werden (He & Garcia 2009). In dieser Arbeit fiel die Entscheidung zugunsten einer stärkeren Gewichtung der Gründächer, da eine Manipulation der Grundlagendaten vermieden werden soll.

Für die Gewichtung wird zunächst die Objektanzahl der beiden Klassen ermittelt. Anschließend wird für die Gründach-Klasse eine Gewichtung berechnet, die dem Verhältnis der Anzahl der Nicht-Gründächer zur Anzahl der Gründächer entspricht. In den Trainingsdaten erhält jedes Gründach diese höhere Gewichtung, während alle anderen Nicht-Gründächer die Gewichtung eins beibehalten.

Anschließend erfolgt das Training eines logistischen Regressionsmodells auf Basis der Trainingsdaten. Dabei wird auf die zuvor festgelegte Gewichtung der Gründächer Bezug genommen und eine Zusammenfassung der Modellparameter ausgegeben. Im nächsten Schritt des R-Skripts werden anhand des trainierten Modells Vorhersagewahrscheinlichkeiten für das Vorliegen von Label 1 (Gründach) für die Testdaten berechnet.

Als klassentrennender Entscheidungsschwellenwert dienen zum einen ein Wert von 0,6 als strenger Cut-off, zum anderen der anhand der ROC-Kurve bestimmte Youden-Index. Zusätzlich erfolgt die Bestimmung des NDVI-Werts, der gemäß Youden-Index eine optimale Trennung ermöglicht. Auf Grundlage dieser Schwellenwerte entstehen schließlich zwei Klassifikationen der Dachflächen.

Die Ergebnisse der Klassifikation werden in einer Confusion Matrix zusammengefasst. So werden die jeweiligen Anteile für True Positive (TP), False Positive (FP), True Negative (TN) und False Negative (FN) aufgeschlüsselt.

Nachfolgend werden Accuracy, Recall, Precision, F1-Score und F2-Score für beide Klassifikationsstrategien ausgegeben. Außerdem wird die „Area Under Curve“ (AUC) ermittelt, welche die Trennschärfe des Modells unabhängig vom Schwellenwert angibt.

Der anschließende Teil des R-Skripts dient der Visualisierung der Ergebnisse. So werden ROC-Kurve, Regressionskurve mit Schwellenwert und jeweils eine Confusion Matrix für konservative und Youden-Klassifikation erstellt.

Bis hierhin wurden nur die Dachflächen innerhalb der Testdaten mit einer Klassifikation versehen. Ziel der Arbeit ist allerdings eine Vorhersage für alle Dachflächen des Untersuchungsgebiets. So wird das trainierte Modell noch einmal auf alle Dachflächen im Untersuchungsgebiet angewandt. Am Ende des Skripts erfolgt die Speicherung der Klassifikation in einer CSV-Datei im definierten Output-Ordner. Diese Datei lässt sich zur Visualisierung im ArcGIS-Projekt über die Dach-IDs verknüpfen.

5.4.2 Multivariate logistische Regression anhand des NDVI und der Bänder RGBI

Die Abläufe der multivariaten ähneln denen der univariaten Regressionsanalyse auch die verwendeten Pakete in RStudio sind dieselben. Die Eingabedaten setzen sich aus NDVI-Median und den Medianen der einzelnen spektralen Bänder Rot, Grün, Blau und Nah-Infrarot pro Dachfläche zusammen, welche im Kapitel 5.3.3 erstellt wurden. Das vollständige R-Skript der multivariaten Regressionsanalyse befindet sich in Anhang 4: RStudio Skript der multivariaten logistischen Regressionsanalyse.

Wie im Skript für die univariate Regression werden zunächst die Dateipfade zu den entsprechenden Exceldateien verknüpft und die Daten in RStudio eingelesen. Zur Erstellung des Analysedatensatzes werden die spektralen Informationen der einzelnen Dächer aus den getrennt vorliegenden Tabellen zusammengeführt. Für jeden Dachdatensatz liegen Medianwerte der spektralen Kanäle Rot, Grün, Blau, Nah-Infrarot sowie des NDVI vor. Diese Tabellen werden mit der Dach-ID schrittweise zu einem gemeinsamen Datensatz zusammengeführt, sodass pro Dach die fünf spektralen Merkmale in einer Zeile vorliegen. Gründächer werden mit dem Label 1 versehen und Nicht-Gründächer erhalten das Label 0. Anschließend erfolgt die Kombination beider Klassen zu einem Gesamtdatensatz. Dieser wird in Trainings- (70 %) und Testdaten (30 %) aufgeteilt. Zur Berücksichtigung der ungleichen Klassenverteilung im Trainingsdatensatz wird wie bei der univariaten Regression eine Gewichtung der seltenen Gründächer vorgenommen.

Auf Basis der gewichteten Eingabedaten erfolgt das Training des logistischen Regressionsmodells, welches anschließend auf die Testdaten angewendet wird. Erneut dient ein Entscheidungsschwellenwert von 0,6 als Referenz, während der Youden-Index anhand der ROC-Kurve bestimmt wird.

Für beide Klassifikationen werden Confusion Matrices erstellt, und die Evaluationsmetriken berechnet. Zur vertieften Interpretation des multivariaten logistischen Regressionsmodells wurden

zusätzlich verschiedene Visualisierungen, wie die Regressionskurve und die partiellen logistischen Kurven für jeden Prädiktor erstellt. Für die partiellen logistischen Kurven variiert jeweils eine Variable, während alle übrigen Variablen auf ihren Mittelwert fixiert bleiben. Die resultierenden Kurven ermöglichen eine vergleichende Betrachtung des Effekts der einzelnen Spektralbänder auf die vorhergesagte Gründach-Wahrscheinlichkeit.

Abschließend wird das trainierte Modell auf alle Dachflächen im Untersuchungsgebiet angewendet, um für jedes Dach eine Vorhersagewahrscheinlichkeit sowie entsprechende Klassenzuordnungen für beide Schwellenwerte zu erhalten. Die resultierenden Vorhersagen werden in einer CSV-Datei gespeichert.

5.5 Pixelbasierte Ermittlung des Grünflächenanteils auf klassifizierten Gründächern

Um den tatsächlichen Grünflächenanteil der klassifizierten Gründächer näherungsweise zu bestimmen, wird die vegetationstypische Pixelmaske aus Kapitel 5.2.4 auf die Ergebnisse der Gründachklassifizierung angewendet.

Mit dem Tool „Zonal Statistics as Table“ erfolgt in ArcGIS die Ermittlung der Summe aller vegetationstypischen Pixel je klassifizierter Gründachfläche. Anschließend verbindet die Dach-ID die Tabelle mit den klassifizierten Objekten. Dadurch lässt sich jeder Fläche eine entsprechende Pixelsumme zuordnen. Zur Berechnung der absoluten Fläche ergänzt eine zusätzliche Spalte in der Attributtabelle die notwendigen Werte, in der sich die Pixel summieren lassen. Mithilfe des Tools „Field Calculator“ lässt sich die Fläche durch Multiplikation der Pixelsumme mit $0,2 \times 0,2$ berechnen, da die Pixel eine Kantenlänge von 20 Zentimetern besitzen.

In einer weiteren Spalte in der Attributtabelle kann darauf aufbauend der Grünflächenanteil in Prozent berechnet werden. Dafür wird die berechnete absolute Grünfläche in Quadratmetern durch die Gesamtdachfläche geteilt und mit 100 multipliziert. Diese Grundlage ermöglicht eine Visualisierung des Grünflächenanteils in Prozent, woraus eine Einteilung der Gründächer abgeleitet werden kann. In Abbildung 15 wird die methodische Herleitung zur Bestimmung der Teilgrünflächen verdeutlicht.

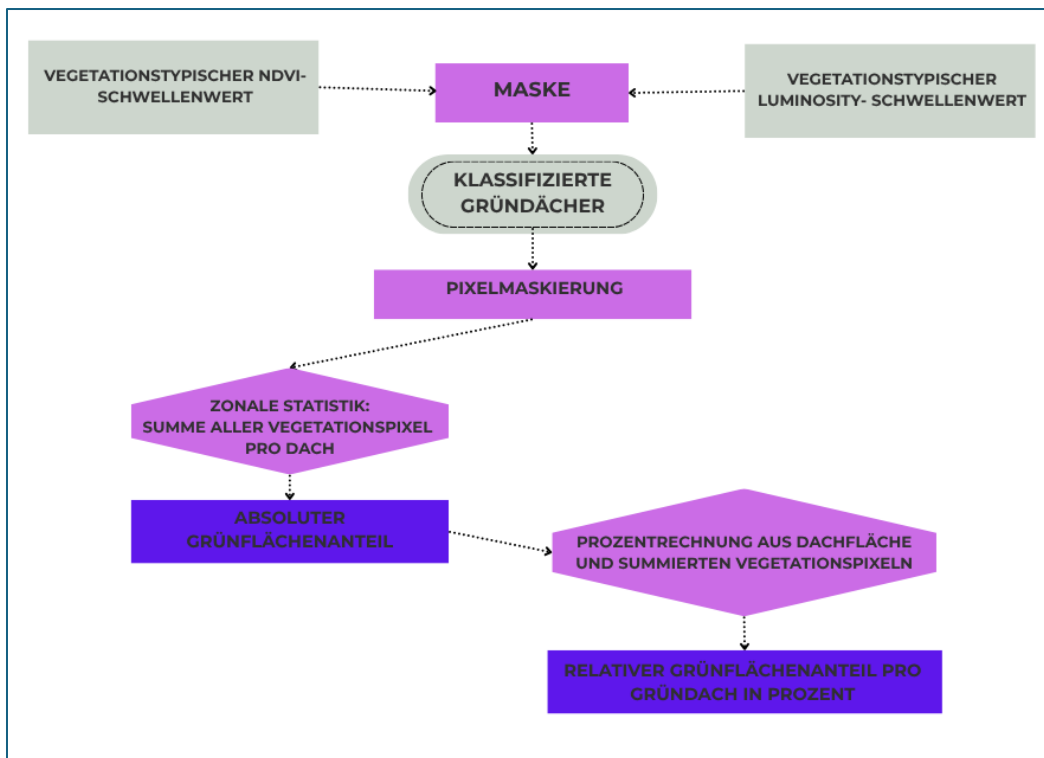


Abbildung 15: Vereinfachtes Fließschema der pixelbasierten Methodik zur näherungsweisen Ermittlung des prozentualen Grünflächenanteils, eigene Darstellung.

6 Ergebnisse

In den folgenden Unterkapiteln werden die Ergebnisse der objektbasierten logistischen Regressionsanalyse und der pixelbasierten Teilgrünflächenermittlung für das Untersuchungsgebiet dargelegt. Zur Gütebewertung der Modelle werden die im Folgenden aufgeführten Evaluationsmetriken herangezogen, welche sich an Marmy et al. (2025) orientieren.

Dabei steht *TP* für „True Positives“ und bezeichnet korrekt als Gründach identifizierte Flächen. *TN* („True Negatives“) umfasst dagegen jene Dächer, die zutreffend als Nicht-Gründächer erkannt wurden. *FN* („False Negatives“) beschreibt Flächen, die irrtümlich nicht als Gründach erkannt wurden, während *FP* („False Positives“) solche Dächer bezeichnet, die fälschlicherweise als Gründach klassifiziert wurden, obwohl sie keine sind.

- **Accuracy:** ist der Anteil der korrekt vorhergesagten Objekte an allen Objekten. *P* steht für alle Gründächer und *N* für alle Nicht-Gründächer im „Ground Truth“. Die Aussagekraft dieser Metrik kann besonders von einem ausgeprägten Klassenungleichgewicht beeinflusst werden.

$$Accuracy = \frac{TP + TN}{P + N}$$

- **Area Under the Curve (AUC):** misst die Fläche unter der Receiver-Operating-Characteristics (ROC)-Kurve, die die True-Positive-Rate (Sensitivität) gegen die False-Positive-Rate (1-Spezifität) bei allen möglichen Klassifikationsschwellenwerten stellt. Der AUC-Wert kann zwischen 0 und 1 liegen, wobei 0,5 der schlechteste Wert ist.

- **Recall:** misst, wie viele richtig-positive Objekte das Modell klassifiziert, gemessen an der Summe aus richtig-positiven und falsch-negativen Klassifizierungen („Trefferquote“). Der Recall ist mit der **Sensitivity** als True-Positive-Rate gleichzusetzen.

$$Recall = \frac{TP}{TP + FN}$$

- **Precision:** beschreibt die Anzahl der korrekt als positiv klassifizierten Ergebnisse gemessen an der Summe von True Positives und False Positives („Genauigkeit“).

$$Precision = \frac{TP}{TP + FP}$$

- **Specificity:** beschreibt die True-Negative-Rate bzw. die „Correct Rejection Rate“ gemessen an der Summe aus True Negatives und False Positives.

$$Specificity = \frac{TN}{TN + FP}$$

- **Negative Predictive Value (NPV):** beschreibt die Anzahl der korrekt als negativ klassifizierten Ergebnisse gemessen an der Summe aus „True Negatives“ und „False Negatives“.

$$NPV = \frac{TN}{TN + FN}$$

- **F1-Score:** ist das harmonische Mittel von Precision und Recall. Der F1-Score überwindet die Einschränkungen der Accuracy bei unausgeglichenen Datensätzen. Genauigkeit und Trefferquote sind gleich gewichtet.

$$F_1 = 2 * \frac{Precision * Recall}{Precision + Recall}$$

- **F2-Score:** als eine Variante des F1-Scores mit viermal stärkerer Gewichtung auf Recall.

$$F_2 = \frac{5}{\frac{4}{precision} + \frac{1}{recall}}$$

Für die Interpretation der Parameter der logistischen Regressionsmodells ist es wichtig zu verstehen, dass die Beziehung zwischen den Prädiktoren und der Eintrittswahrscheinlichkeit der Zielvariable über die so genannten Log-Odds hergestellt wird. Die Odds sind das Verhältnis der Wahrscheinlichkeit, dass ein Ereignis eintritt, zur Wahrscheinlichkeit, dass es nicht eintritt. Die Log-Odds sind der natürliche Logarithmus dieser Odds. Die Schätzung der Modellparameter erfolgt dabei mittels Maximum-Likelihood-Schätzung, wodurch jene Koeffizienten bestimmt werden, die die beobachteten Daten am wahrscheinlichsten erklären (Menard 2011).

Die Regressionskoeffizienten geben an, wie sich eine Veränderung eines Prädiktors auf diese Log-Odds auswirkt, während ihre Exponentialwerte als Odds Ratios interpretiert werden, die die relative Änderung der Chancen beschreiben (Menard 2011; Pal 2021).

In der Modellzusammenfassung der logistischen Regression werden folgende Metriken ausgegeben, deren Beschreibung sich an James et al. (2023) orientiert:

- **Koeffizienten (Estimate):** Geben an, wie stark ein Prädiktor (z. B. NDVI-Median) die Zielvariable beeinflusst. In der logistischen Regression beschreiben die Koeffizienten die Veränderung der Log-Odds. Positive Werte erhöhen die Log-Odds und damit die Eintrittswahrscheinlichkeit der Zielvariable.
- **Standardfehler (Std. Error):** Misst die Unsicherheit der geschätzten Koeffizienten.
- **z-Wert (z value):** Gibt an, wie stark sich ein Koeffizient vom Wert 0 unterscheidet, relativ zu seinem Standardfehler. Je größer der Betrag, desto stärker der Effekt.
- **p-Wert:** Zeigt, ob ein Effekt statistisch signifikant ist.
- **Intercept (Achsenabschnitt):** Beschreibt die Ausgangssituation des Modells: die Log-Odds des Ereignisses, wenn alle Prädiktoren den Wert 0 haben.
- **Null Deviance:** Maß für die Modellgüte eines Modells ohne Prädiktoren (nur mit einem konstanten Wert). Diese dient als Referenz.
- **Residual Deviance:** Maß für die Modellgüte des geschätzten Modells mit Prädiktoren. Eine deutliche Verringerung gegenüber der Null Deviance zeigt eine gute Modellanpassung.
- **AIC (Akaike Information Criterion):** Kennzahl zur Bewertung und zum Vergleich von Modellen. Berücksichtigt sowohl die Modellgüte als auch die Modellkomplexität.
- **Anzahl der Iterationen (Fisher Scoring iterations):** Gibt an, wie viele Rechenschritte das Modell benötigt hat, um eine stabile Lösung zu finden und dient als Hinweis auf die Konvergenz des Modells. Eine Konvergenz ist erreicht, wenn sich die geschätzten

Koeffizienten zwischen aufeinanderfolgenden Iterationen des Optimierungsverfahrens nicht mehr wesentlich verändern und ein Maximum der Likelihood-Funktion gefunden wurde.

6.1 Ergebnisse der univariaten logistische Regression anhand des NDVI

Für die Gewichtung (w) der seltenen Gründächer wurde ein Wert von 6,62 ermittelt, welcher in das Modelltraining eingeflossen ist. In Abbildung 16 ist die Parameterzusammenfassung des trainierten logistischen Regressionsmodells aufgeführt. Zuerst wird die Zusammensetzung des „General Linear Modells“ (glm) beschrieben, welches durch die Eingabe der NDVI-Mediane als Label und als binominal definiert ist. Zusätzlich fließt die Gewichtung (w) ein und als Eingabedaten (data) wird auf die Trainingsdaten (train) zurückgegriffen. Eine tabellarische Zusammenfassung des univariaten Regressionsmodells ist in Anhang 1 einzusehen.

```
> summary(glm_fit)
Call:
glm(formula = label ~ get(median_col), family = binomial, data = train,
     weights = w)

Coefficients:
            Estimate Std. Error z value Pr(>|z|)
(Intercept)   0.11819   0.08978    1.316   0.188
get(median_col) 88.46587   3.60305   24.553 <2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for binomial family taken to be 1)

    Null deviance: 5819.7  on 2415  degrees of freedom
Residual deviance: 1103.6  on 2414  degrees of freedom
AIC: 1147.3

Number of Fisher scoring iterations: 8
```

Abbildung 16: Screenshot der Modellzusammenfassung des univariaten logistischen Regressionsmodells, eigene Darstellung.

Das univariate logistische Regressionsmodell zeigt einen sehr starken und hochsignifikanten Zusammenhang zwischen dem NDVI-Median pro Dachfläche und der Zielvariable „Gründach“. Der geschätzte Koeffizient für den NDVI ist deutlich positiv (≈ 88.47) und statistisch hochsignifikant ($p < 2e-16$), was darauf hinweist, dass mit zunehmendem NDVI die Wahrscheinlichkeit für das Vorliegen eines Gründachs stark ansteigt.

Die deutliche Reduktion der Residual-Deviance (1103,6) im Vergleich zur Null-Deviance (5819,7) lässt darauf schließen, dass das Modell einen großen Teil der Variation im Outcome erklärt und somit eine sehr gute Anpassung an die Daten aufweist. Das AIC beträgt 1147,3 und ist im Vergleich zum multivariaten Modell zu interpretieren. Die Anzahl von acht Fisher-Scoring-Iterationen zeigt, dass das Modell regulär konvergiert ist. Insgesamt weisen die Ergebnisse darauf hin, dass der NDVI ein sehr starker Prädiktor für das Vorliegen eines Gründachs innerhalb der ausgewählten Testdaten ist.

Auch der hohe Wert für die AUC von 0,984 unterstreicht die sehr hohe Trennfähigkeit des Modells. Die Berechnung des Youden-Index als Entscheidungsschwellenwert anhand der ROC-Kurve ergibt einen Wert von 0,567.

In der ROC-Kurve in Abbildung 17 werden Sensitivity und Specificity des univariaten logistischen Modells auf Basis des NDVI-Medians gegenübergestellt. Der Kurvenverlauf liegt deutlich oberhalb der Diagonalen einer Zufallsklassifikation und verläuft steil entlang der linken oberen Ecke, wodurch die AUC maximiert wird. Die Kurve belegt die starke Klassentrennung anhand des NDVI-Medians innerhalb der Testdaten.

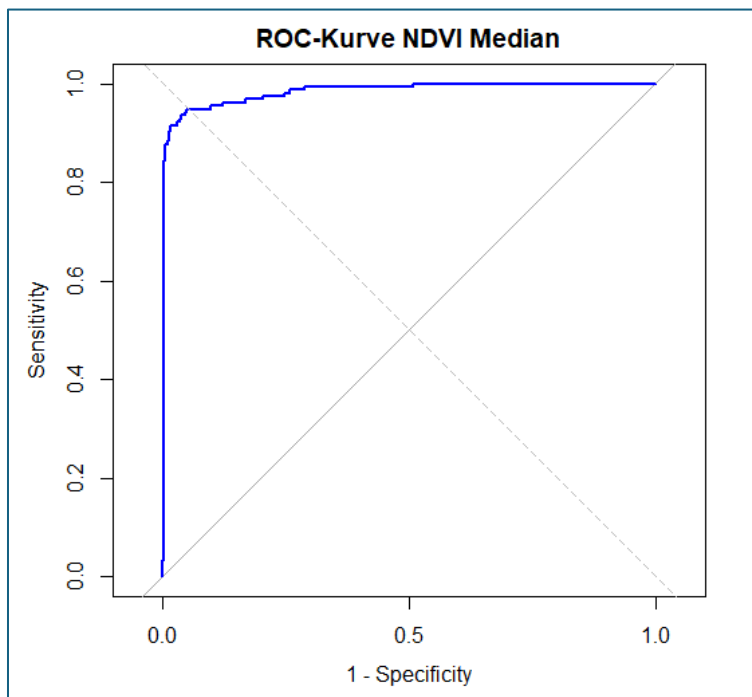


Abbildung 17: ROC-Kurve des univariaten logistischen Modells anhand des NDVI-Medians pro Dachfläche, eigene Darstellung.

Die Regressionskurve in Abbildung 18 zeigt den modellierten Zusammenhang zwischen dem NDVI-Median einer Dachfläche und der Wahrscheinlichkeit, dass es sich um ein Gründach handelt. Der steile S-förmige Verlauf verdeutlicht, dass mit steigenden NDVI-Werten die Wahrscheinlichkeit für ein Gründach stark zunimmt. Bei negativen NDVI-Werten liegt die Wahrscheinlichkeit für ein Gründach nahe Null, während sie ab einem NDVI-Wert knapp unter Null rasch ansteigt. Der eingezeichnete Youden-Schwellenwert von 0,567 markiert den optimalen Entscheidungsgrenzwert der Klassifikation, bei dem Sensitivität und Spezifität gemeinsam maximiert werden. Der Schnittpunkt dieser horizontalen Schwellenwert-Linie mit der Regressionskurve zeigt einen NDVI-Median-Wert bei 0,002. Zusätzlich sind die Datenpunkte der echten Klassen der Testdaten eingezeichnet. Es fällt auf, dass sich diese nur geringfügig überlappen.

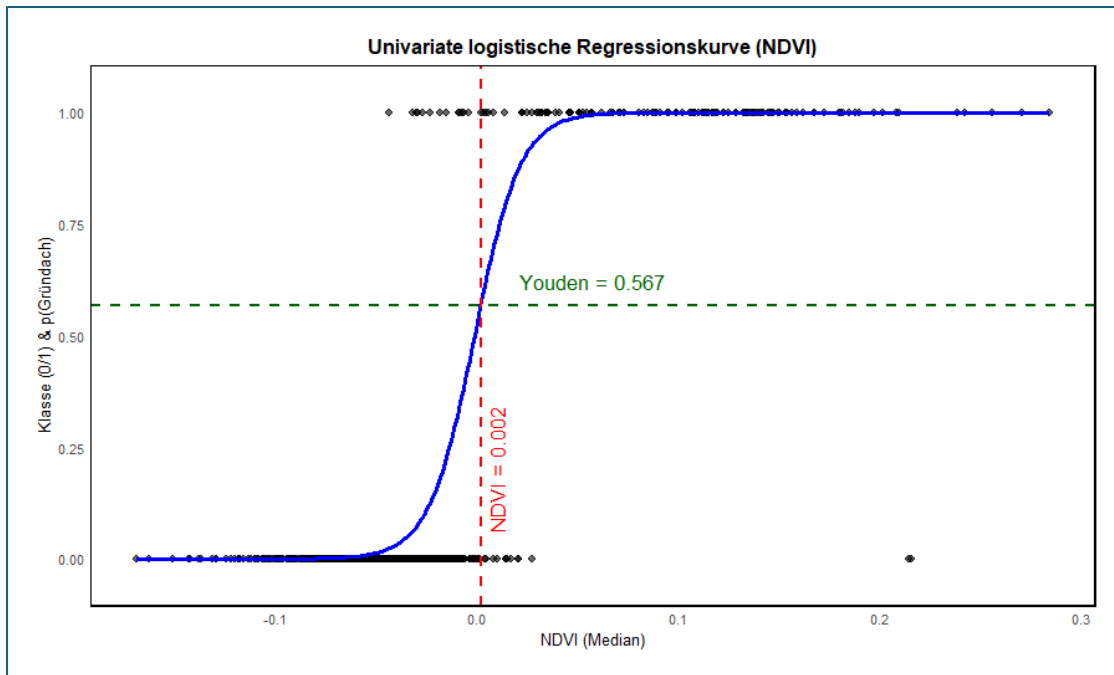


Abbildung 18: Regressionskurve der univariaten logistischen Regression anhand des NDVI-Medians pro Dachfläche mit eingezeichnetem Youden-Schwellenwert, eigene Darstellung.

In Abbildungen 19 ist die Confusion Matrix der Testdaten der univariaten logistischen Regression abhängig vom Schwellenwert 0,6 und dem Youden-Schwellenwert 0,567 dargestellt.

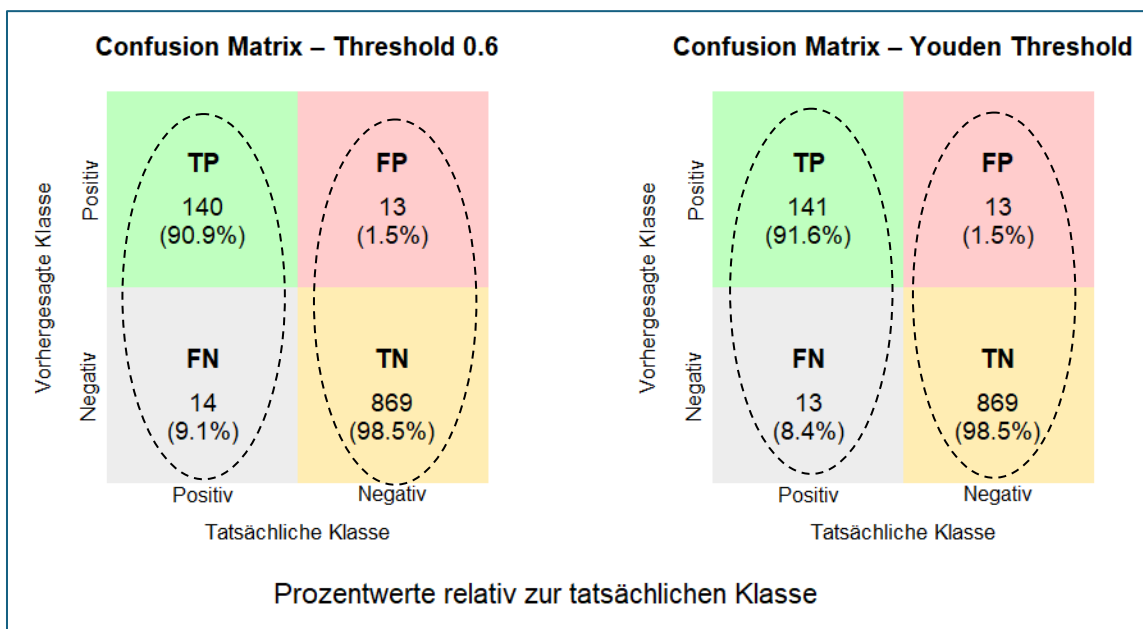


Abbildung 19: Confusion Matrix der univariaten Regressionsanalyse anhand des NDVI-Medians pro Dachfläche; jeweils anhand eines Schwellenwerts von 0,6 und dem ermittelten Youden-Schwellenwert; ergänzt sind die Prozentangaben pro Klasse relativ zur tatsächlichen Zugehörigkeit im Ground Truth; eigene Darstellung.

Zusätzlich sind die Prozentangaben pro Klasse relativ zur tatsächlichen Zugehörigkeit im Ground Truth angegeben. In der Testdaten-Klassifikation anhand des ermittelten Youden-Schwellenwerts wurden

91,6 Prozent der tatsächlichen Gründächer auch als solche erkannt, 8,4 Prozent hingegen als falsch-negativ übersehen. 98,5 Prozent der tatsächlichen Nicht-Gründächer sind richtig klassifiziert, 1,5 Prozent wurden fälschlicherweise als Gründächer klassifiziert und 8,4 % der tatsächlichen Gründächer nicht als solche erkannt. Die Ergebnisse zwischen der Klassifikation nach Youden-Schwellenwert und einem Schwellenwert von 0,6 unterscheiden sich nur geringfügig.

Betrachtet man die Anteile relativ zur Vorhersageklasse des Modells klassifiziert nach Youden-Index, so ergibt sich eine Aufteilung von 91,6 Prozent richtig-positiv klassifizierten im Verhältnis zu 8,4 Prozent falsch-positiv klassifizierten Dächern. 1,5 Prozent der Dächer wurden falsch-negativ und 98,5 Prozent als richtig-negativ zugeordnet.

In der Validierung anhand der Testdaten zeichnet sich das Modell durch eine hohe Genauigkeit (Precision von 0,91) und Trefferquote (Recall von 0,91) aus. Mit einer Accuracy von 0,97 kann ein hoher Anteil an richtig vorhergesagten Beispielen in der Klassifikation vorgewiesen werden. Die Specificity liegt bei 0,98, der F1- und F2-Score bei 0,91. Die entsprechenden Modellwerte sind in Tabelle 3 zusammengefasst.

Tabelle 3: Zusammenfassung der Evaluationsmetriken des univariaten logistischen Regressionsmodells.

	Univariate logistische Regression	
Gewichtung der seltenen Gründächer	6,62	
AUC	0.984	
Klassifikation anhand	Schwellenwert 0,6	Youden- Schwellenwert 0,567
Accuracy	0,974	0,975
Recall/Sensitivity	0,909	0,915
Precision	0,915	0,915
Specificity	0,985	0,985
F1	0,912	0,915
F2	0,910	0,915

Die bisherigen Ergebnisse beziehen sich auf die Modelleistung anhand der aufbereiteten Trainings- und Testdaten. Mit Hilfe des trainierten Modells und dem bestimmten Youden-Index von 0,567 werden im Anschluss noch einmal alle Dachflächen im Untersuchungsgebiet ohne Vorauswahl klassifiziert. In Abbildung 20 ist ein beispielhafter Ausschnitt dieser Klassifikation dargestellt. Zusätzlich sind die Umrisse der ursprünglichen Kartierungen eingezeichnet, sodass optisch

abgeglichen werden kann, welche Dächer als Gründach kartiert und welche auch als solche in der Gesamtklassifikation erkannt wurden. Es muss beachtet werden, dass die ursprüngliche Kartierung keinen Anspruch auf Vollständigkeit hat. In der optischen Kontrolle zeigt sich, dass es Differenzen zwischen Kartierung und Klassifizierung gibt. Sowohl in Form von klassifizierten Gründächern, welche sich als Nicht-Gründächer erweisen, als auch in Form von unerkannten Gründächern, welche aber in der Gründach-Kartierung markiert sind. Diese gehäuften Differenzen stehen im Gegensatz zu der sehr hohen Klassifikationsgenauigkeit, welche durch die Modellparameter ausgewiesen wird. Es ist davon auszugehen, dass die hohe Precision bei einer Modellanwendung auf alle Dachflächen nicht aufrechterhalten werden kann. Eine Validierung dieses Verhältnisses schließt an die Ergebnisse der multivariaten Regressionsanalyse an.

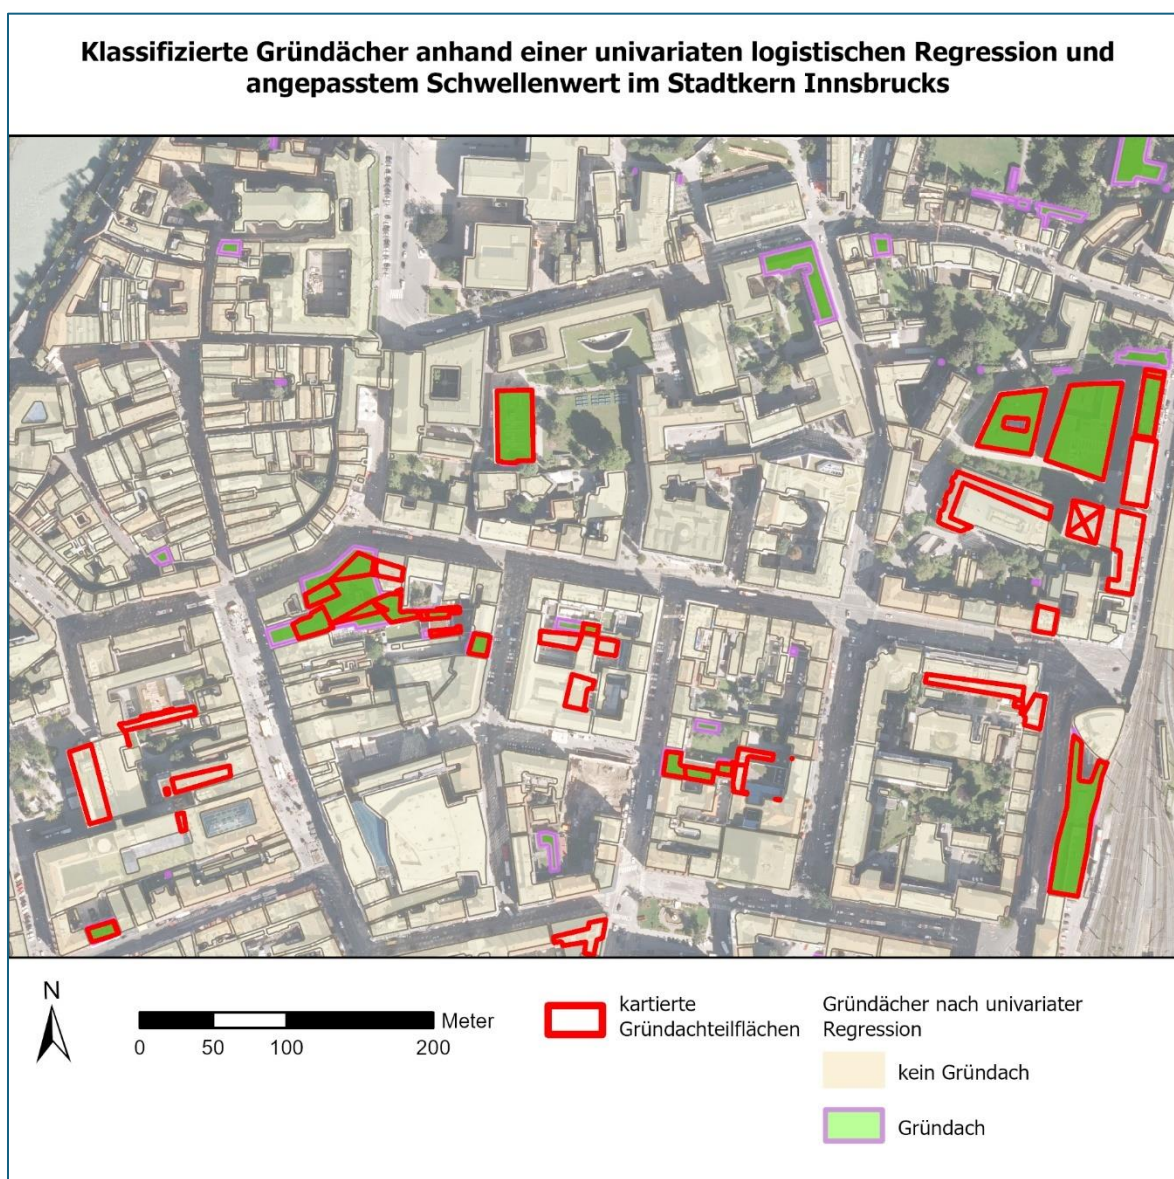


Abbildung 20: Beispielhafter Ausschnitt der klassifizierten Gründächer anhand der univariaten logistischen Regression und dem Youden-Schwellenwert von 0,567; zusätzlich sind die ursprünglichen Gründachkartierungen (rot) eingezeichnet, eigene Darstellung.

6.2 Ergebnisse der multivariaten logistischen Regression anhand NDVI und der Bänder RGBI

Auch im multivariaten Regressionsmodell beträgt die Gewichtung der seltenen Gründachklasse 6,62, da sich die absolute Anzahl der Dachflächen nicht verändert. In Abbildung 21 ist die Parameterzusammenfassung des multivariaten logistischen Regressionsmodells aufgeführt. Anders als im univariaten Ansatz setzt sich das Modell aus den fünf Parametern der RGBI-Mediane und dem NDVI-Median pro Dachfläche zusammen. Eine tabellarische Zusammenfassung des multivariaten Regressionsmodells ist in Anhang 1 einzusehen.

```
> summary(glm_fit)

Call:
glm(formula = label ~ R_med + G_med + B_med + NIR_med + NDVI_med,
    family = binomial, data = train, weights = w)

Coefficients:
            Estimate Std. Error z value Pr(>|z|)
(Intercept)  2.424e+00  6.984e-01   3.471 0.000518 ***
R_med       -1.407e-03  1.073e-04 -13.115 < 2e-16 ***
G_med        5.962e-04  1.916e-04   3.112 0.001856 **
B_med       -5.655e-04  1.419e-04 -3.986 6.71e-05 ***
NIR_med      1.273e-03  1.016e-04  12.522 < 2e-16 ***
NDVI_med    -2.202e+01  7.803e+00 -2.822 0.004771 **
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for binomial family taken to be 1)

    Null deviance: 5819.66  on 2415  degrees of freedom
Residual deviance:  556.24  on 2410  degrees of freedom
AIC: 589.08

Number of Fisher Scoring iterations: 8
```

Abbildung 21: Screenshot der Modellzusammenfassung des multivariaten logistischen Regressionsmodells, eigene Darstellung.

Das multivariate logistische Regressionsmodell zeigt ebenfalls eine sehr gute Modellanpassung und liefert differenzierte Einblicke in die Bedeutung der einzelnen Prädiktoren. Alle Prädiktoren weisen statistisch signifikante Effekte auf die Zielvariable auf, wobei insbesondere Rot ($p < 2e-16$) und Nah-Infrarot ($p < 2e-16$) sehr starke Zusammenhänge zeigen. Der negative Koeffizient von Rot und der positive Koeffizient von Nah-Infrarot entsprechen den erwarteten spektralen Eigenschaften von Vegetation, die typischerweise eine geringe Reflexion im roten und eine hohe Reflexion im nahinfraroten Bereich aufweist. Auch die Parameter Grün ($p = 0,001856$; positiver Koeffizient) und Blau ($p = 6,71e-5$; negativer Koeffizient) tragen signifikant zur Modellvorhersage bei, auch wenn ihre Effektstärken geringer ausfallen.

Auffällig ist, dass der NDVI ($p = 0,004771$), anders als im univariaten Modell einen negativen Koeffizienten aufweist. Die Umkehr des Vorzeichens deutet darauf hin, dass ein erheblicher Teil der durch den NDVI begründeten Varianz bereits durch die einzelnen Spektralbänder erklärt wird. Da der NDVI selbst aus dem Verhältnis von Nah-Infrarot und Rot berechnet wird, ist eine hohe

Multikollinearität mit diesen Variablen zu erwarten. Die veränderte Wirkung des NDVI im multivariaten Kontext ist daher als Hinweis auf redundante Information und Interdependenzen zwischen den Prädiktoren zu interpretieren.

Die Modellgüte verbessert sich gegenüber dem Nullmodell deutlich, was sich im Verhältnis der Null Deviance (5819,66) zur Residual Deviance (556,24) zeigt. Das AIC von 589,08 ist im Vergleich zum univariaten Modell (AIC = 1.147,3) deutlich geringer, was auf eine bessere Modellanpassung hinweist. Die Anzahl von acht Fisher-Scoring-Iterationen zeigt, dass das Modell stabil konvergiert.

Insgesamt verdeutlichen die Ergebnisse, dass die spektralen Einzelbänder eine hohe vorhersagende Relevanz besitzen und eine noch bessere Klassifikation als das univariate Modell ermöglichen.

In Abbildung 22 ist die ROC-Kurve des multivariaten Modells abgebildet. Der Kurvenverlauf liegt ebenfalls deutlich oberhalb der Diagonalen (Zufallsklassifikation) mit einer AUC von 0,995. Im Vergleich zu 0,919 im univariaten Modell ist eine geringfügige Steigerung zu erkennen. Es wurde ein Youden-Schwellenwert von 0,476 berechnet.

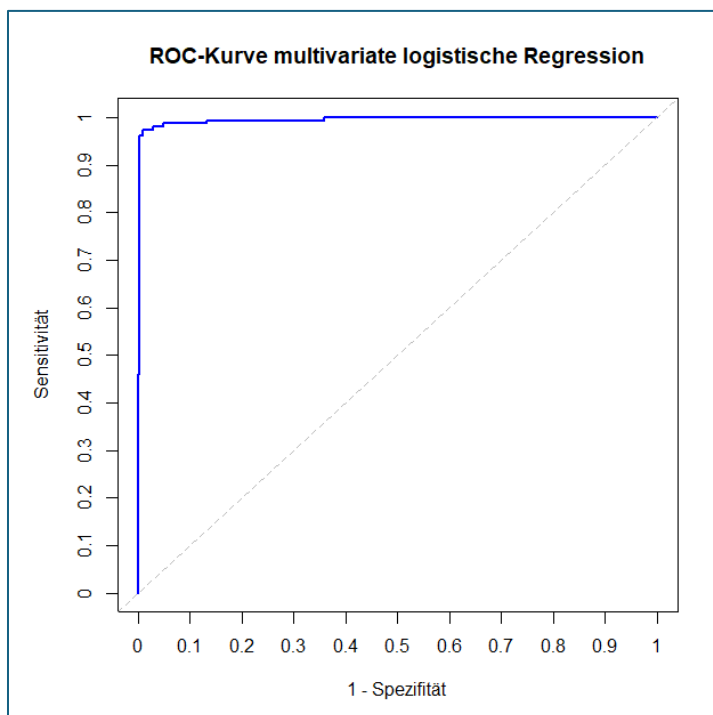


Abbildung 22: ROC-Kurve des multivariaten logistischen Modells, eigene Darstellung.

In Abbildung 23 ist die Regressionskurve des multivariaten Modells dargestellt, wobei die Eingabevariablen in einem Modell-Score zusammengefasst wurden, welcher als gewichtete Summe der Variablen (R, G, B, NIR, NDVI) und dem Intercept berechnet wird. Auch hier zeigt der S-förmige Kurvenverlauf, dass mit steigendem Modell-Score die Wahrscheinlichkeit für das Vorliegen eines

Gründachs steigt. Bei einem Modell-Score knapp unter Null (-0,1) erreicht die Regressionskurve den Youden-Schwellenwert von 0,476. Zusätzlich sind die Datenpunkte der tatsächlichen Klassen der Testdaten eingezeichnet. Wie in Abbildung 18 der univariaten Regressionskurve liegt die große Mehrheit der Datenpunkte in einem Wertebereich, welcher eindeutig einer der Klassen zugeordnet werden kann, nur wenige Punkte befinden sich im Übergangsbereich.

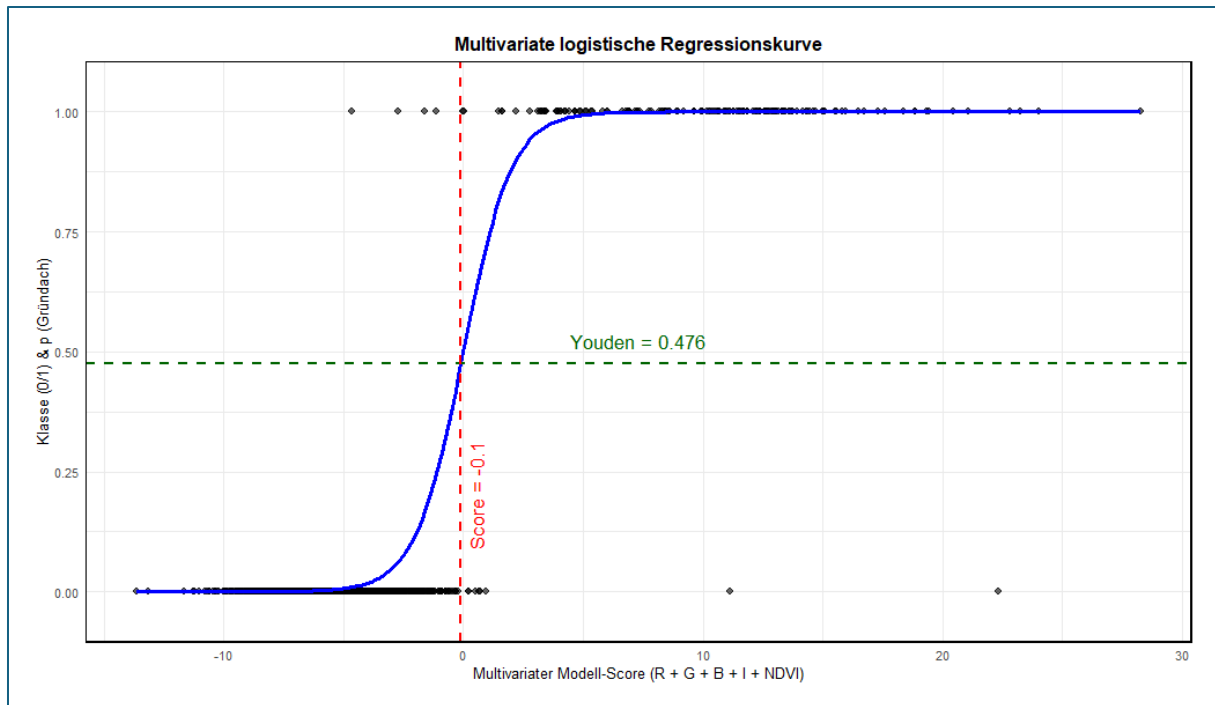


Abbildung 23: Regressionskurve des multivariaten Regressionsmodells mit eingezeichnetem Youden-Schwellenwert bei 0,476 und dem zugehörigen Modell-Score von -0,1, eigene Darstellung.

Abbildung 24 zeigt die partiellen logistischen Kurven für die vier Spektralbänder und den NDVI als Prädiktoren der Gründach-Wahrscheinlichkeit in Abhängigkeit zu den normalisierten Medianwerten. Jede Kurve beschreibt, wie stark sich die vorhergesagte Wahrscheinlichkeit für die Zielklasse Gründach verändert, wenn jeweils nur dieser eine Prädiktor variiert wird, während die anderen konstant gehalten werden. Die steigenden Kurven von Grün und Nah-Infrarot zeigen einen positiven Zusammenhang von steigenden Medianwerten und Zunahme der Gründach-Wahrscheinlichkeit. Die fallenden Kurven von Blau und Rot verdeutlichen einen gegenteiligen Effekt. Je höher die Roten und Blauen Medianwerte einer Dachfläche sind, desto niedriger ist die Wahrscheinlichkeit für das Vorliegen eines Gründachs. Der Verlauf der partiellen NDVI-Kurve ist als Residualeffekt zu verstehen, da ein Großteil der im NDVI enthaltenen Information bereits durch die Rote und Nah-Infrarote Variable im Modell erklärt wird, wodurch dem NDVI ein scheinbar gegenläufiger Einfluss zugeschrieben wird.




Abbildung 24: Partielle Regressionskurven der einzelnen Eingabeparameter der Bänder RGBI und des NDVI anhand der normalisierten Medianwerte, eigene Darstellung.

Die Anwendung des trainierten Modells auf die Testdaten ermöglicht wiederum die Validierung der Modellperformance. In Abbildung 26 ist die Confusion Matrix der Testdaten der multivariaten logistischen Regression abhängig vom Schwellenwert 0,6 und dem Youden-Schwellenwert 0,476 dargestellt.




Abbildung 25: Confusion Matrix der multivariaten Regressionsanalyse anhand der RGBI- und NDVI-Mediane pro Dachfläche; jeweils anhand eines Schwellenwerts von 0,6 und des ermittelten Youden-Schwellenwerts von 0,476; ergänzt sind die Prozentangaben relativ zur tatsächlichen Klasse, eigene Darstellung.

Zusätzlich sind die Prozentanteile relativ zur tatsächlichen Klasse angegeben. Im Fall des multivariaten Klassifikation anhand Youden-Schwellenwert werden 97,4 Prozent der tatsächlichen Gründächer auch als solche erkannt und 2,6 Prozent der Gründächer werden übersehen. 99,1 Prozent der Nicht-Gründächer werden als solche klassifiziert und 0,9 Prozent falsch als Gründach ausgewiesen.

Betrachtet man die Anteile relativ zur Vorhersageklasse so erhält man 94,9 Prozent richtig-positive und 5,1 Prozent falsch-positive Zuweisungen. In der Klasse der Nicht-Gründächer sind es 99,5 Prozent richtig-negative und 0,5 Prozent falsch-negative Klassifikationen.

In der Validierung anhand der Testdaten zeichnet sich das multivariate Modell durch eine noch höhere Genauigkeit (Precision von 0,96) und Trefferquote (Recall von 0,96) als das univariate Modell aus. Mit einer Accuracy von 0,98 kann ein sehr hoher Anteil an richtig vorhergesagten Beispielen in der Klassifikation vorgewiesen werden. Die Specificity liegt bei 0,99, der F1- und F2-Score bei 0,96. Die entsprechenden Modellwerte sind in Tabelle 4 zusammengefasst.

Tabelle 4: Zusammenfassung der Evaluationsmetriken des multivariaten logistischen Regressionsmodells.

	Multivariate Regression	
Gewichtung der seltenen Gründächer	6,62	
AUC	0,995	
Klassifikation anhand	Schwellenwert 0,6	Youden- Schwellenwert 0,476
Accuracy	0,988	0,988
Recall/Sensitivity	0,961	0,974
Precision	0,961	0,949
Specificity	0,993	0,991
F1	0,961	0,961
F2	0,961	0,969

Diese sehr hohen Modellgüten beziehen sich auf den aufbereiteten Modelleingabedatensatz. Mit Hilfe des trainierten multivariaten Modells und dem bestimmten Youden-Index von 0,476 werden im Anschluss noch einmal alle Dachflächen des Untersuchungsgebiets ohne Vorauswahl klassifiziert. In Abbildung 27 ist ein beispielhafter Ausschnitt dieser Klassifikation dargestellt. Hierbei sind nun auch weniger eindeutig zuzuordnende Dächer innbegriffen. Zusätzlich sind die Umrisse der ursprünglichen Kartierungen eingezeichnet. Vergleichend zur univariaten Klassifikation zeigt sich in der visuellen

Kontrolle, dass einige Dachflächen in diesem Fall treffender klassifiziert wurden. Aber auch hier ergeben sich Differenzen zwischen Kartierung und Klassifikation, welche der hohen Modellgenauigkeit widersprechen und in der anschließenden Validierung der Klassifikation aller Dachflächen quantifiziert werden.

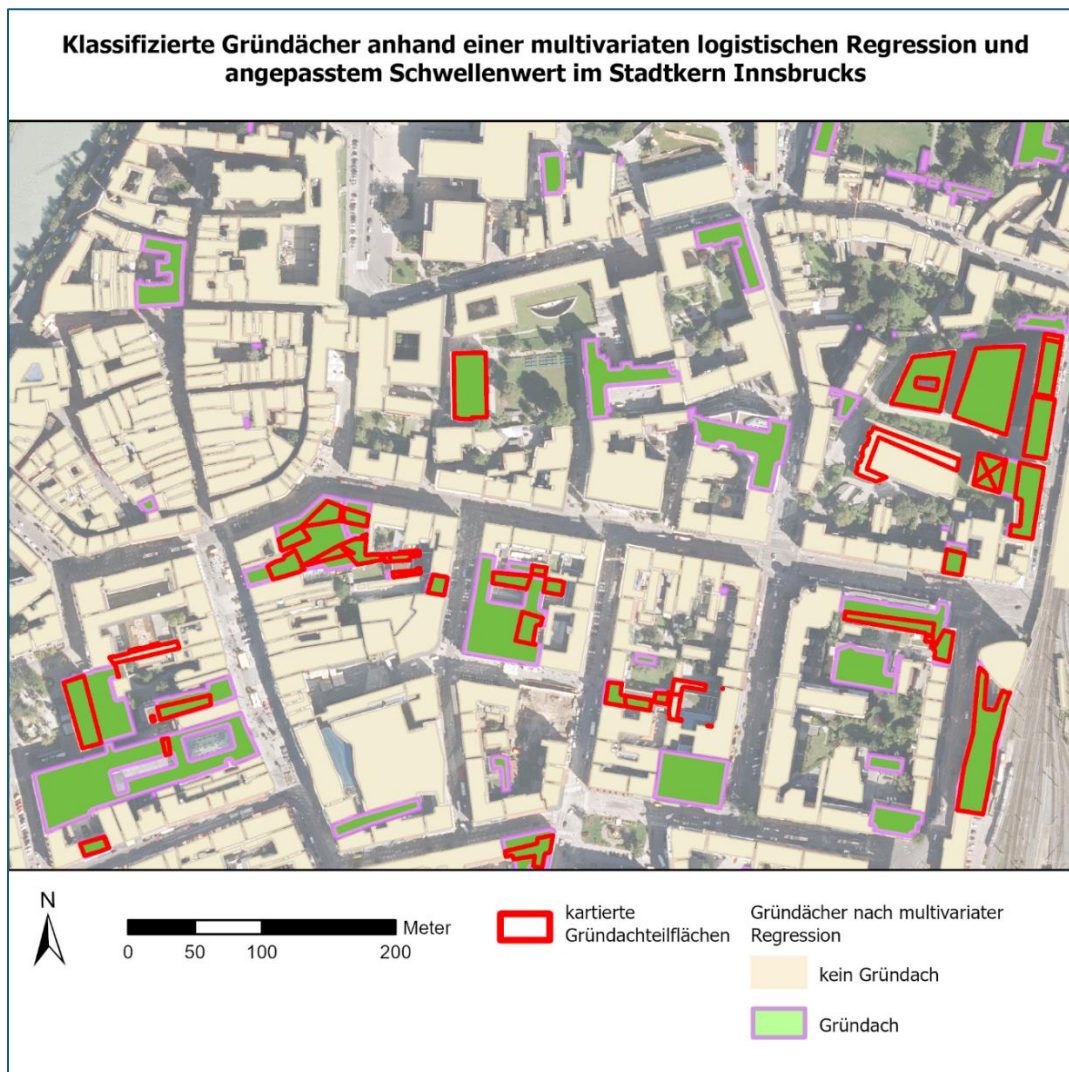


Abbildung 26: Beispielhafter Ausschnitt der klassifizierten Gründächer anhand einer multivariaten logistischen Regression und dem Youden-Schwellenwert von 0,476; zusätzlich sind die ursprünglichen Gründachkartierungen eingezeichnet, eigene Darstellung.

Für die bessere Vergleichbarkeit werden in Tabelle 5 die Evaluationsparameter der univariaten und multivariaten Regression mit den verschiedenen Schwellenwerten noch einmal gegenübergestellt. In fast allen Metriken kann eine Verbesserung des multivariaten gegenüber dem univariaten Regressionsmodells beobachtet werden. Die Nutzung von diversen Eingabeparametern deutet demnach auf eine bessere Modelleleistung hin.

Tabelle 5: Gegenüberstellung der Evaluationsmetriken von univariatem und multivariatem Modelllauf.

	Univariate Regression		Multivariate Regression	
Gewichtung der seltenen Gründächer	6,62			
AUC	0,984		0,995	
Klassifikation anhand	Schwellenwert 0,6	Youden-Schwellenwert 0,567	Schwellenwert 0,6	Youden-Schwellenwert 0,476
Accuracy	0,974	0,975	0,988	0,988
Recall/Sensitivity	0,909	0,915	0,961	0,974
Precision	0,915	0,915	0,961	0,949
Specificity	0,985	0,985	0,993	0,991
F1	0,912	0,915	0,961	0,961
F2	0,910	0,915	0,961	0,969
Modellanwendung auf alle Dachflächen im Untersuchungsgebiet:				
Absolute Anzahl der als Gründach klassifizierten Dächer im Untersuchungsgebiet	2450 von 12103 ~ 20 % Gründächer im Untersuchungsgebiet	2570 von 12103 ~ 21 % Gründächer im Untersuchungsgebiet	2338 von 12103 ~ 19 % Gründächer im Untersuchungsgebiet	2658 von 12103 ~ 21 % Gründächer im Untersuchungsgebiet

6.3 Validierung der Klassifikation aller Dachflächen

Die Eingabedaten, mit welchen das logistische Regressionsmodell trainiert wurde, sind sehr bereinigt und eindeutig einer Klasse zuzuordnen. Anhand der Testdaten zeigen die Modelle außerordentlich gute Evaluationsmetriken, eine hohe Precision und einen hohen Recall. Bei der Modellanwendung auf alle Dächer des Untersuchungsgebiets werden die beiden Modelle jedoch auf einen sehr heterogenen Datensatz angewendet. Die Dachflächen sind weniger einheitlich in ihren Eigenschaften und bestehen oft aus einem Mosaik von unterschiedlichen Oberflächen, was sich in der Medianbildung widerspiegelt. Im Falle dieser heterogenen Dachflächen ist die Wahrscheinlichkeit für das Vorliegen einer Gründachfläche weniger abgrenzungsstark und in der optischen Kontrolle der Klassifikationsvisualisierung zeigen sich vielfältige Differenzen zwischen Kartierung und Klassifikation. Daher ist eine erneute Validierung der Gesamtklassifikation nötig, um zu prüfen, wie zuverlässig das trainierte Modell bei nicht-abgegrenzten heterogenen Eingabedaten funktioniert.

Für die Validierung wurden die Ergebnisse der multivariaten Klassifikation anhand Youden-Index herangezogen und 250 Gründächer und 250 Nicht-Gründächer zufällig aus dem Datensatz der Klassifikation ausgewählt. Diese wurden händisch anhand des Orthofotos überprüft. Für die positive Zuweisung eines Gründachs wurde sich ein Richtwert von mindestens 10 Prozent Grünflächenanteil am gesamten Dachpolygon orientiert.

In der Confusion Matrix in Abbildung 28 sind die Ergebnisse der Validierung aufgeteilt. Bei nur 127 der 250 ausgewählten klassifizierten Gründächer handelt es sich tatsächlich um ein Gründach. 123 der Dächer sind falsch-positiv zugeordnet. In der Klasse der Nicht-Gründächer funktioniert die Zuweisung verlässlicher und nur eines der 250 klassifizierte Nicht-Gründächer wurde falsch zugeordnet. Die restlichen 249 Nicht-Gründächer wurden richtig als solche klassifiziert.

Es zeigt sich, dass die hohe Precision, welche sich bei den Testdaten zeigte, nicht aufrechterhalten werden kann. In der Gesamtvalidierung tritt eine hohe Anzahl an falsch-positiven Klassifizierungen auf, was durch die niedrigen Precision von 0,51 verdeutlicht wird. Der Recall bleibt weiterhin hoch (0,99). Nur in einem Fall wird ein tatsächliches Gründach als Nicht-Gründach klassifiziert (False-Negative FN). Dies wird durch ein sehr hohes Negative Predictive Value von 0,99 verdeutlicht. Aus den Werten der Confusion Matrix ergibt sich eine Accuracy von 0,752. Dieser Wert wird durch die hohe Zahl an richtig-negativen Klassifizierungen gestützt.

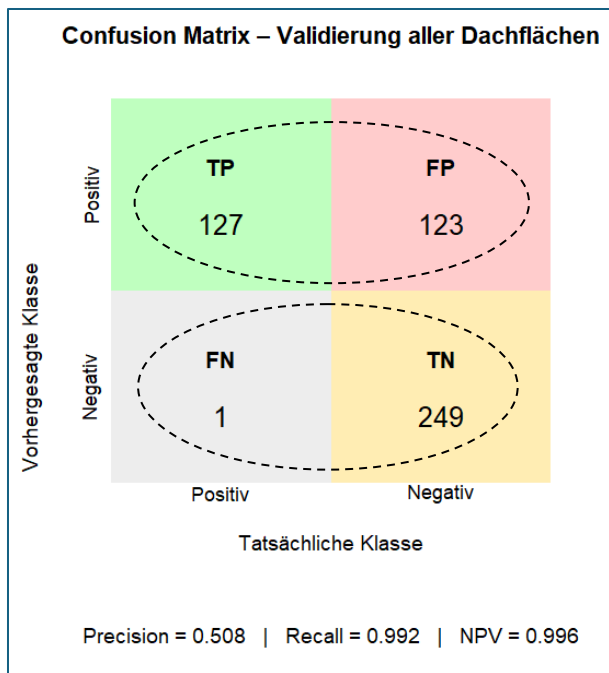


Abbildung 27: Confusion Matrix zur Validierung der multivariaten Klassifikation und Youden-Index aller Dachflächen im Untersuchungsgebiet, eigene Darstellung.

Die Validierung bestätigt den Verdacht, dass das anhand von vorausgewählten Daten trainierte Modell nicht die gleiche Klassifikationsleistung auf einem heterogenen Datensatz bringt. Bei dem Klassifikationsversuch aller Dachflächen muss mit Limitationen durch Fehlerquellen gerechnet werden. Im Zuge des Abgleichs der Dach-Klassifikation mit dem zugrunde liegenden Orthofoto wurden Fehlerquellen wie die Überschattung durch Bäume, tief verschattete Bildbereiche, Verkippungseffekte und die Fehlklassifikation von manchen Ziegeldächern sichtbar.

6.4 Ergebnisse des pixelbasierten Grünflächenanteils auf klassifizierten Gründächern

Anhand des multivariaten Regressionsmodells mit Youden-Schwellenwert wurden 2.658 Gründächern extrahiert. Um diese klassifizierten Gründächer auf ihre Qualität im Sinne des Grünflächenanteils hin zu untersuchen, wird wie in Kapitel 5.5 beschrieben, eine Untersuchung der vegetationstypischen Pixel pro Dachfläche vorgenommen. So kann eine prozentuale Abstufung des Grünflächenanteils visualisiert werden. In Tabelle 6 ist die Verteilung der absoluten Dachflächenanzahl nach prozentualem Grünflächenanteil pro Gründach aufgelistet.

Tabelle 6: Absolute Dachflächenzahl nach prozentualem Grünflächenanteil basierend auf der multivariaten Klassifikation anhand Youden-Schwellenwert.

Grünflächenanteil in Prozent	Absolute Dachflächenzahl entsprechend der multivariaten Klassifikation mit Youden-Schwellenwert
0 – 20	249
21 – 40	474
41 – 60	617
61 – 80	457
81 – 100	798
> 100	7
<Null>	56
	von insgesamt 2658 klassifizierten Gründächern

Die meisten klassifizierten Gründachflächen (798) verfügen demnach über einen hohen Grünflächenanteil zwischen 81 und 100 Prozent. Dies weist darauf hin, dass ein großer Teil der untersuchten Dächer eine flächenhafte Vegetationsbedeckung aufweist. An zweiter Stelle stehen 617 Objekte mit einem Anteil zwischen 41 und 60 Prozent, was auf eine mittlere Ausprägung der Begrünung hindeutet. Weitere 474 Dächer entfallen auf die Kategorie von 21 bis 40 Prozent, während 457 Flächen einen Anteil zwischen 61 und 80 Prozent erreichen. Deutlich seltener sind Objekte mit sehr geringer Bedeckung von 0 bis 20 Prozent (249 Fälle).

Sieben der 2.658 Dächer weisen einen Grünflächenanteil von über 100 Prozent auf. Diese Dachflächen haben eine recht kleine Fläche zwischen 4 und 33 Quadratmetern und sind besonders verschattet oder von Bäumen überwachsen. Der Grünflächenanteil kann hier größer als 100 Prozent sein, da die Grünfläche auf Pixelebene und die Dachfläche anhand der Vektordaten berechnet wird. Durch den Verschnitt kann die Fläche der dem Dach zugewiesenen Pixel größer sein, als die

Dachfläche selbst, sodass der errechnete Gründachflächenanteil leicht über 100 Prozent liegen kann. 56 Dachflächen verfügen über keine vegetationstypischen Pixel und haben demnach keinen Grünflächenanteil. In diesem Fall kann ein Teil der falsch-positiven Klassifikationen herausgefiltert werden. Insgesamt zeigt sich eine klare Konzentration im mittleren bis hohen Bereich der Vegetationsanteile. Dies spricht dafür, dass die Mehrheit der erfassten Dächer über eine ausgeprägte Begrünung verfügt.

In Abbildung 29 können in einem beispielhaften Ausschnitt die Abstufungen des prozentualen Grünflächenanteils pro klassifizierter Gründachfläche nachvollzogen werden. Zusätzlich sind die ursprünglichen Kartierungen in blau eingezeichnet.

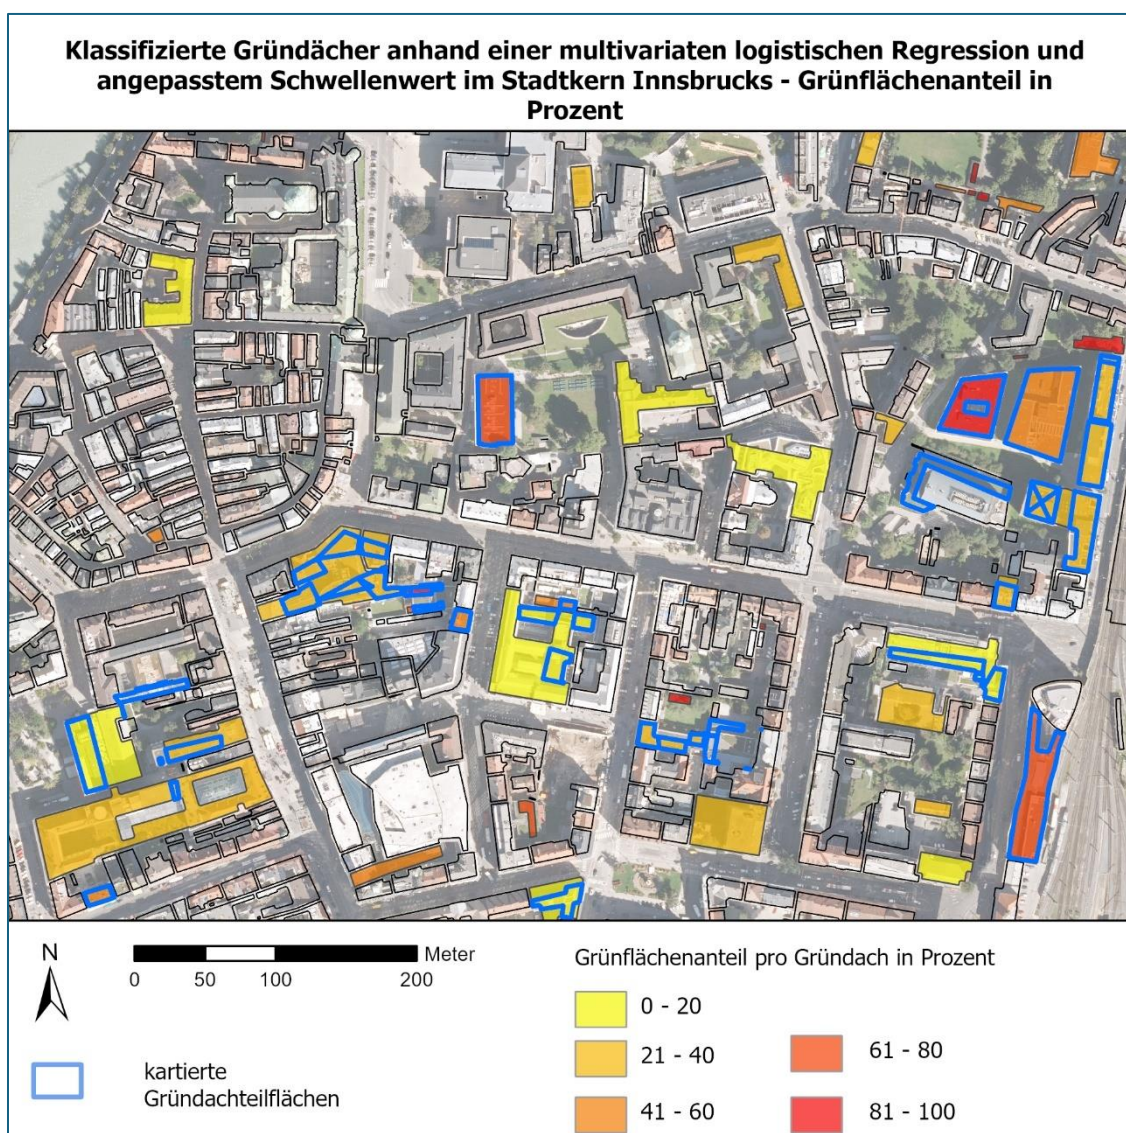


Abbildung 28: Klassifizierte Gründächer anhand der multivariaten logistischen Regression mit einem Youden-Index von 0,476; klassifiziert anhand ihres Grünflächenanteils in Prozent; zusätzlich blau eingezeichnet sind die ursprünglichen Gründachkartierungen zum Abgleich, eigene Darstellung.

Abbildung 30 soll noch einmal verdeutlichen wie die vegetationstypische „Pixel-Maske“ (blau), kombiniert aus Luminosity und NDVI die Vegetations-Pixel von anderen Materialien abgrenzt. Auf den klassifizierten Dachflächen werden einzelne Fenster und Dachaufbauten eindeutig ausgespart. Im visuellen Abgleich sind auf Dächern mit einem niedrigen prozentualen Grünflächenanteil entsprechend wenige vegetationstypische Pixel zu erkennen.

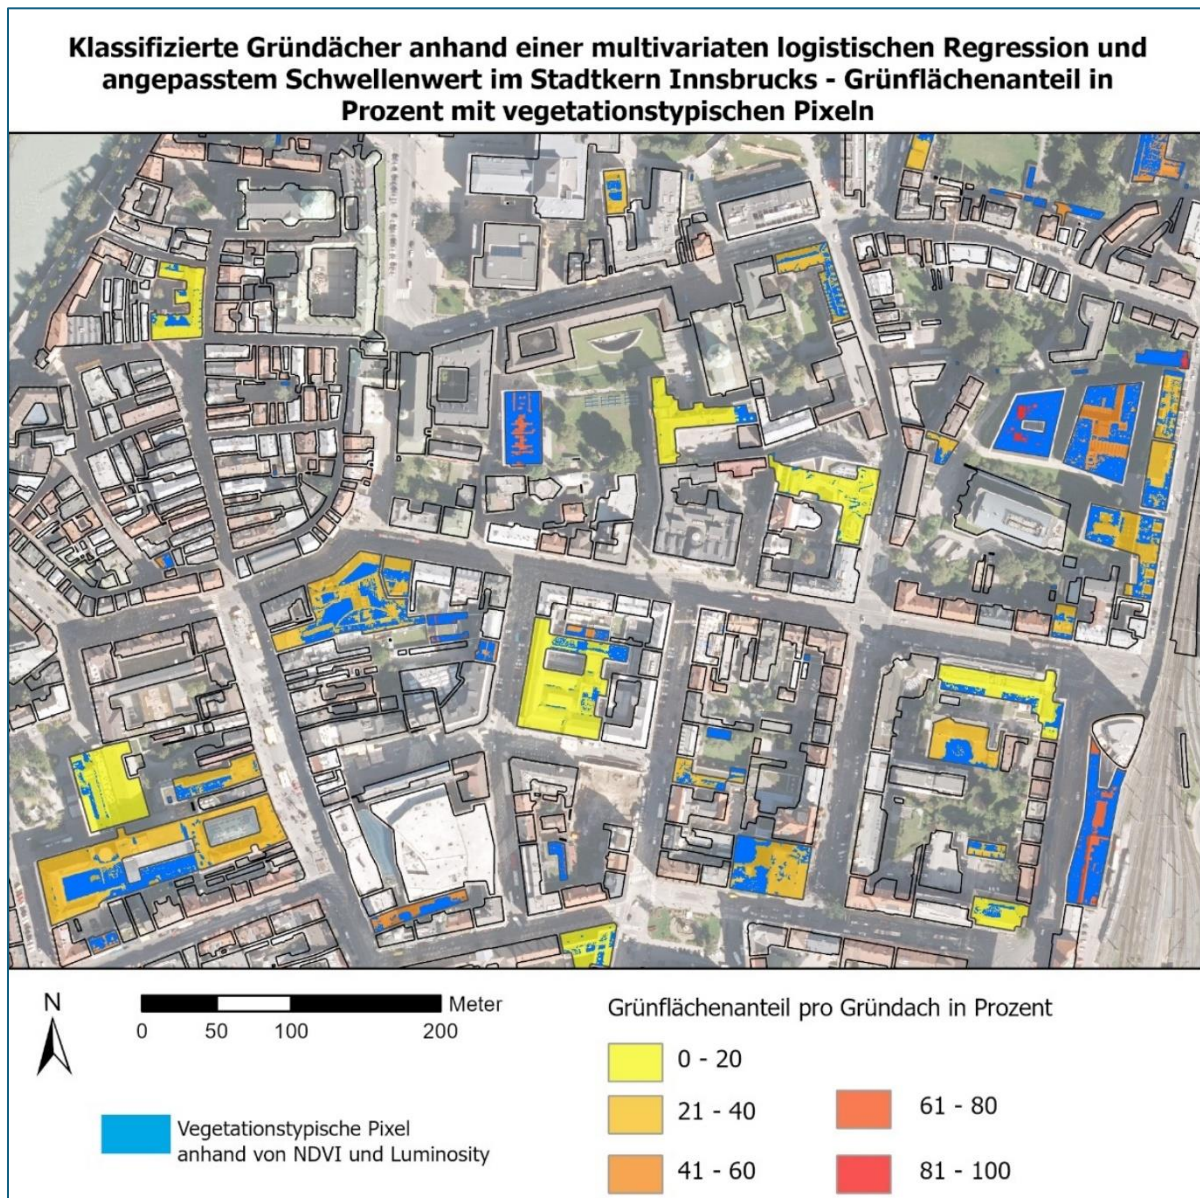


Abbildung 29: Klassifizierte Gründächer anhand einer multivariaten logistischen Regression mit einem Entscheidungsschwellenwert von 0,476; klassifiziert anhand ihres Grünflächenanteils in Prozent, überlagert mit der vegetationstypischen Pixel-Maske aus NDVI und Luminosity, eigene Darstellung.

7 Diskussion

Ein signifikanter Anteil des Arbeitsaufwands für die Modelleingabe der Regressionsanalyse entfiel auf die Aufbereitung und Bereinigung der Grundlagendaten. Zum einen mussten die kartierten Gründachteilflächen mit den amtlichen Gebäudeumringen verschnitten und händisch sortiert werden, zum anderen wurde ein Datensatz für die Nicht-Gründächer über einen pixelbasierten Ansatz abgegrenzt. Dadurch, dass innerhalb der Gründachkartierung des Projekts „Lebensraum Gründach“ nicht davon ausgegangen werden kann, dass alle nicht-kartierten Dachflächen keine Gründächer sind, bestand die Herausforderung in einer angemessenen Datenauswahl. Mit der dachflächeninternen Abgrenzung vegetationstypischer Pixel wurde ein Weg gefunden, tatsächliche Nicht-Gründächer für die Modelleingabe zu extrahieren. Weiterhin schwankte die Qualität der händisch kartierten Gründächer durch die Vielzahl unterschiedlicher KartiererInnen stark.

Innerhalb der vorgefilterten und aufbereiteten Modelleingabedaten konnten Gründächer verlässlich identifiziert und klassifiziert werden. Dies wurde durch die Modellvalidierung anhand der Testdaten bestätigt. Der NDVI allein bietet bereits ein sehr zufriedenstellendes Entscheidungskriterium zur Abgrenzung von Gründächern innerhalb der aufbereiteten Modelleingabe und durch die Kombination mit den einzelnen Spektralbändern RGBI als Prädiktoren konnte die Modelleistung noch einmal gesteigert werden. Die höhere Gewichtung der Gründächer ermöglichte es im Modelltraining, den großen Datenüberhang der Nicht-Gründächer zu relativieren. Als Entscheidungsschwellenwert zur Klassentrennung bildet der individuell ermittelte Youden-Index einen ausgewogenen Cut-off.

Im Aufbau der Methodik wurden drei Klassifikationsansätze mit einer entsprechenden Validierung durchgeführt.

- 1) Validierung der vegetationstypischen Pixelklassifikation
- 2) Validierung der Regressionsmodelle anhand der Testdaten (Modellvalidierung)
- 3) Validierung der Klassifikation aller Dachflächen anhand des multivariaten Regressionsmodells mit Youden-Schwellenwert (Gesamtklassifikation bzw. Gesamtvalidierung)

Bei der Modellvalidierung konnten sehr gute Ergebnisse anhand einer hohen Precision (= 0,94) und eines hohen Recalls (= 0,97) festgestellt werden. Dieses Bild wandelte sich in der Validierung aller Dachflächen, die hohe Vorhersagegenauigkeit des Modells konnte nicht aufrechterhalten werden und die Grenzen des trainierten Modells wurden sichtbar. In der Gesamtvalidierung zeigt sich zwar ein hoher Recall (= 0,99), allerdings sinkt die Precision (= 0,5) deutlich und es treten sehr viele falsch-positive Zuweisungen auf.

Eine Ursache für den Leistungsunterschied ist die Auswahl äußerst homogener Trainings- und Testdaten, welche sehr eindeutig einer Klasse zugeordnet werden können. Heterogene bzw. nicht

eindeutig zuzuordnende Dachflächen wurden durch die Methodik der Trainingsdatenerstellung ausgeschlossen. Dadurch wurde die Klassifikationsaufgabe deutlich vereinfacht, da sich die spektralen Eigenschaften der beiden Klassen folglich wenig überlappen. Dieses Vorgehen führt zwar zu einer erhöhten Trennschärfe innerhalb der Testdaten, schränkt jedoch die Übertragbarkeit auf heterogene Dachstrukturen ein.

Bei einer Fortführung der vorgeschlagenen Methodik sollte ein stärkerer Fokus auf die Heterogenität der Trainingsdaten der Nicht-Gründächer gelegt werden. In den Trainingsdaten sollten demnach mehr verschiedene Dachtypen und Verschattungen enthalten sein. So könnte eine robustere Modellperformance bei heterogenen Dachflächen erreicht werden. Außerdem könnte der Entscheidungsschwellenwert in der Gesamtklassifikation neu kalibriert werden, um durch einen ggf. höheren Cut-off mehr falsch-positive Zuweisungen auszuschließen.

Auch Fehler durch Verschattung und die falsche Klassifikation von Ziegeldächern könnten mit heterogeneren Trainingsdaten gemildert werden. Für das Ausschließen von schrägen Dächern kann außerdem ein nDOM herangezogen werden, mit dessen Hilfe die Neigung der Dachflächen bestimmt wird (Ansel et al. 2025). Unter der Annahme, dass schräge Dächer in der Regel nicht begrünt werden, nutzten Lambarki et al. (2022) in ihrer Potentialanalyse bspw. eine zulässige Höchstneigung von elf Grad.

In der detaillierten Fehlerbetrachtung innerhalb der Gesamtklassifikation aller Dachflächen im Untersuchungsgebiet ist zu erkennen, dass ein großer Teil der falsch-positiven Zuweisungen durch den Überwuchs von Bäumen verursacht wird. Dies lässt sich nicht mit einem heterogeneren Modelltraining beheben, sondern muss auf andere Weise behandelt werden. Ein größerer Buffer scheint nicht sinnvoll, da die Fläche gerade bei kleineren Dächern zu sehr reduziert werden würde und nicht mehr repräsentativ ist. Unter der Annahme, dass vor allem niedrigere Dächer von einer solchen Überdeckung betroffen sind, könnte mit Hilfe eines nDOMs eine Mindestdachhöhe definiert werden, womit Dächer unter dieser bestimmten Dachhöhe ausgeschlossen werden (Pauligk et al. 2020). Louis-Lucas et al. (2021) schließen so alle Gebäude unter drei Meter Höhe aus. Allerdings muss dabei zwischen dem Ausschließen von niedrigen Gründächern und der Vermeidung von überwuchsbedingten Fehlern abgewägt werden. Eine Alternative zum Ausschlusskriterium der Dachhöhe ist das Festlegen einer Mindestdachfläche. In der Gesamtklassifikation ist eine Vielzahl an Dachflächen unter zehn Quadratmetern enthalten, die besonders oft falsch-positiv klassifiziert werden. Es sollte geprüft werden, wie oft Dachflächen unter zehn Quadratmeter in der Realität tatsächlich begrünt sind und welcher Verlust an tatsächlichen Gründächern durch diesen Ausschluss entstehen würde. Beispielsweise legen Simpson et al. (2023) eine Mindestfläche von 10

Quadratmetern für die zu klassifizierenden Dachflächen fest und auch die Kartierung in Vorarlberg beachtet nur Dächer größer als zehn Quadratmeter (Amt der Vorarlberger Landesregierung 2023).

Ebenso kann die Kombination mit anderen Datentypen zielführend sein. Degerickx et al. (2020) klassifizieren verschiedene städtische Grünflächentypen mithilfe eines objektbasierten Klassifikationsansatzes und ziehen LiDAR-Daten zu hyperspektralen und multispektralen Daten in Random-Forest-Modellen hinzu. Für eine höhere Klassifikationsgenauigkeit empfehlen die AutorInnen auch die Integration von multitemporalen Bilddaten.

Eine weitere Möglichkeit, um eine differenziertere Klassifikation zu erreichen, besteht darin mehr als zwei Klassen zu unterscheiden. So können individuelle Vegetationseigenschaften treffender zugeordnet werden. Degerickx et al. (2020) unterscheiden zusätzlich zu Nicht-Gründächern extensive und intensive Begrünung oder Coenradie et al. (2016) weisen die drei Klassen „sichere Vegetation“, „unsicher Vegetation“ und „sicher keine Vegetation“ zu.

In der Validierung der vegetationstypischen Pixelklassifikation hat sich gezeigt, dass dieses Vorgehen zwar für das Ausschließen falsch-negativer Pixel geeignet ist, aber viele falsch-positive Vegetationspixel zulässt. Die Ergebnisse des prozentualen Grünflächenanteils, welche mit Hilfe dieses pixelbasierten Ansatzes erhoben wurden, sind demnach als Richtwerte zu verstehen. Zwar bietet dieser Ansatz keine hohe Genauigkeit, innerhalb der Gründachklasse kann der Ansatz jedoch als Teil der individuellen Validierung dienen. So konnte festgestellt werden, dass 56 der 2.658 Gründächer aus der multivariaten Klassifikation über keine vegetationstypischen Pixel verfügen. In einer eingehenderen Prüfung konnten diese Dächer als falsch-positive Zuweisung identifiziert werden.

Trotz aller Einschränkungen der Gesamtklassifikation wurde im Rahmen dieser Arbeit eine Datengrundlage geschaffen, welche für weiterführende Fragestellungen gezielt aufbereitet und genutzt werden kann. Je nach Ziel können die klassifizierten Gründächer nach Flächengröße oder Grünflächenanteil gefiltert und so bspw. passende Versuchsflächen lokalisiert werden.

Ziel der Arbeit war eine Methodenentwicklung, welche möglichst leicht zugänglich sein sollte. Dies wurde durch die freie Datenverfügbarkeit und die Nutzung von einfachen R-Skripten sichergestellt. Auch die Verarbeitung in ArcGIS Pro können im kostenfreien QGIS reproduziert werden. Dadurch ist die Methodik ohne spezialisierte Infrastruktur umsetzbar. Für die Übertragung auf neue Bilddaten muss die Abgrenzung der spektralen Eigenschaften von Vegetation und anderen Oberflächen allerdings neu kalibriert werden, da diese von den Aufnahmebedingungen der Orthofotos abhängen.

Für zukünftige Gründachkartierungen könnte die Arbeit optimiert werden, indem bereits die amtlichen Gebäudeumringe Teil der Kartierung sind. Manche fehlerhaften Markierungen abseits von Gebäuden könnten dadurch vermieden werden. Die weitere Datenverarbeitung wird außerdem

erleichtert, wenn die kartierten Teilflächen so genau wie möglich abgegrenzt sind. Beispielsweise könnte sowohl die begrünte Teildachfläche als auch das zugehörige amtliche Gesamtpolygon kartiert werden. Daraus würde ein Datensatz resultieren, welcher die Oberflächenaufteilung heterogener Dachflächen anerkennt und die Trennung innerhalb gemischter Oberflächen wiedergibt. Als Kartierungsgrundlage bietet es sich an, dass die amtlichen Gebäudeumringe ausgewählt werden können und nicht händisch eingezeichnet werden müssen. Dies würde zudem eine gewisse Einheitlichkeit bei mehreren KartiererInnen gewährleisten.

8 Fazit und Ausblick

Die vorliegende Arbeit zeigt, dass eine automatisierte Kartierung von Gründächern auf Basis frei verfügbarer Orthofotos und vergleichsweise einfacher methodischer Ansätze grundsätzlich möglich ist. Die Nutzung einer logistischen Regression als Klassifikationsmethodik erweist sich als leistungsfähiger Ansatz zur Identifikation von homogenen Gründächern.

Die Gegenüberstellung der Validierungsergebnisse der Klassifikation homogener Gründächer und der Gesamtklassifikation macht deutlich, dass die Übertragbarkeit des Modells auf reale, heterogene Datensätze weiterhin eine zentrale Herausforderung darstellt und die Qualität und Repräsentativität der Trainingsdaten einen entscheidenden Einfluss auf die Leistungsfähigkeit der Klassifikation haben.

Die Ergebnisse unterstreichen zudem, dass bestimmte Fehlerquellen, insbesondere Verschattung, Überwuchs durch Bäume sowie spektrale Ähnlichkeiten mit nicht begrünten Materialien, nicht allein durch eine Anpassung des Modells behoben werden können. Vielmehr zeigen sich hier bekannte Fehlerquellen, welche in der Orthofotoverarbeitung auftreten. Für zukünftige Arbeiten ergeben sich daraus mehrere Ansatzpunkte. Eine zentrale Rolle spielt die Weiterentwicklung der Trainingsdatenauswahl hin zu stärker heterogenen und realitätsnäheren Datensätzen, um die Übertragbarkeit des Modells zu verbessern. Darüber hinaus bietet die Integration zusätzlicher Geodaten, wie nDOMs oder LiDAR Daten, großes Potenzial zur Reduktion systematischer Fehlklassifikationen, insbesondere im Hinblick auf Dachneigung und Vegetationsüberwuchs.

Die Arbeit leistet einen Beitrag zur Entwicklung leicht zugänglicher Methoden für die Gründacherfassung und zeigt zugleich die Grenzen eines rein spektralbasierten Ansatzes auf. Klassifizierungen wie diese bilden die Grundlage für weitere Analysen zum Thema Stadtklima, Entwässerungsplanung oder Biotopvernetzung in universitären und außeruniversitären Projekten. Außerdem kann sich die gezielte kommunale Förderung begrünter Dächer in Gebieten mangelhafter

Grünausstattung auf diese Datengrundlage stützen und sie für die allgemeine Öffentlichkeitsarbeit nutzen.

Im Rahmen einer weiterführenden Nutzung der Analyseergebnisse im Stadtgebiet Innsbrucks wäre zudem die Verknüpfung der Gründachdaten mit Temperaturdaten von Wärmebildern äußerst spannend. So könnte die etwaige kühlende Wirkung der lokalisierten Gründächer in Bezug auf die Stadtklimaregulierung untersucht werden.

Literatur

- Amt der Tiroler Landesregierung - Abteilung Geoinformation (2022): Orthofoto Download Tirol. Online verfügbar unter <https://tiris.maps.arcgis.com/apps/webappviewer/index.html?id=5849fe1df5994dc8a3c1e4675682d2fd>, zuletzt geprüft am 02.03.2026.
- Amt der Vorarlberger Landesregierung (Hg.) (2023): Raumb Beobachtung Vorarlberg. Gründächer - Methodik. Online verfügbar unter <https://experience.arcgis.com/experience/fa897876b6d249c8a20c72884888f512/page/Methodik?views=Ansicht-3>, zuletzt geprüft am 07.04.2026.
- Ansel, W.; Zeidler, J.; Esch, T. (2015): Fernerkundliche Identifizierung von Vegetationsflächen auf Dächern zur Entwicklung des für die Bereiche des Stadtklimas, der Stadtentwässerung und des Artenschutzes aktivierbaren Flächenpotenzials in den Städten. Abschlussbericht des Entwicklungsprojektes gefördert unter dem Az 30299 von der Deutschen Bundesstiftung Umwelt.
- Awada, F. (2022): Ecology of Green Roofs. Summary of the Grooves Study Green Roofs verified Services 2017 - 2019. Hg. v. L'Institut Paris Region. Agence Regionale de la Biodiversite. Online verfügbar unter chrome-extension://efaidnbmninnipcbajpcgclclefindmkaj/https://en.institutparisregion.fr/fileadmin/NewEtudes/000pack2/Etude_2782/green_roofs_bat.pdf, zuletzt geprüft am 29.10.2025.
- Balata, D.; Gama, I.; Domingos, T.; Proença, V. (2022): Using Satellite NDVI Time-Series to Monitor Grazing Effects on Vegetation Productivity and Phenology in Heterogeneous Mediterranean Forests. In: *Remote Sensing* 14 (10), S. 2322. DOI: 10.3390/rs14102322.
- Barriuso, F.; Urbano, B. (2021): Green Roofs and Walls Design Intended to Mitigate Climate Change in Urban Areas across All Continents. In: *Sustainability* 13 (4), S. 2245. DOI: 10.3390/su13042245.
- Belz, C. (2010): Methodenentwicklung für den Aufbau eines Gründachkatasters von Berlin am Beispiel des Bezirks Friedrichshain-Kreuzberg. Masterarbeit am Fachbereich Landschaftsarchitektur, Geoinformatik, Geodäsie und Bauingenieurwesen der Hochschule Neubrandenburg. Online verfügbar unter digibib.hs-nb.de/file/dbhsnb_derivate_0000000845/Masterarbeit-Belz-2010.pdf, zuletzt geprüft am 24.06.2025.
- Bundesamt für Eich- und Vermessungswesen (Hg.) (2021a): GIS-Grid. Transformationsverfahren NTv2 (National Transformation Version 2). Online verfügbar unter <https://www.bev.gv.at/Services/Produkte/Grundlagenvermessung/GIS-Grid.html>, zuletzt geprüft am 11.06.2025.
- Bundesamt für Eich- und Vermessungswesen (Hg.) (2021b): UTM. Transformator. Online verfügbar unter <https://transformator.bev.gv.at/at.gv.bev.transformator/wiki/doku.php?id=transformator:utm>, zuletzt geprüft am 08.04.2026.

- Bundesamt für Eich- und Vermessungswesen (Hg.) (2024c): Digitales Landschaftsmodell - Bauwerke. Stichtag 18.11.2024. Online verfügbar unter <https://data.bev.gv.at/geonetwork/srv/ger/catalog.search#/search?isTemplate=n&resourceTemporalDateRange=%7B%22range%22:%7B%22resourceTemporalDateRange%22:%7B%22gte%22:null,%22lte%22:null,%22relation%22:%22intersects%22%7D%7D%7D&sortBy=creationDateForResource&sortOrder=desc&from=1&to=100&any=Digitales%20Landschaftsmodell%20-%20Bauwerke&languageStrategy=searchInAllLanguages&titleOnly>, zuletzt geprüft am 05.03.2026.
- Büscher, O.; Mütterthis, A. (2021): ADAM Analyse der thermischen Wirkung von Dachbegrünung mittels Stadtklimamodellierung. AP 1 - Erstellung des Gründachkatasters und Gründachpotentialkatasters. Online verfügbar unter chrome-extension://efaidnbmninnipcegjpcglefindmkaj/https://www.dwd.de/DE/klimaumwelt/klimaforschung/klimawirk/stadtpl/stadtklimaprojekte/projekt_adam/pdfs/adam.pdf?__blob=publicationFile&v=1, zuletzt geprüft am 10.02.2025.
- Coenradie, B.; Haag, L.; Streng, B.; Schiffner, S.; Müller, K. (2016): Erhebung und Aufbereitung von Informationen zum Gründachbestand in Berlin. Gründachkartierung Berlin 2016. Unter Mitarbeit von Dr.-Ing. Bodo Coenradie (DDB), Leilah Haag, Bianca Streng, Sandy Schiffner, Katja Müller (LUP). Online verfügbar unter https://www.berlin.de/umweltatlas/_assets/literatur/ab_gruendaecher_2016.pdf, zuletzt geprüft am 28.02.2026.
- Cohen, B. (2006): Urbanization in developing countries: Current trends, future projections, and key challenges for sustainability. In: *Technology in Society* 28 (1-2), S. 63–80. DOI: 10.1016/j.techsoc.2005.10.005.
- Cristiano, E.; Deidda, R.; Viola, F. (2020): The role of green roofs in urban Water-Energy-Food-Ecosystem nexus: A review. In: *The Science of the total environment* 756, S. 143876. Online verfügbar unter <https://www.sciencedirect.com/science/article/pii/S0048969720374076>.
- Degerickx, J.; Hermy, M.; Somers, B. (2020): Mapping Functional Urban Green Types Using High Resolution Remote Sensing Data. In: *Sustainability* 12 (5), S. 2144. DOI: 10.3390/su12052144.
- Delegido, J.; Verrelst, J.; Meza, C. M.; Rivera, J. P.; Alonso, L.; Moreno, J. (2013): A red-edge spectral index for remote sensing estimation of green LAI over agroecosystems. In: *European Journal of Agronomy* 46, S. 42–52. DOI: 10.1016/j.eja.2012.12.001.
- Dobričić, D.; Miler, M.; Medak, D. (2025): Mapping the Green Urban: A Comprehensive Review of Materials and Learning Methods for Green Infrastructure Mapping. In: *Sensors (Basel, Switzerland)* 25 (2). DOI: 10.3390/s25020464.
- Dreiseitl, S.; Ohno-Machado, L. (2002): Logistic regression and artificial neural network classification models: a methodology review. In: *Journal of biomedical informatics* 35 (5-6), S. 352–359. DOI: 10.1016/s1532-0464(03)00034-0.
- Falcão, A.; Pernes, J.; Miranda, V.; Silva, C. (2025): Mapping Green Roofs on Buildings Using Vegetation Indices and Deep Learning Techniques. *Remote Sensing* (21). Online verfügbar unter

- https://www.mdpi.com/2072-4292/17/21/3657#Material_and_Methods, zuletzt geprüft am 28.02.2026.
- Fluss, R.; Faraggi, D.; Reiser, B. (2005): Estimation of the Youden Index and its associated cutoff point. In: *Biometrical journal. Biometrische Zeitschrift* 47 (4), S. 458–472. DOI: 10.1002/bimj.200410135.
- Green Transition Information Factory (Hg.) (2022): Existing Green Roofs. European Space Agency. Online verfügbar unter https://gtif.esa.int/explore?indicator=SOL1_2&x=1268717.04001&y=5985405.48573&z=16.96173, zuletzt geprüft am 17.03.2026.
- Griffith, D.; Hay, G. (2018): Integrating GEOBIA, Machine Learning, and Volunteered Geographic Information to Map Vegetation over Rooftops. In: *IJGI* 7 (12), S. 462. DOI: 10.3390/ijgi7120462.
- He, H.; Garcia, E. (2009): Learning from Imbalanced Data. In: *IEEE Transactions on Knowledge and Data Engineering* (21(9):1263 - 1284). Online verfügbar unter https://www.researchgate.net/publication/224541268_Learning_from_Imbalanced_Data, zuletzt geprüft am 08.04.2026.
- Hoffert, H.; Lumasegger, M. (2010): Grünraumanalyse Wien, Dachbegrünung. Unter Mitarbeit von freiland Umweltconsulting ZT-GmbH. Wien.
- Huang, S.; Tang, L.; Hupy, J.; Wang, Y.; Shao, G. (2021): A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing. In: *J. For. Res.* 32 (1), S. 1–6. DOI: 10.1007/s11676-020-01155-1.
- James, G.; Witten, D.; Hastie, T.; Tibshirani, R.; Taylor, J. (Hg.) (2023): An Introduction to Statistical Learning. with Applications in Python. Cham: Springer International Publishing.
- Jiang, Z.; Huete, A.; Chen, J.; Chen, Y.; Li, Jing; Yan, G.; Zhang, X. (2006): Analysis of NDVI and scaled difference vegetation index retrievals of vegetation fraction. In: *Remote Sensing of Environment* 101 (3), S. 366–378. Online verfügbar unter <https://www.sciencedirect.com/science/article/abs/pii/S0034425706000290>.
- Kabisch, S.; Rink, D.; Banzhaf, E. (Hg.) (2024): Die Resiliente Stadt. Konzepte, Konflikte, Lösungen. Berlin, Heidelberg: Springer Berlin Heidelberg, zuletzt geprüft am 20.06.2025.
- Khalil, R.; Khan, M.; Hasan, Y.; Nacer, N.; Khan, S. (2024): Supervised NDVI Composite Thresholding for Arid Region Vegetation Mapping. In: *Eng. Technol. Appl. Sci. Res.* 14 (3), S. 14420–14427. DOI: 10.48084/etasr.7202.
- Kim, J.; Choi, S.; Panahi, M.; Li, D.; Kim, Y. (2025): Deep learning-based spatial optimization of green and cool roof implementation for urban heat mitigation. In: *Journal of environmental management* 383, S. 125398. DOI: 10.1016/j.jenvman.2025.125398.
- Kriegler, F.; Malila, W.; Nalepka, R.; Richardson, W. (1969): Preprocessing transformations and their effect on multispectral recognition. In: *University of Michigan*, S. 97–131.
- Lambarki, R.; Achbab, E.; Maanan, M.; Rhinane, H. (2022): Evaluation of the potential of green roofs applied to an urban fabric using GIS and remote sensing data. Case of the Nador city / Ma-

- rocco. In: *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.* XLVI-4/W3-2021, S. 177–184. DOI: 10.5194/isprs-archives-XLVI-4-W3-2021-177-2022.
- Lange, N. de (Hg.) (2020): *Geoinformatik in Theorie und Praxis. Grundlagen von Geoinformationssystemen, Fernerkundung und digitaler Bildverarbeitung.* Berlin, Heidelberg: Springer Berlin Heidelberg.
- Li, Q.; Taubenböck, H.; Zhu, X. (2025): Identification of the potential for roof greening using remote sensing and deep learning. In: *Cities* 159, S. 105782. DOI: 10.1016/j.cities.2025.105782.
- Li, Y.; Svenning, J.; Zhou, W.; Zhu, K.; Abrams, J.; Lenton, T. et al. (2024): Green spaces provide substantial but unequal urban cooling globally. In: *Nature communications* 15 (1), S. 7108. DOI: 10.1038/s41467-024-51355-0.
- Louis-Lucas, T.; Mayrand, F.; Clergeau, P.; Machon, N. (2021): Remote sensing for assessing vegetated roofs with a new replicable method in Paris, France. Sorbonne Université, Centre d'Écologie et des Sciences de la Conservation (CESCO UMR7204), MNHN, CNRS, Paris, France. Online verfügbar unter https://www.researchgate.net/publication/348392657_Remote_sensing_for_assessing_vegetated_roofs_with_a_new_replicable_method_in_Paris_France.
- Lundholm, J. (2015): Green roof plant species diversity improves ecosystem multifunctionality. In: *Journal of Applied Ecology* 52 (3), S. 726–734. DOI: 10.1111/1365-2664.12425.
- Ma, C.; Yuan, C.; Zhang, Y.; Hu, H. (2025): Mapping utilizable rooftop areas to meet food security goal in four high-density cities: A deep learning and GIS integrated approach. In: *Sustainable Cities and Society* 118, S. 106066. DOI: 10.1016/j.scs.2024.106066.
- Maalouf, M.; Siddiqi, M. (2014): Weighted logistic regression for large-scale imbalanced and rare events data. In: *Knowledge-Based Systems* 59, S. 142–148. DOI: 10.1016/j.knosys.2014.01.012.
- Maghami-Mehr, A.; Torabi, H.; Nadeb, H.; Zhao, Y. (2025): Linear regression models for analyzing the covariate-adjusted Youden index and associated cut-off points in three diagnostic groups. In: *Journal of biopharmaceutical statistics*, S. 1–25. DOI: 10.1080/10543406.2025.2558141.
- Marmy, C.; Destouches, S.; Mauch, U.; Cerioni, A.; Pott, R. (2025): Green roofs: automatic detection of green roofs and vegetation type from aerial imagery. Swiss Territorial Data Lab. Online verfügbar unter <https://tech.stdl.ch/PROJ-VEGROOFS/>.
- Martínez-Cambor, P.; Pardo-Fernández, J. (2019): The Youden Index in the Generalized Receiver Operating Characteristic Curve Context. In: *The international journal of biostatistics* 15 (1). DOI: 10.1515/ijb-2018-0060.
- Massy, J.; Martin, P.; Wyler, N. (2011): Cartographie semi-automatisée des toitures végétalisées de la Ville de Genève. Halbautomatische Kartierung der begrünten Dächer der Stadt Genf. Conservatoire et Jardin botaniques de la Ville de Genève. Géomatique Expert - N° 81 - Juillet-Aout 2011, zuletzt geprüft am 27.10.2025.
- Menard, S. (2011): *Applied Logistic Regression Analysis.* 2455 Teller Road, Thousand Oaks California 91320 United States of America: SAGE Publications, Inc.

- Mohajerani, A.; Bakaric, J.; Jeffrey-Bailey, T. (2017): The urban heat island effect, its causes, and mitigation, with reference to the thermal properties of asphalt concrete. In: *Journal of environmental management* 197, S. 522–538. DOI: 10.1016/j.jenvman.2017.03.095.
- Nurmi, V.; Votsis, A.; Perrels, A.; Lehvavirta, S. (2016): Green Roof Cost-Benefit Analysis: Special Emphasis on Scenic Benefits. In: *J. Benefit Cost Anal.* 7 (3), S. 488–522. DOI: 10.1017/bca.2016.18.
- Oberndorfer, E.; Lundholm, J.; Bass, B.; Coffman, R.; Doshi, H.; Dunnett, N. et al. (2007): Green Roofs as Urban Ecosystems: Ecological Structures, Functions, and Services. In: *BioScience* (November 2007 / Vol. 57 No. 10), S. 823–833. Online verfügbar unter <https://academic.oup.com/bioscience/article/57/10/823/232363>, zuletzt geprüft am 02.02.2026.
- Otter, J. (2015): 3-D Referenzsysteme in Österreich. Unter Mitarbeit von N. Höggerl, E. Imrek, G. Stangl und E. Zahn. Online verfügbar unter https://www.bev.gv.at/dam/jcr:3dc49583-f1f5-47c6-89c0-52c8d5f576d1/Systeme_Landesvermessung_2015.pdf, zuletzt geprüft am 08.04.2026.
- Pal, A. (2021): Logistic regression: A simple primer. In: *Cancer Research, Statistics, and Treatment* 4 (3), S. 551–554. DOI: 10.4103/crst.crst_164_21.
- Pauligk, A.; Stöckigt, B.; Streng, B. (2022): Erhebung und Aufbereitung von Informationen zum Gründachbestand in Berlin 2020. Abschlussbericht. Unter Mitarbeit von Luftbild Umwelt Planung GmbH. Senatsverwaltung für Stadtentwicklung, Bauen und Wohnen Berlin. Berlin.
- Perkins, N. J.; Schisterman, E. F. (2005): The Youden Index and the optimal cut-point corrected for measurement error. In: *Biometrical journal. Biometrische Zeitschrift* 47 (4), S. 428–441. DOI: 10.1002/bimj.200410133.
- Razzaghamanesh, M.; Beecham, S. (2014): The hydrological behaviour of extensive and intensive green roofs in a dry climate. In: *The Science of the total environment* 499, S. 284–296. DOI: 10.1016/j.scitotenv.2014.08.046.
- Robin, X.; Turck, N.; Hainard, A.; Tiberti, N.; Lisacek, F.; Sanchez, J.; Müller, M. (2025): pROC: Display and Analyze ROC Curves. Online verfügbar unter <https://xrobin.github.io/pROC/>, zuletzt geprüft am 21.0.2.2026.
- Rousson, V.; Zumbunn, T.: Decision curve analysis revisited: overall net benefit, relationships to ROC curve analysis, and application to case-control studies. In: *BMC Medical Informatics & Decision Making* 2011, zuletzt geprüft am 02.03.2026.
- Sánchez-Cordero, F.; Nanía, L.; Hidalgo-García, D.; López-Chacón, S. (2025): Assessing the Spatial Benefits of Green Roofs to Mitigate Urban Heat Island Effects in a Semi-Arid City: A Case Study in Granada, Spain. Hg. v. remote sensing. Online verfügbar unter https://www.mdpi.com/2072-4292/17/12/2073?utm_source=chatgpt.com.
- Santos, T.; Tenedório, J.; Gonçalves, J. (2016): Quantifying the City's Green Area Potential Gain Using Remote Sensing Data. In: *Sustainability* 8 (12), S. 1247. DOI: 10.3390/su8121247.
- Senatsverwaltung für Stadtentwicklung, Bauen und Wohnen Berlin (2020): Gründächer 2020. Methode. Berlin (Umweltatlas Berlin). Online verfügbar unter

<https://www.berlin.de/umweltatlas/nutzung/gruendaecher/2020/methode/>, zuletzt geprüft am 24.06.2025.

- Seneviratne, S.; Zhang, M.; Adnan, M.; Badi, W.; Dereczynski, C.; Di Luca, A. et al. (2021): Weather and Climate Extreme Events in a Changing Climate. *Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change*. Unter Mitarbeit von Masson-Delmotte, V., P. Zhai, A. Pirani, S.L. Connors, C. Péan, S. Berger, N. Caud, Y. Chen, L. Goldfarb, M.I. Gomis, M. Huang, K. Leitzell, E. Lonnoy, J.B.R. Matthews, T.K. Maycock, T. Waterfield, O. Yelekçi, R. Yu, and B. Zhou (eds. In: *Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change*, S. 1513–1766. Online verfügbar unter chrome-extension://efaidnbnmnnibpcajpcglclefindmkaj/https://www.ipcc.ch/report/ar6/wg1/downloads/report/IPCC_AR6_WGI_Chapter11.pdf, zuletzt geprüft am 02.03.2026.
- Simpson, C.; Brousse, O.; Mohajeri, N.; Davies, M.; Heaviside, C. (2023): An open-source automatic survey of green roofs in London using segmentation of aerial imagery (4). Online verfügbar unter <https://essd.copernicus.org/articles/15/1521/2023/#bib1.bibx23>, zuletzt geprüft am 28.02.2026.
- Solcerova, A.; van de Ven, F.; Wang, M.; Rijdsdijk, M.; van de Giesen, N. (2016): Do green roofs cool the air? In: *Building and Environment* 111, S. 249–255. Online verfügbar unter <https://www.sciencedirect.com/science/article/pii/S036013231630422X>.
- Susca, T.; Gaffin, S. R.; Dell'osso, G. (2011): Positive effects of vegetation: urban heat island and green roofs. In: *Environmental pollution (Barking, Essex : 1987)* 159 (8-9), S. 2119–2126, zuletzt geprüft am 03.07.2025.
- Universität Innsbruck (Hg.) (2024): Lebensraum Gründach. in *Zeiten von Klimawandel und Biodiversitätskrise*. Unter Mitarbeit von J. Rüdissler. Online verfügbar unter <https://vielfaltdach.at/>, zuletzt geprüft am 05.03.2026.
- Williams, K.; Lee, K.; Sargent, L.; Johnson, K.; Rayner, J.; Farrell, C. et al. (2019): Appraising the psychological benefits of green roofs for city residents and workers. In: *Urban Forestry & Urban Greening* 44, S. 126399. DOI: 10.1016/j.ufug.2019.126399.
- Zeng, Y.; Hao, D.; Huete, A.; Dechant, B.; Berry, J.; Chen, J. M. et al. (2022): Optical vegetation indices for monitoring terrestrial ecosystems globally (*Nature Reviews Earth & Environment* 3, 477–493 (2022)). Online verfügbar unter <https://www.nature.com/articles/s43017-022-00298-5>, zuletzt geprüft am 31.10.2025.
- Zhuo, Z.; Ran, K.; Dong, L. (2025): Assessing the Effects of Exposure to Green Rooftop Spaces on Perceived Restorativeness: A Field Study in Xiamen, China. In: *Buildings* 15 (9), S. 1427. DOI: 10.3390/buildings15091427.

Anhang 1: Modellzusammenfassung der univariaten logistischen Regression

Koeffizienten:

Parameter	Estimate	Std. Error	z value	p-Wert	Signifikanz
Intercept	0.11819	0.08978	1.316	0.188	n.s.
get(median_col)	88.46587	3.60305	24.553	< 2e-16	***

Regressionsmodell:

$$\text{Logit}(p) = 0,11819 + 88,46587 * x$$

Wobei x den Medianwert des jeweiligen Spektralbandes darstellt und p die geschätzte Wahrscheinlichkeit für das Vorliegen eines Gründachs.

Modellgüte:

Kennzahl	Wert
Null Deviance	5819.7
Residual Deviance	1103.6
AIC	1147.3
Freiheitsgrade (Null)	2415
Freiheitsgrade (Modell)	2414
Fisher Scoring Iter.	8

Anhang 2: Modellzusammenfassung der multivariaten logistischen Regression

Regressionskoeffizienten:

Parameter	Estimate	Std. Error	z value	p-Wert	Signifikanz
Intercept	0.2424	0.06984	3.471	0.000518	***
R_med	-0.001407	0.0001073	-13.115	< 2e-16	***
G_med	0.0005962	0.0001916	3.112	0.001856	**
B_med	-0.0005655	0.0001419	-3.986	6.71e-05	***
NIR_med	0.001273	0.0001016	12.522	< 2e-16	***
NDVI_med	-22.02	0.7803	-2.822	0.004771	**

Regressionsmodell:

$$\text{Logit}(p) = 0,2424 - 0,001407 * R_{med} + 0,0005962 * G_{med} - 0,0005655 * B_{med} + 0,001273 * NIR_{med} - 2,202 * NDVI_{med}$$

Modellgüte:

Kennzahl	Wert
Null Deviance	5819.66
Residual Deviance	556.24
Freiheitsgrade (Nullmodell)	2415
Freiheitsgrade (Modell)	2410
AIC	589.08
Fisher Scoring Iterationen	8

Anhang 3: RStudio Skript der univariaten logistischen Regressionsanalyse

Zur Unterstützung bei der Erstellung und Strukturierung des R-Codes wurde das KI-Tool ChatGPT (OpenAI, Version GPT-5.3) verwendet. Die generierten Inhalte wurden überprüft und angepasst.

```
# =====  
# UNIVARIATE LOGISTISCHE REGRESSION – NDVI MEDIAN  
# =====  
  
# ---- Pakete ----  
if(!require(readxl)) install.packages("readxl")  
if(!require(pROC)) install.packages("pROC")  
library(readxl)  
library(pROC)  
  
# ---- Dateipfade ----  
file_green <- "D:/..."  
file_normal <- "D:/..."  
  
# ---- Einlesen ----  
df_green <- read_excel(file_green)  
df_normal <- read_excel(file_normal)  
  
# ---- Spalten prüfen ----  
cat("Spalten Label1:\n"); print(names(df_green))  
cat("Spalten Label0:\n"); print(names(df_normal))  
median_col <- "MEDIAN"  
  
# ---- Label setzen ----  
df_green$label <- 1  
df_normal$label <- 0  
  
# ---- Zusammenführen ----  
df_all <- rbind(df_green[,c("Dach_ID",median_col,"label")],  
              df_normal[,c("Dach_ID",median_col,"label")])  
df_all <- df_all[complete.cases(df_all),]
```

```

# ---- Train/Test Split ----
set.seed(123)
n <- nrow(df_all)
train_idx <- sample(1:n, size=0.7*n)
train <- df_all[train_idx,]
test <- df_all[-train_idx,]
# ---- Gewichtung ----
n_yes <- sum(train$label==1)
n_no <- sum(train$label==0)
weight_yes <- n_no/n_yes
train$w <- ifelse(train$label==1,weight_yes,1)
cat("Gewicht Gründächer =",round(weight_yes,2),"\n")

# ---- Logistisches Modell ----
glm_fit <- glm(label ~ get(median_col),
              data=train, weights=w, family=binomial)
summary(glm_fit)
# ---- Modell speichern ----
saveRDS(glm_fit,"D:/...")

# ---- Vorhersagen & ROC ----
test$prob <- predict(glm_fit,newdata=test,type="response")
roc_obj <- roc(test$label,test$prob)
cat("AUC =",auc(roc_obj),"\n")

# ---- Youden-Schwelle ----
you <- coords(roc_obj,"best",
             ret=c("threshold","sensitivity","specificity"),
             best.method="youden")
th_youden <- as.numeric(you["threshold"])
sens_y <- as.numeric(you["sensitivity"])
spec_y <- as.numeric(you["specificity"])
cat("Youden:",round(th_youden,6),

```

```

"| Sens:",round(sens_y,3),
"| Spez:",round(spec_y,3),"\\n")

# ---- NDVI-Cutoff ----
b0 <- coef(glm_fit)[1]
b1 <- coef(glm_fit)[2]
logit_y <- log(th_youden/(1-th_youden))
ndvi_cut <- (logit_y-b0)/b1
cat("NDVI-Cutoff:",round(ndvi_cut,4),"\\n")

# ---- Klassifikation ----
test$pred_06 <- ifelse(test$prob>=0.6,1,0)
test$pred_y <- ifelse(test$prob>=th_youden,1,0)

# ---- Konfusionsmatrix ----
conf_mat <- function(true,pred){
  TP <- sum(true==1 & pred==1)
  FP <- sum(true==0 & pred==1)
  TN <- sum(true==0 & pred==0)
  FN <- sum(true==1 & pred==0)

  acc <- (TP+TN)/(TP+FP+TN+FN)
  rec <- TP/(TP+FN)
  prec <- TP/(TP+FP)
  F1 <- 2*(prec*rec)/(prec+rec)
  F2 <- 5*(prec*rec)/(4*prec+rec)

  list(TP=TP,FP=FP,TN=TN,FN=FN,
        accuracy=acc,recall=rec,
        precision=prec,f1=F1,f2=F2)}

cm_06 <- conf_mat(test$label,test$pred_06)
cm_y <- conf_mat(test$label,test$pred_y)

```

```

print(cm_06)
print(cm_y)

# ---- ROC Plot -----
plot(roc_obj,col="blue",lwd=2,
     main="ROC-Kurve NDVI Median",
     legacy.axes=TRUE)
abline(a=0,b=1,lty=2,col="gray")

# ---- Regressionskurve -----
plot(test[[median_col]],test$prob,
     pch=16,cex=0.7,col=rgb(0,0,0,0.3),
     xlab="NDVI Median",ylab="p(Gründach)",
     main="Logistische Regressionskurve")
curve(predict(glm_fit,
             newdata=data.frame(MEDIAN=x),
             type="response"),
       add=TRUE,col="blue",lwd=2)
abline(h=th_youden,col="darkgreen",lty=2,lwd=2)
abline(v=ndvi_cut,col="red",lty=2,lwd=2)

# =====
# MODELLANWENDUNG AUF ALLE DÄCHER
# =====

glm_fit <- readRDS("D:/...")
file_all_roofs <- "D:/..."
df_all_roofs <- read_excel(file_all_roofs)
df_all_roofs <- df_all_roofs[
  !is.na(df_all_roofs[[median_col]]),]

df_all_roofs$prob_green <- predict(
  glm_fit,newdata=df_all_roofs,
  type="response")

```

```
th_youden <- 0.567
```

```
df_all_roofs$class_youden <- ifelse(df_all_roofs$prob_green >= th_youden, 1, 0)
```

```
df_all_roofs$class_06 <- ifelse(df_all_roofs$prob_green >= 0.6, 1, 0)
```

```
write.csv(df_all_roofs,
```

```
"D:/...csv",
```

```
row.names=FALSE)
```

Anhang 4: RStudio Skript der multivariaten logistischen Regressionsanalyse

Zur Unterstützung bei der Erstellung und Strukturierung des R-Codes wurde das KI-Tool ChatGPT (OpenAI, Version GPT-5.3) verwendet. Die generierten Inhalte wurden überprüft und angepasst.

```
# =====  
# MULTIVARIATE LOGISTISCHE REGRESSION – RGBI + NDVI – Label 0 bereinigt  
# =====  
# ---- Pakete ----  
if(!require(readxl)) install.packages("readxl")  
if(!require(pROC)) install.packages("pROC")  
library(readxl)  
library(pROC)  
  
# 1) DATEIPFADE  
file_green_R <- "D:/.../Label1MedianROT_Teilflächen.xls"  
file_green_G <- "D:/.../Label1MedianGREEN_Teilflächen.xls"  
file_green_B <- "D:/.../Label1MedianBLUE_Teilflächen.xls"  
file_green_NIR <- "D:/.../Label1MedianNIR_Teilflächen.xls"  
file_green_NDVI <- "D:/.../Label1_medianeNDVI_Teilflächen.xls"  
  
file_norm_R <- "D:/.../ROT_medianLabel0.xls"
```

```

file_norm_G <- "D:/.../GREEN_medianLabel0.xls"
file_norm_B <- "D:/.../BLUE_medianLabel0.xls"
file_norm_NIR <- "D:/.../NIR_medianLabel0.xls"
file_norm_NDVI <- "D:/.../NDVImedianLabel0.xls"

# =====

# 2) EINLESEN
g_R <- read_excel(file_green_R)
g_G <- read_excel(file_green_G)
g_B <- read_excel(file_green_B)
g_NIR <- read_excel(file_green_NIR)
g_NDVI <- read_excel(file_green_NDVI)

n_R <- read_excel(file_norm_R)
n_G <- read_excel(file_norm_G)
n_B <- read_excel(file_norm_B)
n_NIR <- read_excel(file_norm_NIR)
n_NDVI <- read_excel(file_norm_NDVI)

# =====

# 3) SPALTEN
id_col <- "Dach_ID"
median_col <- "MEDIAN"

merge5 <- function(R,G,B,NIR,NDVI){
  tmp <- merge(R[,c(id_col,median_col)],G[,c(id_col,median_col)],by=id_col)
  names(tmp)[2:3] <- c("R_med","G_med")
  tmp <- merge(tmp,B[,c(id_col,median_col)],by=id_col); names(tmp)[4] <- "B_med"
  tmp <- merge(tmp,NIR[,c(id_col,median_col)],by=id_col); names(tmp)[5] <- "NIR_med"
  tmp <- merge(tmp,NDVI[,c(id_col,median_col)],by=id_col); names(tmp)[6] <- "NDVI_med"
  tmp}

df_green <- merge5(g_R,g_G,g_B,g_NIR,g_NDVI)

```

```

df_normal <- merge5(n_R,n_G,n_B,n_NIR,n_NDVI)
df_green$label <- 1
df_normal$label <- 0
df_all <- rbind(df_green,df_normal)
df_all <- df_all[complete.cases(df_all),]

# =====

# 4) TRAIN / TEST
set.seed(123)
idx <- sample(1:nrow(df_all),size=0.7*nrow(df_all))
train <- df_all[idx,]
test <- df_all[-idx,]

# ---- Gewichtung ----
n_yes <- sum(train$label==1)
n_no <- sum(train$label==0)
w_yes <- n_no/n_yes
train$w <- ifelse(train$label==1,w_yes,1)

# =====

# 5) MODELL
glm_fit <- glm(label ~ R_med+G_med+B_med+NIR_med+NDVI_med,
               data=train,weights=w,family=binomial)
summary(glm_fit)

saveRDS(glm_fit,
"D:/...")

# =====

# 6) ROC + AUC
test$prob <- predict(glm_fit,newdata=test,type="response")
roc_obj <- roc(test$label,test$prob)
cat("AUC =",round(as.numeric(auc(roc_obj)),4),"\n")

```

```

you <- coords(roc_obj,"best",
             best.method="youden",
             ret=c("threshold","sensitivity","specificity"))
th_youden <- as.numeric(you["threshold"])
cat("Youden =",round(th_youden,6),"\n")

# =====
# 7) KLASSIFIKATION
test$pred_06 <- ifelse(test$prob>=0.6,1,0)
test$pred_youd <- ifelse(test$prob>=th_youden,1,0)

conf_full <- function(true,pred){
  TP <- sum(true==1 & pred==1)
  FP <- sum(true==0 & pred==1)
  TN <- sum(true==0 & pred==0)
  FN <- sum(true==1 & pred==0)
  acc <- (TP+TN)/(TP+FP+TN+FN)
  rec <- TP/(TP+FN)
  prec <- TP/(TP+FP)
  F1 <- 2*(prec*rec)/(prec+rec)
  F2 <- 5*(prec*rec)/(4*prec+rec)
  list(TP=TP,FP=FP,TN=TN,FN=FN,
       accuracy=acc,recall=rec,
       precision=prec,f1=F1,f2=F2)
}

cm06 <- conf_full(test$label,test$pred_06)
cmy <- conf_full(test$label,test$pred_youd)

print(cm06)
print(cmy)

```

```

# =====
# 8) MULTIVARIATE LOGISTISCHE KURVE
test$linear_score <- predict(glm_fit,newdata=test,type="link")
x_seq <- seq(min(test$linear_score),max(test$linear_score),length.out=300)
y_curve <- plogis(x_seq)

plot(test$linear_score,test$prob,
      pch=16,cex=0.6,col=rgb(0,0,0,0.25),
      xlab="Modell-Score (RGBI + NDVI)",
      ylab="p(Gründach)",
      main="Multivariate logistische Regressionskurve")
lines(x_seq,y_curve,col="blue",lwd=3)
abline(h=th_youden,col="darkgreen",lty=2,lwd=2)
abline(v=qlogis(th_youden),col="red",lty=2,lwd=2)

# =====
# 9) MODELLANWENDUNG AUF ALLE DÄCHER
glm_fit <- readRDS(
"D:/...")

file_all_R <- "D:/.../ROT_medianALLEGeb.xls"
file_all_G <- "D:/.../GREEN_medianALLEGeb.xls"
file_all_B <- "D:/.../BLUE_medianALLEGeb.xls"
file_all_NIR <- "D:/.../NIR_medianALLEGeb.xls"
file_all_NDVI <- "D:/.../NDVImedianALLEGeb.xls"

all_R <- read_excel(file_all_R)
all_G <- read_excel(file_all_G)
all_B <- read_excel(file_all_B)
all_NIR <- read_excel(file_all_NIR)
all_NDVI <- read_excel(file_all_NDVI)

df_all_roofs <- merge5(all_R,all_G,all_B,all_NIR,all_NDVI)

```

```
df_all_roofs <- df_all_roofs[complete.cases(df_all_roofs),]
```

```
df_all_roofs$prob_green <- predict(glm_fit,  
                                  newdata=df_all_roofs,  
                                  type="response")
```

```
th_youden <- 0.475961
```

```
df_all_roofs$class_youden <-
```

```
ifelse(df_all_roofs$prob_green >= th_youden, 1, 0)
```

```
df_all_roofs$class_06 <-
```

```
ifelse(df_all_roofs$prob_green >= 0.6, 1, 0)
```

```
write.csv(df_all_roofs,
```

```
"D:/....csv",
```

```
row.names=FALSE)
```

```
cat("CSV erfolgreich exportiert.\n")
```