



universität
wien

MASTERARBEIT / MASTER'S THESIS

Titel der Masterarbeit / Title of the Master's Thesis

„Einfluss von Wetterveränderungen auf Lawinengefahrenmuster – Analyse
durch Möglichkeiten der Geokommunikation“

verfasst von / submitted by

Gregor Babka, BSc

angestrebter akademischer Grad/ in partial fulfilment of the requirements for the degree of

Master of Science (MSc)

Wien, 2022 / Vienna, 2022

Studienkennzahl lt. Studienblatt /
degree programme code as it appears on
the student record sheet:

UA 066 856

Studienrichtung lt. Studienblatt /
degree programme as it appears on
the student record sheet:

Masterstudium Kartographie und Geoinformation

Betreut von / Supervisor:

Ass.-Prof. Mag. Dr. Karel Kriz

Danksagung

An erster Stelle möchte ich mich bei meinen Eltern, *Klaus Astner* und *Regina Babka*, bedanken, die mir durch persönliche und finanzielle Unterstützung die Durchführung meines Studiums und speziell die Teilnahme an diversen In- und Auslandsexkursionen ermöglichten. Für die gesammelten Erfahrungen und die Möglichkeit, mein Studium nach meinen eigenen Vorstellungen durchführen zu können, bin ich sehr dankbar.

Einen besonderen Dank möchte ich an dieser Stelle meinem Vater aussprechen, der mich nicht nur inhaltlich, sondern auch motivationstechnisch in allen Schritten bei der Erstellung dieser Masterarbeit unterstützte und ebenfalls das Korrekturlesen der Arbeit übernahm.

Für die hilfsbereite und konstruktive Zusammenarbeit bei Themenfindung und Datenakquirierung möchte ich mich bei den Mitarbeiter*innen des Lawinenwarndienstes Tirol und insbesondere bei *Patrick Nairz* bedanken, der sich zusätzlich die Zeit für ein ausführliches Experteninterview nahm.

Abschließend möchte ich auch meinem Betreuer *Karel Kriz* dafür danken, dass er mir die Möglichkeit aufzeigte, in einem großen Interessensbereich meinerseits diese Arbeit verfassen zu können. Im Laufe des Studiums konnte ich, angefangen mit der Hochgebirgsexkursion oder der Auslandsexkursion nach Armenien, aber auch im Zuge der Erstellung meiner Bachelor- und Masterarbeit, sehr interessante Aspekte der Lawinenkunde kennenlernen, was ich mir bei Antritt des Studiums in dieser Form wahrlich nicht erwartet hatte.

Inhaltsverzeichnis

Abbildungsverzeichnis.....	iv
Tabellenverzeichnis	v
Kurzfassung	vi
Abstract	vi
1. Einleitung.....	1
1.1. Problemstellung	2
1.2. Forschungsfrage	2
1.3. Ziel der Arbeit	3
2. Methodik	3
3. Theorie und Konzept	6
4. Kartographie und Geokommunikation.....	8
5. Entstehungsfaktoren von Lawinen	11
5.1. Konstante Faktoren	12
5.1.1. Hangneigung	12
5.1.2. Exposition	13
5.1.3. Geländeform.....	14
5.2. Variable Faktoren	15
5.2.1. Wetter	15
5.2.2. Schneedecke	18
6. Lawinenwarnung	22
6.1. Grundlegendes zur Lawinenwarnung.....	22
6.2. Informationspyramide.....	23
6.2.1. Gefahrenstufe.....	23
6.2.2. Kernzone der Gefahrenstufe	24
6.2.3. Lawinenprobleme.....	25
6.2.4. Gefahrenbeurteilung mittels Gefahrenmuster	27
6.2.5. Zusatzinformationen und Messwerte	37
6.3. Lawinenlagebericht	38
7. Datenanalyse	39
7.1. Auswahl repräsentativer Wetterstationen	39
7.2. Datenverfügbarkeit und Qualität	49
7.3. Aufbereitung der Daten	54
7.4. Analysemethode.....	59
7.4.1. Entscheidende Werte für Ergebnisinterpretation.....	63
7.4.2. Datenlücken.....	64

8.	Analyseergebnisse	66
8.1.	Gefahrenmuster 1: Bodennahe Schwachschicht	66
8.2.	Gefahrenmuster 2: Gleitschnee	70
8.3.	Gefahrenmuster 6: Lockerer Schnee und Wind	74
8.4.	Gefahrenmuster 10: Frühjahrssituation.....	79
9.	Schlussfolgerung und Ausblick	83
10.	Literaturverzeichnis	87
Anhang		89

Abbildungsverzeichnis

Abb. 1: Schema der Informationsübertragung (Quelle: Hake et al. 2002: 9).....	9
Abb. 2: Zirkulärer, kartographischer Prozess (Quelle: Kriz 2001: 232)	9
Abb. 3: Einflussfaktoren der Lawinengefahr (Quelle: NEUGEBAUER 2021: 41).....	11
Abb. 4: Untersuchung zur Hangneigung bei von Menschen ausgelösten Lawinenabgängen in der Schweiz zwischen 1987 und 1997 (Quelle: SCHWEIZER und LÜTSCHG 2001: 152)	12
Abb. 5: Häufigkeit von Schneebrettlawinen in Abhängigkeit von der Hangneigung (Quelle: NAIRZ et al. 2011: 51)	13
Abb. 6: Abbauende Metamorphose (Quelle: EAWS 2022)	19
Abb. 7: Aufbauende Metamorphose (Quelle: EAWS 2022)	20
Abb. 8: EAWS-Informationspyramide (Quelle: EAWS 2021).....	23
Abb. 9: Natürlicher, kontinuierlicher Verlauf der Lawinengefahr (Quelle: LWD Tirol 2021 ²).....	24
Abb. 10: Kernzone der Gefahrenstufe (Quelle: LWD Tirol 2021 ⁴).....	24
Abb. 11: Symbol für das Neuschneeproblem (Quelle: LWD Tirol 2021 ⁵).....	25
Abb. 12: Symbol für Tribschneeproblem (Quelle: LWD Tirol 2021 ⁵).....	25
Abb. 13: Symbol für Altschneeproblem (Quelle: LWD Tirol 2021 ⁵)	25
Abb. 14: Symbol für das Nassschneeproblem (Quelle: LWD Tirol 2021 ⁵)	26
Abb. 15: Symbol für das Gleitschneeproblem (Quelle: LWD Tirol 2021 ⁵).....	26
Abb. 16: Räumliche Verteilung von gm.1 (Quelle: LWD Tirol)	28
Abb. 17: Zeitliche Verteilung von gm.1 (Quelle: LWD Tirol)	28
Abb. 18: Räumliche Verteilung von gm.2 (Quelle: LWD Tirol)	29
Abb. 19: Zeitliche Verteilung von gm.2 (Quelle: LWD Tirol)	30
Abb. 20: Räumliche Verteilung von gm.3 (Quelle: LWD Tirol)	30
Abb. 21: Zeitliche Verteilung von gm.3 (Quelle: LWD Tirol)	30
Abb. 22: Räumliche Verteilung von gm.4 (Quelle: LWD Tirol)	31
Abb. 23: Zeitliche Verteilung von gm.4 (Quelle: LWD Tirol)	31
Abb. 24: Räumliche Verteilung von gm.5 (Quelle: LWD Tirol)	32
Abb. 25: Zeitliche Verteilung von gm.5 (Quelle: LWD Tirol)	32
Abb. 26: Räumliche Verteilung von gm.6 (Quelle: LWD Tirol)	33
Abb. 27: Zeitliche Verteilung von gm.6 (Quelle: LWD Tirol)	33
Abb. 28: Räumliche Verteilung von gm.7 (Quelle: LWD Tirol)	34
Abb. 29: Zeitliche Verteilung von gm.7 (Quelle: LWD Tirol)	34
Abb. 30: Räumliche Verteilung von gm.8 (Quelle: LWD Tirol)	35
Abb. 31: Zeitliche Verteilung von gm.8 (Quelle: LWD Tirol)	35
Abb. 32: Räumliche Verteilung von gm.9 (Quelle: LWD Tirol)	36
Abb. 33: Zeitliche Verteilung von gm.9 (Quelle: LWD Tirol)	36
Abb. 34: Räumliche Verteilung von gm.10 (Quelle: LWD Tirol)	37
Abb. 35: Zeitliche Verteilung von gm.10 (Quelle: LWD Tirol)	37
Abb. 36: Auszug aus dem Lagebericht vom 06.12.2020 (Quelle: LWD Tirol 2021 ³).....	38
Abb. 37: Übersichtskarte der ausgewählten Wetterstationen (Quelle: eigene Darstellung)	41
Abb. 38: Standortkarte Station Tuxerjoch (Quelle: eigene Darstellung).....	42
Abb. 39: Standortkarte Station Magdeburger Hütte & Hechenberg (Quelle: eigene Darstellung)	43
Abb. 40: Standortkarte Station Mosesgipfel (Quelle: eigene Darstellung)	44
Abb. 41: Standortkarte Station Nachtweide & Palinkopf (Quelle: eigene Darstellung).....	45
Abb. 42: Standortkarte Station Rendl Riffel 1 & Salzboden (Quelle: eigene Darstellung)	46
Abb. 43: Standortkarte Station St. Veit (Quelle: eigene Darstellung)	47
Abb. 44: Standortkarte Station Valdafur & Tscheyegg (Quelle: eigene Darstellung)	48
Abb. 45: Rohdaten Lufttemperatur (Datenquelle: LWD Tirol; eigene Darstellung).....	49
Abb. 46: Einlesen der Rohdaten und entfernen von Ausreißern (Quelle: eigene Darstellung)	50
Abb. 47: Ausfiltern von Messfehlern (Quelle: eigene Darstellung).....	50

Abb. 48: Berechnung der Tagesmittelwerte (Quelle: eigene Darstellung)	51
Abb. 49: Berechnung der Tagesdifferenzwerte (Quelle: eigene Darstellung)	51
Abb. 50: Rohdaten Gefahrenmuster 2010-2018 (Datenquelle: LWD Tirol; eigene Darstellung)	52
Abb. 51: Rohdaten Gefahrenmuster 2018-2020 (Datenquelle: LWD Tirol; eigene Darstellung)	52
Abb. 52: Einlesen der Gefahrenmusterdaten (Quelle: eigene Darstellung).....	53
Abb. 53: Gefahrenmuster und Gefahrenstufen in den Östlichen Tuxer Alpen im Winter 2018/19 (Quelle: eigene Darstellung).....	54
Abb. 54: Gefahrenmuster und Gefahrenstufen in den Östlichen Tuxer Alpen im Winter 2019/20 (Quelle: eigene Darstellung).....	55
Abb. 55: Schneehöhen und Gefahrenmuster in den Östlichen Tuxer Alpen im Winter 2018/19 (Quelle: eigene Darstellung).....	56
Abb. 56: Schneehöhen und Gefahrenmuster in den Östlichen Tuxer Alpen im Winter 2019/20 (Quelle: eigene Darstellung).....	56
Abb. 57: Luftfeuchte und Gefahrenmuster in den Östlichen Tuxer Alpen im Winter 2018/19 (Quelle: eigene Darstellung).....	57
Abb. 58: Luftfeuchte und Gefahrenmuster in den Östlichen Tuxer Alpen im Winter 2019/20 (Quelle: eigene Darstellung).....	57
Abb. 59: Lufttemperatur und Gefahrenmuster in den Östlichen Tuxer Alpen im Winter 2018/19 (Quelle: eigene Darstellung).....	58
Abb. 60: Lufttemperatur und Gefahrenmuster in den Östlichen Tuxer Alpen im Winter 2019/20 (Quelle: eigene Darstellung).....	58
Abb. 61: Auswahl eines Gefahrenmusters (Quelle: eigene Darstellung)	59
Abb. 62: Hinzufügen einer Dummyvariable (Quelle: eigene Darstellung)	60
Abb. 63: Angepasste Auswahl eines Gefahrenmusters (Quelle: eigene Darstellung).....	60
Abb. 64: Verknüpfung der Wetter- und Gefahrenmusterdaten (Quelle: eigene Darstellung)	61
Abb. 65: Darstellung der kombinierten Wertetabellen (Quelle: eigene Darstellung)	61
Abb. 66: Beispielauswertung eines Modells (Quelle: R-bloggers 2021)	63
Abb. 67: Darstellung der Untersuchungsergebnisse (Quelle: eigene Darstellung)	84

Tabellenverzeichnis

Tabelle 1: Übersicht der ausgewählten Wetterstationen	40
Tabelle 2: Übersicht über absolute Auftrittszahlen der Gefahrenmuster in Tirol im Untersuchungszeitraum 2010-2018 (Quelle: eigene Darstellung)	62
Tabelle 3: Beispielauswertung zum Auftreten vom gm.10 am Stationsstandort Tuxerjoch im Winter 2019/20 (Quelle: eigene Darstellung)	64
Tabelle 4: Übersicht über erstellte Modelle	66
Tabelle 5: Trainingsdaten gm.1, Modell 1: Tuxerjoch	67
Tabelle 6: Trainingsdaten gm.1, Modell 2: St. Veit	68
Tabelle 7: Trainingsdaten gm.1, Modell 3: Mosesgipfel	68
Tabelle 8: Trainingsdaten gm.2, Modell 1: Mosesgipfel	71
Tabelle 9: Trainingsdaten gm.2, Modell 2: Rendl Riffel 1 und Salzboden	72
Tabelle 10: Auswertungen der Prognosegenauigkeit der Modelle zu gm.2	73
Tabelle 11: Trainingsdaten gm.6, Modell 1: Tuxerjoch	75
Tabelle 12: Trainingsdaten gm.6, Modell 2: St. Veit	75
Tabelle 13: Trainingsdaten gm.6, Modell 3: Rendl Riffel 1 und Salzboden	76
Tabelle 14: Auswertungen der Prognosegenauigkeit der Modelle zu gm.6	78
Tabelle 15: Trainingsdaten gm.10, Modell 1: Rendl Riffel 1 & Salzboden	79
Tabelle 16: Trainingsdaten gm.10, Modell 2: St. Veit	80
Tabelle 17: Auswertungen der Prognosegenauigkeit der Modelle zu gm.10	81
Tabelle 18: Gegenüberstellung der Untersuchungsergebnisse	85

Kurzfassung

Das Themengebiet der Lawinenwarnung unterliegt auf Basis modernster Technologien und einer großen Menge geographischer Daten einem ständigen Wandel und strebt stets nach einer Optimierung der Informationsvermittlung, in dessen Prozess die Bedeutung der Geokommunikation zum Tragen kommt. Ein großes Ziel der Lawinenwarndienste ist es, komplexe Vorgänge in und auf der Schneedecke für eine stetig wachsende Zielgruppe verständlich zu kommunizieren und dabei Informationsverluste weitgehend zu vermeiden. Das Angebot, das zur Übermittlung dieser themenrelevanten Inhalte verwendet wird, wird laufend erweitert, um das Ziel der bestmöglichen Informationsvermittlung zu gewährleisten. Im Zuge dessen wurde mit den Gefahrenmustern 2010 eine weitere Möglichkeit zum ausgiebigen Repertoire hinzugefügt, die eine Situationsbeschreibung auf Basis wiederkehrender Muster ermöglicht und Nutzer*innen Informationen über die Ursachen der Lawinengefahr vermitteln soll. Die vorliegende Arbeit widmet sich der detaillierten Untersuchung dieser Gefahrenmuster und will unter Berücksichtigung der wichtigsten meteorologischen Einflussfaktoren durch statistische Analysen Zusammenhänge im Auftreten einzelner Gefahrenmuster identifizieren. Es wird versucht, mithilfe von Wetterstationsdaten Auftrittswahrscheinlichkeiten zu prognostizieren und somit eine weitere Komponente zur geokommunikativen Informationsvermittlung lawinenrelevanter Inhalte bereitzustellen und die vorrangig auf empirischen Erfahrungswerten der Lawinenprognostiker*innen basierte Entscheidungsfindung bei der Ausgabe der Gefahrenmustern mit statistischen Ergebnissen zu unterstützen.

Abstract

Based on modern technologies and a rising amount of geospatial data, the topic of avalanche warning is under constant change. A primary goal of local avalanche warning systems is to accomplish the optimization of information transfer, where the importance of geo-communication comes into play. The complexity of the processes leading to avalanche danger requires a communication of those topics, while understandability must be guaranteed for a growing audience. To ensure a complete information of the prevailing situation, danger patterns were described in 2010 and elaborated as an additional tool in the avalanche report. This thesis attempts to use statistical evaluations to uncover the extent to which those danger patterns are influenced by the weather, using weather station measurements. A detailed data analysis thus shall expose and procure relations in between those effects and play its part in the evolving topic of avalanche warning, while supporting the staff of avalanche warning systems with additional statistical information in the creation of daily avalanche reports.

1. Einleitung

Der zunehmende Trend zu Skitouren im freien Gelände, durchaus zusätzlich angefeuert durch COVID-19-bedingte Einschränkungen des klassischen Skitourismus seit März 2020, führt unweigerlich zu einer größeren Zielgruppe für den umfangreichen Themenbereich der Lawinenkunde. Neben einer Ausbildung für Neueinsteiger ist vor allem der Aspekt der Lawinenwarnung in der Vorbereitung auf eine Tour im freien Gelände unverzichtbar. Die zuständigen Lawinenwarndienste leisten diesbezüglich eine sehr gute Arbeit und verbessern ihr Informationsangebot laufend und passen es den aktuell geltenden Standards an, wodurch die Gefahr einer Lawinenauslösung in der Folge präventiv vorgebeugt beziehungsweise weitgehendst minimiert werden soll. Dieses Angebot wurde unter der Obhut der Leiter des Lawinenwarndienstes Tirol im Jahr 2010 mit der Veröffentlichung des Buches „Lawine. Die 10 entscheidenden Gefahrenmuster erkennen.“ (MAIR und NAIRZ 2010) um eine weitere Komponente ausgeweitet. Unter dem Leitspruch „Die erkannte Gefahr ist bekanntlich eine halbe Gefahr.“ sollte mithilfe dieses Buches und der im Zuge dessen neu entwickelten Lawinengefahrenmuster das Informationsangebot für Wintersportler und Interessierte zusätzlich erweitert werden.

Die folgende Masterarbeit beschäftigt sich umfassend mit der Bedeutung der Geokommunikation in der Lawinenwarnung mit einem sehr spezifischen Fokus auf diese Lawinengefahrenmuster und deren Abhängigkeit von meteorologischen Einflussfaktoren in Form von Wetterstationsdaten. Während der Zusammenhang von Lawinengefahrenstufen und Wetterlagen (vgl. ZOTTLER et al. 2014) bereits das Objekt wissenschaftlicher Untersuchungen war, wurde der Zusammenhang der 10 entscheidenden Gefahrenmuster (vgl. MAIR und NAIRZ 2010) mit dem unmittelbaren Wettergeschehen, noch keiner vergleichbaren Analyse unterzogen und gilt bis auf empirische Erfahrungen im täglichen Arbeitsspektrum der Lawinenwarndienste als statistisch weitgehend unerforscht. Dies kann unter anderem damit begründet werden, dass die Ausgabe von Gefahrenmustern im Lawinenlagebericht einer sehr subjektiven Einschätzung der zuständigen Lawinenprognostiker*innen unterliegt. Eine Datenanalyse zum Zusammenhang von Wetterstationsdaten und dem Auftreten bestimmter Gefahrenmuster im Rahmen dieser Masterarbeit soll dabei helfen, diese Informationslücke zu schließen und statistische Ergebnisse zum Thema liefern, um das Ziel der bestmöglichen Informationsvermittlung in Bezug auf die Lawinenwarnung zu unterstützen.

Insbesondere hat sich diese Arbeit zum Ziel gesetzt, die Gefahrenmuster auf ihre meteorologischen Einflussfaktoren zu untersuchen und infolgedessen zu versuchen, mithilfe von Wetterstationsdaten Rückschlüsse auf das Auftreten der Gefahrenmuster herstellen zu können. Da es sich bei den erarbeiteten Lawinengefahrensmustern – wie der Name bereits verrät – um wiederkehrende Muster handelt, ist es für die Forschung interessant herauszufinden, inwiefern sich diese Muster mit statistischen Wetterdaten unterlegen und damit in Zukunft möglicherweise besser prognostizieren lassen, um das ohnehin gute Informationsangebot der Lawinenkunde um eine weitere Komponente zu ergänzen.

1.1. Problemstellung

Der Trend in der Lawinenwarnung geht in den letzten Jahren dahin, einen internationalen Standard zu schaffen, der eine länderübergreifende Beurteilung der Lawinengefahr erleichtern soll. So werden in Österreich in täglich erscheinenden Lawinenlageberichten neben den international genormten Gefahrenstufen und auftretenden Lawinenproblemen seit 2010 auch sogenannte Gefahrenmuster zur detaillierten Beschreibung der Lawinengefahr herangezogen. Dabei wird auf die Ursache der Lawinenproblematik und Vorgänge in der Schneedecke eingegangen und durch diese Beschreibungen versucht, ein noch besseres Bild der Lawinengefahr zu vermitteln. Wie die gesamte Lawinengefahr sind auch die Gefahrenmuster dabei stark wetterabhängig und werden von den verschiedenen meteorologischen Einflussfaktoren unterschiedlich beeinflusst.

Dieser Einfluss und die damit einhergehende, möglichst genaue Vorhersage und das damit verbundene Verständnis über die Vorgänge in der Schneedecke sind nicht nur für Freizeitsportler, sondern auch für den Schutz alpiner Infrastruktur während der Wintermonate von großem Interesse und sollen mithilfe dieser Arbeit weiter untersucht werden. Angestrebt sind statistische Auswertungen, die im Zuge der Entscheidungsfindung der zuständigen Lawinenwarndienste herangezogen werden können, um die Prozesse und Einflussfaktoren noch besser nachvollziehen zu können.

1.2. Forschungsfrage

Aus der vorangegangenen Problemstellung ergibt sich folgende Forschungsfrage:

- Wie wirken sich Wetterveränderungen auf die lawinenrelevanten Gefahrenmuster aus?

Zur Beantwortung dieser umfangreichen Frage, wird die Bearbeitung mehrerer Arbeitsfragen herangezogen, um die komplexe Forschungsfrage auf ihre Einzelteile herunterzubrechen.

Um den komplexen Prozessen des Wettergeschehens auf den Grund zu gehen und mögliche Konsequenzen auf die Auftrittszahlen von Gefahrenmustern beschreiben zu können, sollen die Auswirkungen der einzelnen relevanten meteorologischen Parameter im Zuge der Datenanalyse detailliert begutachtet werden. Dabei soll ein Augenmerk auf die Datenerfassung und Aussagekraft von solchen Wetterstationsdaten gelegt werden und gleichzeitig die Relevanz der einzelnen Parameter in Hinblick auf die unterschiedlichen Gefahrenmuster thematisiert werden, da sich diese in ihren typischen Auftrittsbedingungen teils stark voneinander unterscheiden.

- Wie wirken sich die einzelnen meteorologischen Parameter Lufttemperatur, Schneehöhe, Windgeschwindigkeit und Luftfeuchte kurzfristig auf die Lawinengefahrenmuster aus?

Die Bestimmung der Gefahrenmuster unterliegt subjektiven Einschätzungen des jeweiligen Lawinenwarndienstes, wobei neben den Wetterstationsdaten weitere Entscheidungshilfen wie Schneeprofile, Lawinenereignisse und Geländebeobachtungen ebenfalls eine tragende Rolle spielen. In einem weiteren Schritt sollen daher die Wetterstationsdaten dazu herangezogen werden, um eine Prognose der Gefahrenmuster aufzustellen und diese mit realen Auftrittszahlen vergleichen zu können. Dadurch sollen Rückschlüsse auf die Bedeutung der Datensätze in der Gefahrenmusterbestimmung gezogen werden können.

- Inwiefern lassen sich Auftritte der Gefahrenmuster prognostizieren und aufgrund meteorologischer Parameter begründen?

Falls diese Prognose gelingt, wäre es interessant herauszufinden, ob die Untersuchung auf mehrere Gefahrenmuster ausgeweitet werden kann. Im Lawinenlagebericht des Lawinenwarndienstes Tirol werden seit 2018 für jede Region bis zu zwei Gefahrenmuster pro Tag ausgegeben. Es soll versucht werden, häufige Kombinationen aufzudecken und diese Häufungen mithilfe statistischer Auswertungen der Wetterstationsdaten zu unterlegen.

- Welche Gefahrenmuster treten häufig in Kombination auf und inwiefern lassen sich diese mit wiederkehrenden Wetterereignissen erklären?

Aus der Bearbeitung dieser Arbeitsfragen soll ein Erkenntnisgewinn gezogen werden, mithilfe dessen die übergeordnete Forschungsfrage beantwortet und der Einfluss von Wetterveränderungen auf ausgewählte Lawinengefahrenmuster statistisch unterlegt werden kann.

1.3. Ziel der Arbeit

Übergeordnetes Ziel der Arbeit ist die Untersuchung der Korrelation zwischen Veränderungen im Wetter und den lawinenrelevanten Gefahrenmustern. Eine Datenanalyse soll Aufschluss darüber geben, wie sich kurzfristige Veränderungen im Wetter auf die Angabe der Gefahrenmuster im Lawinenlagebericht auswirken und signifikante statistische Zusammenhänge aufdecken. Die Abfolge der Gefahrenmuster ist ebenfalls zu untersuchen und auf Ursachen in den meteorologischen Messdaten zu prüfen. Schließlich ist ein Ergebnis angestrebt, das konkrete Zusammenhänge des lawinenrelevanten Wettergeschehens mit den Gefahrenmustern aufdeckt und statistisch nachweist.

Unter Beachtung wichtiger Grundsätze der Geokommunikation ist die bestmögliche Informationsvermittlung dieser Analyseergebnisse angestrebt.

Zur Bearbeitung der in Kapitel 1.2 formulierten Forschungsfragen sind Kenntnisse in mehreren Themenbereichen vonnöten, weshalb ein grober Überblick über die wichtigsten Begriffe als Ergebnis einer intensiven Literaturrecherche zu den relevanten Themengebieten gegeben wird.

Neben der Rolle der Kartographie in der Lawinenwarnung, insbesondere der Geokommunikation und den Darstellungsmöglichkeiten raumbezogener Daten soll auch ein Grundverständnis zur Lawinenkunde und zum Einfluss des Wetters in der Lawinenkunde vermittelt werden. Dabei wird die Arbeit der Lawinenwarndienste etwas näher unter die Lupe genommen und so ein Einblick in die tägliche Entscheidungsfindung zur Gefahrenbeurteilung im Lawinenlagebericht ermöglicht.

2. Methodik

Im folgenden Kapitel wird auf die methodische Vorgehensweise Bezug genommen, anhand derer eine Umsetzung der in Kapitel 1.3. festgelegten Ziele dieser Masterarbeit durch die Beantwortung der in Kapitel 1.2. ausformulierten Forschungsfragen erreicht werden soll. Es werden sämtliche Schritte dokumentiert, die von der ersten Idee bis schließlich zur Durchführung der binären logistischen

Regression vorgenommen wurden, um den Arbeitsprozess, der dazu geführt hat, vorzustellen und gewisse Entscheidungen auf dem Weg dorthin zu begründen.

Vorrangig werden zwei Zugänge verwendet, um die Erreichung der Ziele zu gewährleisten. Einerseits eine ausführliche Literaturrecherche, um den gegenwärtigen Stand der Forschung auszuarbeiten und einen Einblick in die relevanten Themengebiete der Arbeit zu erhalten. Diese Literaturrecherche umfasst die Sichtung und Erklärung der bestehenden wissenschaftlichen Literatur zu den Themenkomplexen Geokommunikation und Lawinenkunde und kann als Grundlage zur weiteren Bearbeitung des Forschungsgebietes angesehen werden. Andererseits wird nach detaillierter Auseinandersetzung mit den wichtigsten Begrifflichkeiten anhand einer statistischen Datenanalyse die Beantwortung der Forschungsfrage angestrebt. Diese statistische Auswertung soll Zusammenhänge zwischen den untersuchten Datensätzen aufdecken und den Einfluss von Wetterstationsdaten auf die Gefahrenmuster zahlengestützt bestimmen, um ein aussagekräftiges Ergebnis zu liefern.

Das Forschungsgebiet wurde gewählt, weil der Verfasser ein großes Interesse im Themengebiet der Lawinenkunde hat und durch die Kooperation des Instituts für Geographie und Regionalforschung der Universität Wien mit diversen Lawinenwarndiensten die Möglichkeit gegeben war, dieses Interesse in Form einer wissenschaftlichen Arbeit weiter zu verfolgen. Die Spezialisierung auf die Lawinengefahrenmuster kann damit begründet werden, dass im Zuge einer Literaturrecherche herausgefunden wurde, dass ein Zusammenhang mit dem Wettergeschehen noch keiner statistischen Untersuchung unterzogen wurde und daher eine gewisse Relevanz in diesem Bereich gegeben war.

Die Bearbeitung des Themengebietes bedarf einer intensiven theoretischen Auseinandersetzung mit dem Themenkomplex der Geokommunikation und Lawinenwarnung, bevor eigene Untersuchungen angestellt werden konnten. Der Arbeit liegt somit eine ausführliche Literaturrecherche zugrunde, deren Ergebnisse in den Kapiteln 2 bis 4 dargelegt werden und den vorhandenen Wissensstand zur Geokommunikation und Lawinenkunde widerspiegeln, wobei ein besonderes Augenmerk auf die Bedeutung der Gefahrenmuster als zentrales Interessensobjekt dieser Arbeit gelegt werden soll. Die Bedeutung und der Einfluss des Wetters für die Lawinengefahr soll anhand der verschiedenen meteorologischen Einflussfaktoren dargelegt werden, die im Rahmen der Datenanalyse im weiteren Verlauf auf die statistischen Auswirkungen auf die Gefahrenmuster untersucht werden soll. Dadurch wird der aktuelle Stand der Forschung herangezogen und durch die Erklärung der Begrifflichkeiten eine Grundlage für die weitere Bearbeitung des Themengebietes geschaffen.

Zu Beginn dieser Forschungsarbeit wurde nach der Literaturrecherche und dem Konkretisieren der Arbeitsziele nach einer Möglichkeit gesucht, die Lawinengefahrenmuster auf ihren Zusammenhang mit dem Wettergeschehen zu untersuchen. Unumgänglich war dabei der Zugang zu entsprechenden Datensätzen, die in Österreich allerdings nicht frei zur Verfügung stehen. Ein erster Versuch, mit dem Lawinenwarndienst Steiermark in Kontakt zu treten, führte zu keinem zufriedenstellenden Ergebnis, weshalb der Kontakt zum Lawinenwarndienst Tirol und dessen Leiter DI Patrick Nairz hergestellt wurde, mit dem der Verfasser bereits im Laufe seines Studiums im Rahmen der Hochgebirgsexkursion und bei der Ausarbeitung seiner Bachelorarbeit zu tun hatte. Kooperationsbereit wurden sogleich erste Ideen ausgetauscht und anhand von übermittelten Testdatensätzen das methodische Vorhaben konkretisiert.

Bereits in diesen ersten Schritten wurde das Statistikprogramm RStudio, eine integrierte Entwicklungsumgebung für die statistische Programmiersprache R (<https://www.rstudio.com/>), aufgrund der vielseitigen Möglichkeiten in Hinblick auf Datenanalysen und Ergebnisdarstellungen zur weiteren Verwendung ausgewählt und verschiedene Analysemethoden getestet.

Als wichtiger Zwischenschritt zur Erreichung der Ziele ist eine repräsentative Auswahl der Wetterstationen, deren Daten im weiteren Verlauf verwendet werden sollen, unumgänglich. Zur Gewährleistung signifikanter Analyseergebnisse müssen themenrelevante Kriterien wie Lage, Exposition und Seehöhe der Messstellen genauer untersucht werden, um eine speziell für die Lawinengefahrenmuster aussagekräftige Auswahl an Stationen treffen zu können. Der Fokus liegt hierbei auf der Auswahl einer möglichst geringen Anzahl an Stationen, die den Einfluss der meteorologischen Parameter auf die unterschiedlichen Lawinengefahrenmuster bestmöglich darlegen. In Kapitel 7.1 wird der konkrete Ablauf des Auswahlprozesses und eine detaillierte Beschreibung der ausgewählten Stationen vorgestellt.

Nach der Auswahl der Wetterstationen und dem Erhalt der entsprechenden Datensätze zu den meteorologischen Messwerten sowie den Lawinengefahrenmustern wurde in einem weiteren Schritt die Datenqualität überprüft und diverse Anpassungen vorgenommen, um die Daten für eine folgende Analyse vorzubereiten. In Kapitel 7.2 werden diese Arbeitsschritte detailliert beschrieben.

Aufgrund der guten Datenqualität der lawinenbezogenen Daten, die auch die Gefahrenmuster beinhalten, ist hier vor allem eine Generalisierung und Fehlerbereinigung der meteorologischen Messdaten notwendig, da diese über den Untersuchungszeitraum von 10 Jahren lediglich in 10-Minuten Intervallen vorliegen und aufgrund der oft hochalpinen Standorte eine regelmäßige Wartung und Instandhaltung nicht immer garantiert werden kann. Um Datenfehler zu verhindern, die die Analyse später beeinträchtigen können, müssen die Datensätze in diesem Zwischenschritt separat überprüft und für die weitere Verwendung vorbereitet werden.

Erschwerend war dabei jedoch die Tatsache, dass die Datenstruktur der Gefahrenmuster im Zeitraum von 2010 - 2018 Unterschiede zu jener nach 2018 aufwies. Es musste ein Weg gefunden werden, um beide Datensätze für dieselbe Analyse verwendbar zu machen, was schließlich in einer Datenselektion und dem Erstellen einer Dummyvariable für das jeweils zu untersuchende Gefahrenmuster mündete.

In einem weiteren Schritt wurde aufgrund der vorliegenden Datentypen und Forschungsziele in der binären logistischen Regression eine passende Analysemethode gefunden, mithilfe derer die Auswirkungen mehrerer unabhängiger Variablen, in diesem Fall die Messwerte der meteorologischen Parameter, auf eine abhängige Variable, hier das ausgewählte Gefahrenmuster, untersucht werden konnten. Dabei wird anhand eines Trainingsdatensatzes einer ausgewählten Station ein Modell erstellt, das mögliche Zusammenhänge des Auftretens der Gefahrenmuster an den einzelnen Tagen des verwendeten Untersuchungsraumes mit den einzelnen Einflussparametern statistisch nachweist. Sofern diese Modellerstellung die Überprüfung der Modellgüte übersteht und damit für eine Analyse geeignet erscheint, können in einem nächsten Arbeitsschritt anhand der Datensätze der anderen Wetterstationen Testprognosen durchgeführt werden. Ziel der Analyse ist es, anhand der Modelle eines Standortes die Auftrittstage der Gefahrenmuster an den anderen Standorten richtig zu identifizieren und somit Rückschlüsse auf Zusammenhänge mit den meteorologischen Datensätzen zuzulassen. Die praktische Umsetzung der Analyse ist Thema von Kapitel 7.4.

Um die statistischen Analyseergebnisse mit einer empirischen Expertenmeinung vergleichend gegenüberstellen zu können, wurde als zusätzliches Instrument ein Interview mit dem Leiter des Lawinenwarndienst Tirol geführt. Der erstellte Leitfaden sollte unter Berücksichtigung der, für die Arbeit relevanten Teilbereiche, einen Einblick in die subjektive Entscheidungsfindung der Lawinenprognostiker*innen ermöglichen, um eine Gegenüberstellung mit den statistischen Auswertungen durchführen zu können und dabei gleichzeitig die Relevanz der Wetterstationsdaten in der täglichen Arbeit der Lawinenwarndienste herausfinden. Der ausgearbeitete Leitfaden für die Durchführung des Interviews ist in Anhang 1.1 zu finden, in Anhang 1.2 kann das Interview in seiner Gänze begutachtet werden.

3. Theorie und Konzept

Um ein differenziertes Bild davon abgeben zu können, inwiefern die gewählte und in Kapitel 2 beschriebene Methodik in der Theorie zur Beantwortung der wissenschaftlichen Fragestellung beitragen kann, wird im folgenden Kapitel auf diesen Punkt Bezug genommen. Mögliche Zusammenhänge zwischen Wetter und Lawinengefahr werden unter Berücksichtigung weiterer Einflussfaktoren thematisiert, Hintergründe und Einzelheit der bevorzugten Analysemethoden beleuchtet und angestrebte Ergebnisse, aber auch Nicht-Ziele der wissenschaftlichen Untersuchung im Zuge dessen klar definiert.

Grundsätzlich ist es allgemeiner Konsens in der Lawinenkunde, dass der Einfluss des Wetters eine sehr große Rolle in der Lawinenwarnung spielt, was bereits KELLERMANN (1989) lange vor der Einführung von heute bekannten Lawinenwarnstandards mit seiner Aussage zur Bedeutung der verschiedenen Witterungseinflüsse als wichtigsten Aspekt bei der Beurteilung der Lawinengefahr hervorhob. Ziel dieser wissenschaftlichen Arbeit ist es jedoch, diesen Einfluss statistisch zu untermauern und die tatsächliche Bedeutung von Daten auf die Entscheidungen des Lawinenwarndienst Tirol zu überprüfen, da neben den Messwerten besonders subjektiven Einschätzungen vonseiten der Lawinenprognostiker*innen und deren Erfahrungsschatz als Basis jahrelanger Auseinandersetzung mit dem Thema ebenfalls eine sehr große Bedeutung zugeschrieben werden muss, wie auch Patrick Nairz im Interview (siehe Anhang 1.2) deutlich klarstellte.

Das Konzept hinter der folgenden Datenanalyse kann somit dadurch beschrieben werden, dass der statistische Einfluss auf persönliche Entscheidungen (schließlich handelt es sich bei der Verfassung eines Lageberichts um die persönliche Einschätzung der zuständigen Lawinenwarndienste) anhand der Messdaten der Wetterstationen untersucht werden soll.

Unter Verwendung der Rohdaten der Messstandorte ist eine Prognose der Gefahrenmuster angestrebt, die subjektive Einschätzungen außen vor lässt und damit den rein datenspezifischen Aspekt und dessen Bedeutung in der Entscheidungsfindung untersucht. Als Grundkonzept der Datenanalyse ist die Modellierung von Witterungssituationen angestrebt, unter denen mit einem bestimmten Gefahrenmuster statistisch zu rechnen ist und diese Modellergebnisse schließlich mit den realen Auftritten der Gefahrenmuster zu vergleichen. Um eine möglichst präzise Aussage diesbezüglich treffen zu können, ist es vonnöten mehrere relevante Wetterparameter in die Untersuchung miteinzubeziehen und so vorherrschende Witterungssituationen möglichst akkurat zu modellieren. Da die einzelnen Gefahrenmuster unterschiedlichen meteorologischen Einflüssen unterliegen (siehe Kapitel 6.2.4), ist es von großer Bedeutung für die Modellerstellung, die Parameter nach spezifischen Einflüssen auf die zu untersuchenden Gefahrenmuster auszuwählen, um die statistischen Auswirkungen von Wetterveränderungen ausfindig zu machen und die Ergebnisse nicht durch irrelevante Variablen zu verzerren. Gleichzeitig soll aus der Analyse hervorgehen, welche meteorologischen Größen jeweils den größten Einfluss auf die Gefahrenmuster haben und somit ein zusätzlicher Erkenntnisgewinn gewährleistet werden.

Bewerkstelligt soll die Untersuchung dieser Zusammenhänge mit der Durchführung binärer logistischer Regressionen zu den unterschiedlichen Gefahrenmustern werden. Wie bereits in Kapitel 2 erläutert, soll diese Analysemethoden anhand der Trainingsdaten einer ausgewählten Station Situationen modellieren, die mit dem zu untersuchenden Gefahrenmuster in Verbindung stehen. Vereinfacht gesagt, werden alle Auftrittstage des Gefahrenmusters auf statistische Zusammenhänge in den vorherrschenden Witterungssituationen untersucht und so in den meteorologischen Messdaten nach Gründen für das Auftreten des jeweiligen Gefahrenmusters gesucht.

Kann das Modell statistische Zusammenhänge mit den Messdaten finden, wird es anhand der Daten anderer Stationen überprüft, wobei wiederum jene Tage ausfindig gemacht werden sollen, an denen ein Gefahrenmuster tatsächlich im Lagebericht erwähnt wurde. Es handelt sich dabei im Grunde um eine Prognose der Auftrittstage auf Basis der statistischen Zusammenhänge, die bei der Modellerstellung anhand der Daten der Trainingsstation gefunden wurden. Konnte die Modellerstellung keine Zusammenhänge mit den Messdaten liefern, wird auch eine Prognose an einer anderen Station keine Beziehung zwischen den meteorologischen Daten und den Gefahrenmustern ausfindig machen können. Ist die Modellerstellung jedoch erfolgreich und kann anhand der Trainingsdaten eine Relation zwischen Wettereinflüssen und Gefahrenmustern aufzeigen, so wird versucht, diese Beziehungen auch bei anderen Stationen zu ermitteln und so die Bedeutung der statistischen Werte skizziert. Die Prognose mithilfe der Modelle wird dementsprechend mit den tatsächlichen Auftrittstagen der Gefahrenmuster abgeglichen und kann infolgedessen Genauigkeiten der einzelnen Modelle identifizieren, indem der Prozentsatz an korrekt prognostizierten Auftritten begutachtet wird.

Aufgrund der Bedeutung weiterer Einflüsse auf die Lawinengefahr und im Zuge dieser Ausarbeitung spezifisch auf die Lawinengefahrenmuster, die nicht nur mit Zahlen und Messwerten beschrieben werden können, wie beispielsweise Metamorphoseprozessen innerhalb der Schneedecke (siehe Kapitel 5.2.2) ist eine 100-prozentige Prognose der Auftrittstage äußerst unwahrscheinlich und nicht als Ergebnis dieser Arbeit angestrebt. Vielmehr soll die Datenanalyse aufzeigen, inwiefern unter Verwendung statistischer Messwerte eine Aussage zum Auftreten von Gefahrenmustern getroffen werden kann und in welchem Zusammenhang die jeweiligen meteorologischen Parameter zu den einzelnen Gefahrenmustern stehen. Im Grunde wird ein Modell ab einer Prognosegenauigkeit von 70% als gut angesehen, wobei natürlich auch jene Tage in die Genauigkeit einfließen, an denen Gefahrenmuster nicht ausgegeben wurden. Wenn ein Modell beispielsweise alle 35 Tage ausfindig machen kann, an denen in einer bestimmten Wintersaison gm.6 im Lawinenlagebericht erwähnt wurde, gleichzeitig aber auch 50 Tage als solche mit gm.6 ausweist, an denen es jedoch real nicht auftrat, kann das Modell nicht als präzise Vorhersage behandelt werden und aufgedeckte Zusammenhänge mit den statistischen Messwerten müssen als unzureichend gekennzeichnet werden.

Um das Aufdecken falscher Konnexionen zu vermeiden, wird dieses Konzept nicht nur anhand der Trainingsdaten einer Station untersucht, sondern zu jedem Gefahrenmuster werden Modelle mit den Daten unterschiedlicher Stationen und Jahre erstellt, die wiederum alle an den Daten der Teststationen auf ihre Genauigkeit überprüft werden. Damit wird bewerkstelligt, dass zufällig aufgedeckten Zusammenhängen keine zu große Bedeutung zugeschrieben wird und die Prognosemöglichkeit eines spezifischen Gefahrenmusters abschließend als Summe aller Modellüberprüfungen bewertet werden kann. Weisen die Ergebnisse der binären logistischen Regressionen zu einem bestimmten Gefahrenmuster im Mittel ähnliche Ergebnisse auf, lässt das Rückschlüsse auf die Zusammenhänge mit den Stationsdaten zu. Ist das nicht der Fall und die Modelle unterscheiden sich sehr stark untereinander oder können nicht die angestrebte Genauigkeit von 70% erreichen, so muss als Erkenntnis eine zu geringe beziehungsweise nicht vorhandene Kausalität zwischen meteorologischen Messwerten und dem Auftreten des untersuchten Gefahrenmusters als solche gekennzeichnet und behandelt werden.

4. Kartographie und Geokommunikation

In einem ersten Schritt der Literaturrecherche wurde der Themenbereich der Kartographie mit speziellem Augenmaß auf den Aspekt der Geokommunikation und die damit beschriebenen Möglichkeiten der Kommunikation räumlicher Daten näher untersucht und chronologisch aufbereitet.

Um die Bedeutung der Geokommunikation in der Gesellschaft und in Bezug auf diese Arbeit speziell auf die Lawinenwarnung darlegen zu können, ist ein Blick auf die jüngere Vergangenheit der Kartographie empfehlenswert.

Der Aufgabenbereich der Kartographie unterlag nicht zuletzt aufgrund technischer Neuerungen und einer damit einhergehenden Vielzahl an neuen Möglichkeiten in den letzten Jahren einem gewissen Wandel, was die Prozesse und Kommunikationsmöglichkeiten betrifft.

„Über Jahrhunderte hinweg waren ihre graphischen Darstellungen trotz aller inneren und äußeren Vielfalt stets zugleich Medium und Speicher raum-zeitlicher Informationen, und Zahlen dienten weitgehend nur als bloße Hilfsmittel auf dem Wege zur Graphik. Im heutigen Informationszeitalter besitzen dagegen die Zahlen durch den vielseitigen Einsatz der digitalen Rechentechnik einen eigenen Stellenwert von zentraler Bedeutung.“ (HAKE et al. 2001: 3)

Dabei wird die große Bedeutung der klassischen analogen Karte als Kommunikationsmedium vor der Digitalisierung hervorgehoben.

„Lange Zeit waren nur die Karte und ihre kartographischen Ausdrucksformen Forschungsobjekte der Kartographie, wobei das Letztere meistens nur am Rande behandelt wurde und geringe, wissenschaftliche Beachtung fand. Die Karte stand im Mittelpunkt des Interesses und wurde als kartometrisches Grundrissbild der Wirklichkeit gesehen.“ (KRIZ 2001: 230)

Demzufolge wurde die klassische Informationsübertragung als unidirektionaler Prozess vom Sender über einen Kanal (analoges Kartenmaterial) zum Empfänger angesehen. Das Schema der Informationsübertragung nach Hake (siehe Abb. 1) visualisiert diesen Prozess, bei dem mithilfe von Symbolen und Zeichen Informationen über eine analoge Karte übermittelt werden.

Dabei wird vorausgesetzt, dass nicht nur der Sender (Kartograph), sondern auch der Empfänger ein gewisses kartographisches Grundverständnis mitbringt, ohne das die effiziente Kommunikation der Information scheitern würde. Wie in vielen anderen Bereichen der modernen Kommunikation erfolgt die Darstellung der raumbezogenen Informationen zu einem großen Teil in Grafiken und kann lediglich durch die visuelle Aufnahme ebendieser durchgeführt werden. (vgl. KRIZ 2013: 10)

Die im Prozess integrierte Störquelle (Abb. 1) soll diesen Unsicherheitsfaktor darstellen, der in gewisser Weise mithilfe einer ausführlichen Zeichenerklärung reduziert werden kann, jedoch nur einen Informationsaustausch in eine Richtung ermöglicht.




Abb. 1: Schema der Informationsübertragung (Quelle: Hake et al. 2002: 9)

Durch die Entwicklungen in der Kartographie als Wissenschaft ist dieser Weg der Informationsübertragung in der heutigen, durch digitale Medien beeinflussten Gesellschaft nicht mehr ausreichend, um die Kommunikation von Geodaten zu beschreiben.

„Betrachtet man den kartographischen Prozess nicht als ‚Einbahnstraße‘, wo lediglich in eine Richtung produziert bzw. kommuniziert wird – Produkt zum Nutzer – sondern als zirkulären, dynamisch-interaktiven Vorgang, dann erhält die Kartographie eine neue Dimension“ (Kriz 2001: 230).

Dieser zirkuläre Prozess (siehe Abb. 2) beschreibt die moderne Form der Informationsübertragung deutlich besser, wenn man beispielsweise an interaktive digitale Kartenwerke denkt, bei denen dieser zirkuläre Prozess durch die Interaktion des Nutzers mit den Inhalten besonders stark ausfällt.




Abb. 2: Zirkulärer, kartographischer Prozess (Quelle: Kriz 2001: 232)

Das Modell baut dabei auf den drei Grundsäulen der Gestaltung, Kognition und Kommunikation auf. Besonders dem letztgenannten Punkt der Kommunikation wird in der Kartographie eine stetig wachsende Bedeutung zuteil, der Begriff der Geokommunikation ist daher aus der modernen Kartographie nicht mehr wegzudenken.

BRODERSEN (2007) spricht gar von einem Paradigmenwechsel von der Kartographie zur Geokommunikation, aufgrund der sich wandelnden Bedeutung der Karte und der veränderten Bedingungen in der Übermittlung räumlicher Informationen. Zwar ist die Kerndisziplin der Kartographie nach wie vor die Erstellung von Karten, das Verständnis und die Umsetzung dieser Karten hat sich jedoch nicht zuletzt aufgrund der Digitalisierung und dem Einsatz von computergestützten Methoden drastisch verändert.

Im Zuge des angesprochenen Paradigmenwechsels ist die Karte somit nicht mehr als einziges und zentrales Medium der Kommunikation räumlicher Information, sondern lediglich als ein Teilstück der Geokommunikation anzusehen (vgl. BRODERSEN 2005). Die Karte ist nicht mehr die primäre Informationsquelle, wie sie es im analogen Zeitalter durchaus war (vgl. KRIZ 2001; HAKE et al. 2002), sondern vielmehr eine der möglichen Ausdrucksformen der Geoinformation, die heutzutage mithilfe vieler anderer Informationsquellen bereitgestellt werden können (vgl. BRODERSEN 2007).

Die angesprochene Vielzahl an Kommunikationsmöglichkeiten reicht dabei von Texten mit raum-zeitlichem Bezug, Zahlen und Tabellen, über vereinfachte graphische Darstellungen wie Piktogrammen bis hin zu komplexen Diagrammen und verschiedensten Kartenformen sowie kartenverwandten Darstellungen.

Die Lawinenwarnung bedient sich in ihrer Arbeit einer Vielzahl dieser Möglichkeiten, um das Ziel der Informationsübermittlung gewährleisten zu können. Man kann durchaus von einer Omnipräsenz der Geokommunikation in der Lawinenwarnung sprechen, da sie einen zentralen Baustein zur Erfüllung der Ziele der Lawinenwarndienste, der raum-zeitlichen Informationsvermittlung zur Lawinengefahr, darstellt. Konkret kann der digitale Lawinenlagebericht als gutes Beispiel zur Umsetzung des zirkulären Kommunikationsmodells angesehen werden, da dem Nutzer durch eine Vielzahl an Möglichkeiten Zugang zu detaillierten, interaktiven Inhalten zur Verfügung gestellt wird.

Auf die praktische Umsetzung der Geokommunikation in der Lawinenwarnung wird in Kapitel 6 insofern näher eingegangen, dass die Arbeit der Lawinenwarndienste mit speziellem Blick auf die angewandte Geokommunikation vorgestellt wird. Im Anschluss wird in Kapitel 5 zuvor jedoch noch die Entstehung von Lawinen und damit die Grundlage der Lawinenkunde näher unter die Lupe genommen.

5. Entstehungsfaktoren von Lawinen

In diesem zweiten Schritt der Literaturrecherche lag der Fokus sehr stark auf den Einflussfaktoren, die zur Ausbildung einer Lawinengefahr führen und somit den Grundstein für die Arbeit der Lawinenwarndienste legen. Dem Leser soll ein Bild davon vermittelt werden, wie komplex und vielseitig dieser Themenbereich ist und wodurch Gefahrensituation beeinflusst werden können, um im weiteren Verlauf der Arbeit selbst Rückschlüsse ziehen zu können.

„Die Beurteilung der Lawinengefahr ist schwierig. Dabei spielen die Faktoren Schnee- und Wetterverhältnisse (meteorologische Komponente), das Gelände (topographische Komponente) und letztendlich der Mensch selbst eine entscheidende Rolle.“ (KRIZ und GALANDA 1998: 117)

„Ob überhaupt und zu welchem Zeitpunkt eine Lawine losbricht, lässt sich auch mit den heutigen wissenschaftlichen Erkenntnissen nicht genau voraussagen. Zu vielfältig sind die verschiedenen Auslösefaktoren. Dabei spielen der Aufbau der Schneedecke mit ihren Gleit- und schwachen Schichten, die Neigung, Exposition und Bodenbeschaffenheit eines Hanges ebenso eine Rolle wie die Neuschneemenge, Wind, Temperatur und Sonneneinstrahlung. Eine Lawine löst sich, sobald die Schneedecke instabil und die Belastung größer als ihr Widerstand wird.“ (AMMANN et al. 1997: 74)

„Die Ursache einer Lawinenauslösung ist daher eine Störung im Gleichgewicht der Schneedecke. Schnee bricht auf entsprechenden Hangneigungen aus seinem Verband aus, weil die treibenden Kräfte größer werden als die rückhaltenden.“ (ERNEST 1981: 74)




Abb. 3: Einflussfaktoren der Lawinengefahr (Quelle: NEUGEBAUER 2021: 41)

Grundsätzlich kann man die wichtigsten Einflussfaktoren zur Lawinenbildung, wie in Abbildung 3 dargestellt, in einer Dreiecksbeziehung aus dem Gelände, dem Wetter und der Schneedecke erklären, wobei der Mensch und sein Handeln stets als vierte und zentrale Komponente in Betracht gezogen werden müssen.

Die äußeren Einflussfaktoren lassen sich in konstante und variable Faktoren gliedern, wobei das Gelände, mit Ausnahme von Geländeformen wie Mulden oder Kammlagen, die durch Schneeverfrachtungen lokalen Veränderungen unterliegen können, als zeitlich konstante Größe bezeichnet werden kann und damit sozusagen die Grundvoraussetzung für die Entstehung einer Lawine bildet. (vgl. KRIZ und GALANDA 1998: 117)

Als variable Faktoren können hingegen die Wetterverhältnisse und der Schneedeckenaufbau bezeichnet werden, die im Laufe des Winters aufgrund verschiedenster meteorologischer Einflussfaktoren teils großen Veränderungen unterliegen und so die Entstehung einer Lawinengefahr kurzfristig stark beeinflussen.

5.1. Konstante Faktoren

Im Folgenden wird auf die konstanten Faktoren der Lawinengefahr Bezug genommen, die zusammenfassend auch als Geländefaktoren bezeichnet werden können. Die verschiedenen Ausprägungen und Auswirkungen sollen dabei vorgestellt werden, um ihre Rolle in der Lawinenwarnung zu verorten.

„Das Gelände ist ein essenzieller Faktor zur Lawinenbildung und dabei der einzige Faktor, der über die Zeit konstant bleibt“ (SCHWEIZER et al. 2003: 3).

Die wichtigsten Einflussgrößen zur Beschreibung des Geländes in Zusammenhang mit der Lawinengefahr, stellen die Hangneigung, die Exposition des Hanges und die Geländeform dar. (vgl. ERNEST 1981: 99; KRIZ und GALANDA 1998: 117)

5.1.1. Hangneigung

„Ab einer gewissen Neigung des Hanges steigt die Wahrscheinlichkeit eines Lawinenabganges deutlich an“ (KRIZ und GALANDA 1998: 117).

„Je steiler das Gelände ist, desto häufiger wird mit Lawinenabgängen zu rechnen sein. Die günstigste Hangneigung für die Lawinenbildung ist zwischen 20° und 50°.“ (ERNEST 1981: 101)

Grundsätzlich gilt ein Gelände ab einer Hangneigung von 30° als Voraussetzung für die Auslösung einer Schneebrettlawine, wobei unter besonderen Bedingungen auch in flacheren Hangbereichen Lawinen ausgelöst werden können. (vgl. SCHWEIZER et al. 2003: 3)

„Bei einer Untersuchung aller 617 von Menschen ausgelösten Lawinen in den Schweizer Alpen zwischen 1987 und 1997 [Anm. siehe Abb. 4] konnte eine durchschnittliche Hangneigung von 38,7° festgestellt werden, wobei in 40% der Fälle die Hangneigung größer als 40° war“ (SCHWEIZER und LÜTSCHG 2001: 152).




Abb. 4: Untersuchung zur Hangneigung bei von Menschen ausgelösten Lawinenabgängen in der Schweiz zwischen 1987 und 1997 (Quelle: SCHWEIZER und LÜTSCHG 2001: 152)

Ähnliche Ergebnisse führen auch NAIRZ et al. (2011: 51) an, wonach 50% der Schneebrettlawinen in einem Anbruchgebiet mit einer Hangneigung zwischen 35° und 40° auftreten, wie in Abbildung 5 ersichtlich wird.




Abb. 5: Häufigkeit von Schneebrettlawinen in Abhängigkeit von der Hangneigung (Quelle: NAIRZ et al. 2011: 51)

„Oberhalb von 45° brechen hauptsächlich Lockerschneelawinen an“ (ebd.). Mit fortschreitender Hangneigung nimmt die Wahrscheinlichkeit einer Lawinenauslösung stark ab, was wiederum darauf zurückzuführen ist, dass in diesen Steilhanglagen meist deutlich geringere Schneemengen akkumuliert werden.

„Bei Neigungen über 50° tritt meist schon während des Schneefalles eine portionsweise Entladung der Hänge ein. Als Anbruchgebiete kommen Hänge mit derartigen Neigungen kaum mehr in Frage.“ (ERNEST 1981: 101)

Mit Verweis auf die Bedeutung weiterer Einflussfaktoren ist somit vorrangig der Hangneigungsbereich zwischen 30° und 45° als Anbruchgebiet großer und gefährlicher Lawinenauslösungen zu bewerten. (vgl. NAIRZ et al. 2001: 51)

5.1.2. Exposition

„Die Exposition beeinflusst stark die Lawinenbildung“ (ERNEST 1981: 102).

Dabei führen NAIRZ et al. (2011: 54) die Rolle der Exposition eines Anbruchgebietes nicht nur durch die Lage zu den Hauptwinden, sondern auch durch die Lage zur Sonneneinstrahlung als einen entscheidenden Faktor für die Lawinenbildung an.

Die Auswirkungen der Lage zur Sonneneinstrahlung ist in saisonaler Abhängigkeit differenziert zu betrachten, so wird die Setzung der Schneedecke an Sonnenhängen auf Grund der höheren Einstrahlung beschleunigt, was einen raschen Abbau einer latenten Lawinengefahr zur Folge hat und somit begünstigend auf die Lawinensituation wirkt. (vgl. ebd; ERNEST 1981: 102)

„Die intensivere Strahlung an Südhängen kann allerdings wiederum im Frühjahr zu einem gehäuften Auftreten von Nassschneelawinen führen“ (NAIRZ et al. 2011: 54), da die strahlungsbedingte Temperaturerhöhung mit einer Durchnässung der Schneedecke die Stabilität ebendieser markant verringert.

Die Auswirkungen der expositionsbedingten Lagefaktoren beschränken sich jedoch nicht nur auf den sonnenzugewandten Südbereich. Zu erwähnen sei hierbei, dass sämtliche Expositionsangaben in Bezug zum Sonnenstand im Rahmen dieser Arbeit unter der Annahme einer Situationsbeschreibung auf der Nordhemisphäre getroffen wurden.

„An Schattenhängen wird die Schwimmschnee- und Oberflächenreifbildung begünstigt. Dieser Vorgang tritt besonders im Frühwinter ein, wenn die Temperaturunterschiede zwischen Tag und Nacht noch relativ groß sind.“ (ERNEST 1981: 102)

SCHWEIZER und LÜTSCHG (2001: 153) konnten bei der Untersuchung der Lawinenunfälle zwischen 1987 und 1997 feststellen, dass rund 60% der Lawinen in Schattenhängen ausgelöst wurden.

Trotz der großen Bedeutung der Lage zur Sonneneinstrahlung, darf die Lage zu den Hauptwinden nicht außer Acht gelassen werden.

„Besonders gefährdet sind neben den Schattenhängen vor allem Leehänge wegen der vermehrten Triebsschneeansammlungen“ (ERNEST 1981: 102), worauf in Kapitel 5.1.3 näher eingegangen wird.

Zusammenfassend ist zu beachten, dass unterschiedliche Lagefaktoren mit veränderten Einflüssen auf die Lawinengefahr kombiniert werden und sich je nach Exposition verschiedene Gefahrenmuster ausbilden und häufen können. (siehe Kapitel 6.2.4)

5.1.3. Geländeform

„Geländeformen sind sehr wichtig für die Erkennung von Gefahrenbereichen. Kammlagen und Geländekanten können beispielsweise entscheidend für Schneeverfrachtungen und für die Bildung von Wechten sein. Schnee, der durch starke Winde verfrachtet und auf die Leeseite abgelagert wird, kann durch seine Struktur die Bildung von Lawinen fördern.“ (KRIZ und GALANDA 1998: 118)

Bei der Untersuchung der Lawinenunfälle zwischen 1987 und 1997 konnten SCHWEIZER und LÜTSCHG (2001: 154) feststellen, dass 52% der Lawinen in kammnahen Bereichen ausgelöst wurden. Als besonders gefährliche Geländeformen zur Lawinenauslösung konnten Mulden und Rinnen ausgemacht werden.

Aber nicht nur in Hinblick auf Schneeverfrachtungen spielt die Geländeform eine Rolle für die Lawinenbildung.

„An glatten, einförmigen Hängen entstehen besonders leicht Lawinen. Jede Unterlage, wie Felsplatten, gleichmäßige Grashänge (...) und kleinsteinige Schuttriesen begünstigen die Lawinenbildung.“ (ERNEST 1981: 103)

Obwohl der Geländeeinfluss bei der Beurteilung der Lawinengefahr jedenfalls berücksichtigt werden muss, so verweist ERNEST (1981: 103) jedoch darauf, dass der Geländeeinfluss auf die Lawinengefahr meist überbewertet wird. Weiters führt er an, dass dem Wetter und seinem Einfluss auf die Schneedecke eine weit größere Bedeutung zukommt, was er mit der Aussage

„Es gibt kein ausgewiesenes Lawinengelände, wohl aber Lawinenzeiten“ (ebd.)

deutlich hervorhob.

5.2. Variable Faktoren

Die von ERNEST (1981: 103) erwähnten Lawinenzeiten können auch mit dem Begriff der variablen Einflussfaktoren beschrieben werden. Als solche variable Einflussfaktoren der Lawinengefahr werden das Wettergeschehen und die Schneedecke bezeichnet. Das Wetter spielt dabei eine bedeutende Rolle, da es sich unmittelbar auf die Zusammensetzung der Schneedecke auswirkt und somit die Grundlage zur Entstehung variabler Lawinenfaktoren darstellt. Die beiden Faktoren Wetter und Schneedecke werden in diesem Kapitel auf ihre wichtigsten Eigenschaften überprüft und sollen ein Verständnis über die zeitlich variablen Entstehungsfaktoren und ihre Ausprägungen vermitteln.

5.2.1. Wetter

Im Folgenden wird der meteorologische Aspekt in Hinblick auf die Lawinengefahr beschrieben, da die verschiedenen Einflussfaktoren unterschiedliche Auswirkungen auf den Aufbau und die Zusammensetzung der Schneedecke und infolgedessen auf die Gefahrenentstehung haben. Es soll gleichzeitig ein kurzer Einblick in die wichtigsten Wetterparameter und deren Messungsmethoden gegeben werden, um eine Basis für die folgende Datenanalyse bereitzustellen und eine der wichtigsten Informationsquellen der Lawinenwarndienste vorzustellen.

„Die meteorologische Komponente ist maßgeblich dafür verantwortlich, dass Lawinen überhaupt entstehen. Schneefall, Niederschlagsintensität, Wind, Temperatur und der daraus resultierende Schneedeckenaufbau sind variable Faktoren, die sich über die Zeit ständig verändern.“ (KRIZ und GALANDA 1998: 117)

Niederschlag

Grundsätzlich gilt Niederschlag als wichtigster Vorhersageparameter für große Lawinenereignisse und so steht Neuschnee in enger Relation mit einem Anstieg der Lawinengefahr. (vgl. SCHWEIZER 2003: 5)
Bei Schneefall ohne Windeinwirkung –

„Windeinwirkung erhöht die Gefahr beträchtlich“ (KELLERMANN 1989: 138)

– werden grundsätzlich Neuschneemengen zwischen 30 und 50cm als kritisch für die natürliche Selbstauslösung von Lawinen angesehen, während für die künstliche Auslösung durch Wintersportler bei ungünstigen Verhältnissen abhängig von äußeren Einflüssen wie Wind oder Temperatur bereits Neuschneemengen zwischen 10 und 20cm als kritisch angesehen werden können. (vgl. SCHWEIZER 2003: 5)

Fällt der Niederschlag als Regen, ist durch den Wassereintrag in die Schneedecke und die daraus resultierende große Zusatzbelastung kurzfristig fast immer mit einer Zunahme der Lawinengefahr zu rechnen. (vgl. MAIR und NAIRZ 2010: 68)

Eine Messung des Niederschlages erfolgt gewöhnlich in mm, während Schneehöhen in cm aufgezeichnet werden. Wichtig ist bei der Niederschlags- oder Schneehöhenmessung vorrangig die Wahl eines repräsentativen Standortes für ein gewisses Gebiet, weshalb solche Stationen oft an flacheren Passagen eines Hanges oder Sattellagen installiert werden, da hier die Akkumulation einer aussagekräftigen Schneedecke gegeben ist und nicht durch etwaige Geländefaktoren beeinflusst wird.

Wind

„Der Wind ist der Baumeister der Lawinen‘: Dieser klassische Spruch von Wilhelm Paulcke aus den dreißiger Jahren des vorigen Jahrhunderts gilt auch heute noch unverändert. Wind beeinflusst sowohl den fallenden als auch den bereits abgelagerten Schnee und ist einer der wesentlichsten Lawinen bildenden Faktoren.“ (MAIR und NAIRZ 2010: 113)

Die Auswirkung des Windes auf die Lawinenintensität spiegelt sich in einer erhöhten Sprödigkeit des Schnees und in örtlich erhöhten Schneeeablagerungen wider. (vgl. NAIRZ et al. 2011: 42)

„Bläst der Wind mit mehr als 25 Stundenkilometern, vermag er nämlich Schnee zu transportieren. Er wirbelt den trockenen Neuschnee auf, trägt ihn über Kreten und Bergkämme (...) und lagert ihn auf ihren Windschattenseiten (Leehängen) als Tribschneeansammlungen ab.“ (AMMANN et al. 1997: 84)

„Aus diesem Grund ist neben der Windgeschwindigkeit auch die Windrichtung von besonderem Interesse in der Lawinenwarnung. Als Windrichtung wird jene Himmelsrichtung bezeichnet, aus welcher der Wind kommt.“ (ERNEST 1981: 26)

„Doch der Wind verfrachtet den Schnee nicht nur auf die Windschattenseite (Lee) von Bergkämmen. Auch auf der Windseite (Luv) kann es in Rinnen, Runsen und Mulden zu gefährlichen Tribschneeansammlungen kommen.“ (AMMANN et al. 1997: 84)

„Windbegleitende Schneefälle und Tribschneeansammlungen sind stets lawinenverdächtig. Der Wind verdichtet den gefallenen Neuschnee, die einzelnen Kristalle sind daher nicht mehr frei beweglich, und so kommt es zu ungünstigen Spannungsverhältnissen auf geneigter Unterlage.“ (KELLERMANN 1989: 138f)

Aufgrund der großen Bedeutung des Windes für die Lawinenwarnung, erfolgt eine Messung dieser Variable sowohl in Form der Windgeschwindigkeiten (km/h), Windböen (km/h) sowie der ebenfalls relevanten Windrichtung (°). Dabei ist es wichtig, diese Daten unverfälscht aufzuzeichnen, weshalb Windmessstationen meist an ausgesetzteren Stellen verortet sind als die Messstationen zu anderen meteorologischen Parametern. Ausgesetzt bedeutet in diesem Fall, dass die Standorte so gewählt werden, dass die tatsächlich vorherrschenden Winde ohne Ablenkungen oder Verfälschungen gemessen werden können, was beispielsweise in Kamm- oder Gipfellagen der Fall ist.

Lufttemperatur

Die Lufttemperatur spielt ebenso eine entscheidende und komplexe Rolle in der Lawinenkunde, da sich ihre Veränderung auf unterschiedliche Weise auf die Schneedeckenstabilität auswirken kann. Dabei werden primär oberflächennahe Schneeschichten beeinflusst. (vgl. SCHWEIZER et al. 2003: 7)

„Tiefe Temperaturen konservieren eine bestehende oder entstehende Lawinensituation, weil sich bei tieferen Temperaturen die Schneekristalle in der Schneedecke nur wenig verändern und die Setzung der Schneedecke nur langsam fortschreitet. Eine langsame Erwärmung hingegen fördert einerseits die Setzung der Schneedecke, andererseits unterstützt sie aber auch die aufbauende Metamorphose [Anm.: s. Kapitel 5.2.2] und beeinflusst damit die Festigkeit der Schneedecke negativ.“ (AMMANN et al. 1997: 86f)

„Warmlufteinbrüche und Föhn schaffen an allen Hangrichtungen eine Lawinenkrise, die aber durch die rasche Entladung oft nur kurzzeitig ist“ (KELLERMANN 1989: 137).

„Die Messung der Lufttemperatur ist meteorologisch genau definiert. Man versteht darunter jene Temperatur, die im Schatten (früher meist in einer Wetterhütte) 2 m über dem Boden gemessen wird. Bei modernen automatischen Wetterstationen wird keine Wetterhütte mehr verwendet, da diese im Hochgebirge eine zu große Angriffsfläche für die oft stürmischen Höhenwinde bietet. Auch ohne Wetterhütte wird aber durch einen Strahlungsschutz und eventuell eine Belüftung gewährleistet, dass man die Temperatur ‚im Schatten‘ misst.“ (MAIR und NAIRZ 2010: 196)

„Die Lufttemperatur nimmt üblicherweise mit der Seehöhe ab. Bei trockener Luft beträgt diese Abnahme etwa 1°C/100 m, bei feuchter Luft nur noch 0,5°C/100 m. Ausnahmen bilden Inversionswetterlagen, vor allem im Winter“ (ebd.).

Globalstrahlung

Besonders im Frühling, wenn die Temperatur der Schneedecke nahe am Schmelzpunkt ist, verläuft ein Anstieg der Lawinengefahr parallel mit der tageszeitlichen Erwärmung, weshalb am Nachmittag die Lawinengefahrenstufe unter diesen Umständen aufgrund der starken Sonneneinstrahlung oft als höher einzuschätzen ist als am Vormittag. (vgl. AMMANN et al. 1997: 87)

Luftfeuchtigkeit

Hier ist zwischen absoluter und relativer Luftfeuchtigkeit zu unterscheiden. Die absolute Feuchte gibt die Wasserdampfmenge an, die sich momentan in einer Volumeneinheit Luft befindet und wird üblicherweise in Gramm pro Kubikmeter (gm/m^3) angegeben. (vgl. MAIR und NAIRZ 2010: 198)

„Dieser Wert ist temperaturabhängig: Je wärmer die Luft, desto mehr Feuchtigkeit kann sie aufnehmen. So kann etwa 1 m³ Luft bei 0°C maximal 4,8 g Wasserdampf enthalten, bei 30°C aber schon 30,3 g! Diesen Wert bezeichnet man als maximal mögliche Feuchte. Gebräuchlicher als die absolute Feuchte ist die Angabe der relativen Feuchte: Diese gibt in Prozent an, wie viel von der maximal möglichen Wasserdampfmenge tatsächlich in der Luft vorhanden ist“ (ebd.).

„Bei 100% relativer Luftfeuchtigkeit ist die absolute Luftfeuchtigkeit so hoch wie die Sättigungsfeuchtigkeit.“ (KELLERMANN 1989: 64)

Die Luftfeuchtigkeit spielt in der Lawinenkunde insofern eine relevante Rolle, dass bei Erreichen des Sättigungsgrades (100% relativer Luftfeuchte) der überschüssige Wasserdampf in flüssiger Form ausgeschieden wird und Kondensation entsteht. Erfolgt die Ausscheidung in fester Form wie Eiskristallen, wird es als Sublimation bezeichnet. (vgl. ERNEST 1981: 21) Jene Tau- (Kondensation) oder Reifbildung (Sublimation) in oder auf der Schneedecke hat oft die Ausbildung einer störanfälligen Schwachschicht zur Folge, was bei erneutem Schneefall zu einer kritischen Lawinensituation führen kann und u.a. näher in Kapitel 6.2.4 unter gm.8 Eingeschneider Oberflächenreif thematisiert wird.

Taupunkt

„Der Taupunkt ist jene Temperatur, auf die man Luft abkühlen muss, damit Sättigung – also 100% relative Luftfeuchte – eintritt. Bei gesättigter Luft ist also der Taupunkt ident mit der Lufttemperatur. Je trockener die Luft aber ist, desto mehr liegt der Taupunkt unterhalb der Lufttemperatur. Wird der Taupunkt erreicht bzw. unterschritten, so setzt Kondensation ein (Wolkenbildung).“ (MAIR und NAIRZ 2010: 198)

„Wenn auch die drei Hauptelemente für die Beurteilung der Lawinengefahr (Gelände, Schneedecke, Wetter) stark ineinander verzahnt sind, so sind es trotzdem die verschiedenen Witterungseinflüsse, die zu guter Letzt eine Beurteilungsentscheidung am massivsten beeinflussen“ (KELLERMANN 1989: 137).

Aus diesem Grund betreiben die Lawinenwarndienste eine Vielzahl an Wetterstationen, um die Entwicklungen in all ihren regionalen Unterschieden stets beobachten zu können und eine Informationsgrundlage zu schaffen, auf Basis derer schließlich Entscheidungen getroffen werden können. Näheres zur Arbeit der Lawinenwarndienste folgt in Kapitel 6.

5.2.2. Schneedecke

Den zweiten variablen Faktor bei der Entstehung von Lawinen stellt neben dem Wetter die Schneedecke dar, die nicht nur in ihrer Mächtigkeit während eines Winters variiert, weshalb in diesem Subkapitel der Fokus stark auf die Veränderungen innerhalb der Schneedecke, die einen maßgeblichen Einfluss auf die Lawinengefahr haben, gerichtet ist. Dabei ist es wichtig, die verschiedenen Metamorphoseprozesse näher zu erläutern, da einige Gefahrenmuster stark von diesen abhängig sind.

„Schnee ist ein höchst komplexes Material, das sich ständig verändert“ (MAIR und NAIRZ 2010: 101).

„Ab dem ersten Schneefall im Frühwinter lagert sich jeder folgende Schneefall als neue Schicht auf der Altschneedecke ab. Durch den Wetterverlauf wird Schnee in Schichten unterschiedlicher Stärken und Eigenschaften abgelagert.“ (ERNEST 1981: 58)

Beispielsweise sorgen Wind oder Temperaturunterschiede in verschiedenen Luftschichten, durch die die Schneekristalle fallen, für Veränderungen in Größe und Form der Schneekristalle, wodurch sich in Folge die Eigenschaften des Schnees verändern. (vgl. MAIR und NAIRZ 2010: 101)

„Doch nicht nur die Wetterverhältnisse während des Schneefalls spielen eine Rolle, die Schneedecke reagiert auch nach dem Schneefall auf äußere Einflüsse. In ihrem Innern finden permanent Veränderungen statt, keinen Augenblick bleibt ihr Anfangszustand erhalten.“ (AMMANN et al. 1997: 48)

Sobald die Schneekristalle zu Boden fallen, beginnt der Umwandlungsprozess, der in der Lawinenkunde als Schneemetamorphose bezeichnet wird. (vgl. MAIR und NAIRZ 2010: 101)

„Es handelt es sich dabei um einen stetigen Prozess, der seinen Beginn schon in der Atmosphäre nimmt. Bereits während des Schneefalls ändern sich in verschiedenen Höhengniveaus ständig die Temperatur-, Feuchte- und Windverhältnisse, die sich unmittelbar auf das Kristallwachstum bzw. dessen Zerstörung auswirken. Die Umwandlung setzt sich dann im Zuge der Schneeablagerung am Boden bis zum endgültigen Abschmelzprozess fort. Die Metamorphose ist entscheidend für die Lawinenentstehung, weil sich dadurch Schwachschichten in der Schneedecke bilden.“ (NAIRZ et al. 2011: 34)

Diese Metamorphose ist wiederum von äußeren Einflüssen wie dem Wetter oder dem Temperaturgradienten innerhalb der Schneedecke abhängig und wird in abbauende, aufbauende und Schmelzmetamorphose untergliedert. (vgl. ERNEST 1981: 59; AMMANN et al. 1997: 48)

„Durch diese Umwandlungsprozesse entstehen sowohl andere Formen als auch andere Größen der Schneekristalle. Zudem ändern sich mit Dichte, Porenanteil und Struktur weitere, für die Lawinenbildung wesentliche Eigenschaften.“ (MAIR und NAIRZ 2010: 101)

Abbauende Metamorphose

„Bei der abbauenden Metamorphose wandeln sich die Neuschneekristalle zu körnigem Altschnee um“ (AMMANN et al. 1997: 49).

Der Neuschnee, in seiner ursprünglichen Form regelmäßiger, sechsarmiger Schneekristalle fällt zu Boden und wird unter mechanischer Einwirkung verändert. Zusammenstöße von Kristallen untereinander, Windeinfluss und der Aufprall auf den Boden selbst, sorgen dabei für das Brechen einzelner Arme und Verästelungen, wodurch der Schneekristall kleiner wird. (vgl. MAIR und NAIRZ 2010: 101)

„Damit ist die abbauende Metamorphose jedoch nicht abgeschlossen, der Schneekristall besitzt immer noch zahlreiche Seitenarme. Dem Naturgesetz über die Verkleinerung der freien Energie folgend, haben die Schneekristalle das Bestreben, ihre Oberfläche zu verkleinern. Die kleinste Gestalt der Oberfläche wird erreicht, wenn jedes Kristall Kugelgestalt annimmt.“ (ERNEST 1981: 60)

„Durch Sublimation entsteht an den Spitzen der Schneesterne Wasserdampf, der im kälteren Kristallzentrum wiederum angelagert wird“ (AMMANN et al. 1997: 49).

„Das heißt, es findet laufend ein Massentransport von den verzweigten Ästen in Richtung des Zentrums des Schneekristalls statt“ (MAIR und NAIRZ 2010: 103).

„In diesem Umwandlungsprozess entsteht ein Zwischenstadium, bei dem die Neuschneeformen teilweise noch erhalten sind. Diese Struktur wird als filzig bezeichnet.“ (ERNEST 1981: 60)

Mit Fortschreiten der abbauenden Metamorphose verschwinden jedoch die Spitzen und Kanten der Schneekristalle ganz und es bilden sich runde Körner (siehe Abb. 6). Durch die kompakten und festen Rundkörner, die sich untereinander gut verbinden, kommt es zu einer Setzung und Verfestigung, wodurch die Schneedecke stabiler wird. (vgl. AMMANN et al. 1997: 49; MAIR und NAIRZ 2010: 103)

„Dieser Prozess ist stark von der Schneetemperatur abhängig: Je näher diese bei 0°C liegt, desto schneller schreitet er voran; bei tieferen Temperaturen verzögert sich die abbauende Umwandlung. Üblicherweise dauert die abbauende Umwandlung einige Tage, bei ungünstigeren Verhältnissen – wie z.B. sehr niedrigen Temperaturen und fehlender Sonneneinstrahlung – aber auch bis zu zwei Wochen oder länger.“ (MAIR und NAIRZ 2010: 103)




Abb. 6: Abbauende Metamorphose (Quelle: EAWS 2022)

Aufbauende Metamorphose

„Wenn bei strenger Kälte in der Schneedecke große Temperaturunterschiede entstehen, beginnt die kalte, trockene Luft der oberen Schneesichten nach unten zu sinken und die wärmere, feuchte Luft der bodennahen Schichten anzusteigen“ (ERNEST 1981: 61).

Aufgrund des Bodenwärmestromes und der isolierenden Wirkung der Schneedecke sinkt die Temperatur der bodennahen Schneeschichten selten unter -2°C , wodurch bei tiefen Lufttemperaturen der Temperaturunterschied, auch als Temperaturgradient bezeichnet, zu oberen Schichten und der Schneeoberfläche wächst. Unter diesen Umständen kommt es dazu, dass Wasserdampf von Bodennähe in Richtung der oberen, kälteren Schneeschichten aufsteigt, dort sublimiert und wieder feste Formen bildet. (vgl. MAIR und NAIRZ 2010: 104)

„Es entstehen neue, kantige Kristallformen, die bis zu einer Größe von einigen Millimetern heranwachsen. Dauert der Umwandlungsprozess an, bilden sich daraus becherartige Hohlformen.“ (AMMANN et al. 1997: 51)

In Abbildung 7 wird dieser Prozess der aufbauenden Metamorphose grafisch dargestellt.

Diese Becherkristalle wachsen zu einer Größe von bis zu einem Zentimeter heran und können sich aufgrund ihrer Form nicht mehr gut untereinander verbinden, da weniger Kontaktpunkte als bei rundkörnigen Kristallen vorhanden sind. Infolgedessen nimmt die Festigkeit der Schneedecke ab und eine solche Schicht aus Becherkristallen, die in der Lawinenkunde auch als Schwimmschneeschicht bezeichnet wird, bildet aufgrund dieser fehlenden Verbindungen zwischen den Schneekristallen und der Bildung von luftgefüllten Hohlräumen durch den Materialverlust im Zuge des Wasserdampftransportes in obere Schichten eine instabile Unterlage für die darüberliegenden Schneeschichten. (vgl. AMMANN et al. 1997: 51; ERNEST 1981: 62; MAIR und NAIRZ 2010: 104)

Üblicherweise ist der Prozess der aufbauenden Umwandlung etwas langwieriger als die abbauende Metamorphose, wodurch bis zur Bildung von Becherkristallen in der Regel zwischen zwei bis vier Wochen vergehen. (vgl. MAIR und NAIRZ 2010: 104) Die tatsächliche Geschwindigkeit der aufbauenden Metamorphose hängt dabei stark vom Temperaturgradienten innerhalb der Schneedecke ab. (vgl. ERNEST 1981: 61)

„Ein großes Temperaturgefälle, wie es bei tiefen Außentemperaturen und einer dünnen Schneedecke herrscht, beschleunigt die Bildung von Becherkristallen, während milde Temperaturen und eine dicke und dadurch gut isolierende Schneeschicht sie verlangsamt.“ (AMMANN et al. 1997: 51)

„Schattenhänge sind für die Ausbildung von Schwimmschneekristallen am anfälligsten, weil das Temperaturgefälle zwischen warmer Boden- und kalter Oberflächenschicht meist besonders groß ist“ (ERNEST 1981: 62).




Abb. 7: Aufbauende Metamorphose (Quelle: EAWS 2022)

Schmelzmetamorphose

Die Schmelzmetamorphose, auch Verfirnung genannt, stellt eine Sonderform der Schneenumwandlung dar und findet statt, sofern eine Schneeschicht durch einen Anstieg der Lufttemperatur, durch starke Sonneneinstrahlung oder durch Regeneintrag eine Temperatur von 0°C erreicht und der Schnee zu schmelzen beginnt. Dabei runden sich die Schneekristalle ab und freiwerdendes Schmelzwasser füllt die Poren zwischen den Rundkörnern. (vgl. MAIR und NAIRZ 2010: 68)

„Freies Wasser wirkt sich jedoch in der Summe immer ungünstig auf die Schneedeckenstabilität aus. Speziell während des Frühjahrs bahnt sich deshalb regelmäßig eine sehr lawinenaktive Zeit an.“ (NAIRZ et al. 2011: 37)

„Günstig hingegen ist der Wechsel aus tageszeitlicher Durchfeuchtung und nächtlicher Abkühlung der Schneedecke“ (NAIRZ et al. 2011: 37).

Bei Wiedergefrieren der Schneedecke führt der Wassereintrag zwischen den Körnern zur Ausbildung einer festen Schicht, dem sogenannten Schmelzharsch. (vgl. ERNEST 1981: 63)

„Es entstehen – je nach Kälteexposition – mitunter sehr dicke Schmelzharschdecken mit den typischen zusammengefrorenen, glasigen Rundkörnern“ (MAIR und NAIRZ 2010: 70).

Zusammenfassend ist der Schneemetamorphose und den Veränderungen innerhalb der Schneedecke somit neben dem Wetter als variabler Faktor eine große Bedeutung bei der Entstehung und Beurteilung der Lawinengefahr beizumessen, weshalb sie stets im Entscheidungsprozess berücksichtigt werden muss.

6. Lawinenwarnung

In diesem Kapitel werden die Lawinenwarnung und die Arbeit der Lawinenwarndienste genauer vorgestellt, wodurch eine Einordnung der in dieser Arbeit im Fokus stehenden Lawinengefahrenmuster im Gesamtbild der Lawinenwarnung ermöglicht wird und die Relevanz, der in Kapitel 5 beschriebenen Einflussfaktoren durch die Berücksichtigung im täglichen Schaffensbereich der Lawinenwarnung unterstrichen werden kann.

Die Bedeutung der Lawinenwarnung stieg im Laufe des 20. Jahrhunderts immer stärker an und ist heute aus dem winterlichen Alltag im Hochgebirge nicht mehr wegzudenken. Grundsätzlich besteht die Arbeit der Lawinenwarnung aus einer Prognose zur Einschätzung der Lawinengefahr einerseits zum Schutz alpiner Infrastruktur und andererseits für Privatpersonen, die sich im alpinen Gelände bewegen wollen. In Kapitel 4 wurde bereits auf den Einsatz von geokommunikativen Methoden in der Lawinenwarnung Bezug genommen, die nun im Folgenden näher vorgestellt werden sollen.

6.1. Grundlegendes zur Lawinenwarnung

Die Lawinenwarnung ist in Österreich Aufgabe der einzelnen Bundesländer, wobei die Arbeit mittlerweile europäischen Standards unter Zusammenarbeit verschiedener Lawinenwarndienste des gesamten Kontinents unter dem Projekt EAWS (European Avalanche Warning Services) zur verbesserten Informationsübermittlung unterliegt. Im Folgenden werden die Methoden des Lawinenwarndienstes Tirol zur Erläuterung des Tätigkeitsbereiches herangezogen, da auch die Daten für die spätere Datenauswertung von ebendiesem stammen.

Der Lawinenwarndienst Tirol wurde, vorangetrieben durch die von schweren Lawinenkatastrophen geprägten Wintersaisons 1951 sowie 1954 im Dezember 1960 in Vorbereitungen zu den olympischen Winterspielen in Innsbruck 1964 gegründet und hat sich seither eine möglichst präzise Prognose der Lawinengefahr zum Schutz von Alpinsportlern sowie alpiner Infrastruktur zum Ziel gesetzt.

In seiner mittlerweile über 60-jährigen Geschichte wurde nicht nur der Wissensstand zur Lawinengefahr, sondern auch die Methoden zur Lawinenwarnung immer weiter verbessert und können heute als weltweit führend angesehen werden. Seit der Wintersaison 2018/19 ist der Lawinenwarndienst Tirol Teil des ALBINA Euregio Projektes, das eine gemeinsame, multilinguale und grenzüberschreitende Lawinenvorhersage für die Länder Tirol, Südtirol und Trentino auf einer Website durch optimierte Kartendarstellungen sowie auf Textbausteinen basierenden Beschreibungen intuitiv und vergleichbar präsentiert. (vgl. LWD Tirol 2021⁶)

Die Vorhersage der Lawinengefahr erfolgt in den Wintermonaten im täglich erscheinenden Lawinenlagebericht jeweils für den folgenden Tag und enthält eine Fülle an Informationen aus Wetterstationsdaten, Beobachtungen, Schneeprofilen und Lawinenereignisse zur bestmöglichen Einschätzung der Lawinensituation am Berg. Bereitgestellt wird dieser Lawinenlagebericht vorrangig auf der angesprochenen Website www.lawinen.report, wobei auch ein mobiles Angebot in Form einer Smartphone App angeboten wird. Die Inhalte des Lageberichtes unterliegen dabei internationalen Standards und sind in ihrem Aufbau zur besseren Informationsvermittlung stets ähnlich angeordnet.

6.2. Informationspyramide

Die Erstellung des Lawinenlageberichts ist inhaltlich bei allen Mitgliedern der EAWS gleich aufgebaut und strukturiert. Die Gliederung der Inhalte folgt dem, in Abbildung 8 visualisierten Prinzip der Informationspyramide.



Abb. 8: EAWS-Informationspyramide (Quelle: EAWS 2021)

Die Grundidee hinter der Informationspyramide ist eine hierarchische Präsentation der Inhalte, wonach die wichtigsten Informationen zuerst präsentiert und so die bestmögliche Informationsvermittlung gewährleistet werden kann. Die relevantesten Informationen sind zusammengefasst in der Pyramide oben angesiedelt, während eine Vertiefung der Informationen mit den darunterliegenden Ebenen angestrebt wird.

6.2.1. Gefahrenstufe

Im Fall des Lawinenlageberichts betrifft die wichtigste Information die Gefahrenstufe, da diese unter Berücksichtigung aller Einflussfaktoren einen ersten groben Eindruck der Lawinengefahr vermittelt und medial wirksam und sehr vereinfacht mitteilt.

Die Lawinengefahrenstufen wurden 1993 in Zusammenarbeit der europäischen Lawinenwarndienste standardisiert und basierend auf der Auslösewahrscheinlichkeit von Lawinen, dem Umfang der Gefahrenstellen sowie der Größe und Häufigkeit der zu erwartenden Lawinen in eine fünfteilige ordinale Lawinengefahrenstufenskala kategorisiert, wobei Gefahrenstufe 1 die niedrigste und Gefahrenstufe 5 die höchste Lawinenwarnstufe darstellt.

Die Veränderungen bzw. die Kombination der beschriebenen Eingangsgrößen führen zur Ausgabe einer bestimmten Gefahrenstufe, wobei der Anstieg der Gefahrenstufen nicht als linear, sondern wie in Abbildung 9 dargestellt, eher als überproportional angesehen werden kann.




Abb. 9: Natürlicher, kontinuierlicher Verlauf der Lawinengefahr (Quelle: LWD Tirol 2021²)

Der überproportionale Verlauf der Lawinengefahr, in Abbildung 9 mittels blauer Linie dargestellt, ergibt zugleich eine große Bandbreite der Gefahrenbeurteilung innerhalb der einzelnen Gefahrenstufen.

„Am meisten kommt diese Bandbreite bei der Gefahrenstufe 3 Erheblich zum Ausdruck. Am oberen Rand dieser Gefahrenstufe beobachtet man viele Alarmzeichen (Wummgeräusche, Risse, frische Lawinen) und die Gefahr ist akut. Am unteren Rand dieser Gefahrenstufe fehlen diese deutlichen Hinweise. Häufig wird dadurch – meist unbewusst – risikoreicheres Gelände befahren.“ (LWD Tirol 2021²)

Deshalb sind, wenngleich die Gefahrenstufe an der Spitze der Informationspyramide stehen und damit die wichtigsten Informationen zusammengefasst übermitteln, weitere Informationen zur Lawinensituation notwendig, um eine angemessene Beschreibung und Beurteilung der Lawinengefahr zu veröffentlichen.

6.2.2. Kernzone der Gefahrenstufe

So gibt die Gefahrenstufe, die stets für größere Regionen mit einer Fläche von > 100km² ausgegeben wird, keine Hinweise auf die Lokalität der Gefahr. Dafür werden sogenannte Kernzonen der Gefahrenstufe veröffentlicht, die in der zweiten Ebene der Informationspyramide angesiedelt sind und eine genauere Beschreibung der Problembereiche vor allem hinsichtlich Exposition und Seehöhe übermitteln sollen.

„Eine zusätzliche Orientierung bieten diesbezüglich die Hangrosen- und Höhenstufenpiktogramme, welche die besonders gefährdeten Bereiche grafisch darstellen.“ (MAIR und NAIRZ 2010: 215)



Abb. 10: Kernzone der Gefahrenstufe (Quelle: LWD Tirol 2021⁴)

In Abbildung 10, einem Auszug aus dem Lawinenlagebericht vom 18.12.2020, wird mithilfe der Piktogramme beispielsweise auf besondere Gefahrenstellen in nördlich exponierten Lagen über einer Seehöhe von 2200m hingewiesen, um eine räumliche Eingrenzung der Lawinengefahr zu ermöglichen, was im Textteil des Lageberichtes folgendermaßen erwähnt wird:

„Vorsicht vor allem an steilen Schattenhängen oberhalb von rund 2200m“ (LWD Tirol 2021⁴).

6.2.3. Lawinenprobleme

In der dritten Ebene der Informationspyramide werden sogenannte Lawinenprobleme erwähnt. Wie auch bei den Gefahrenmustern wurden diese Lawinenprobleme unter Zusammenarbeit der europäischen Lawinenwarndienste (EAWS) standardisiert und in fünf typische und wiederkehrende Probleme gegliedert, um die Art der Lawinengefahr international genormt detaillierter beschreiben zu können.

Die Definitionen dieser Lawinenprobleme beinhalten neben einer Beschreibung des Problems, den zu erwartenden Lawinenarten und der charakteristischen räumlichen Verteilung auch die Lage der Schwachschichten innerhalb der Schneedecke. Es konnten Charakteristika hinsichtlich der Art des Auslösemechanismus und der typischen Dauer der Gefährdung der Lawinenprobleme beschrieben werden und gleichzeitig Ratschläge zur Bewegung im Gelände formuliert werden. Die Kennzeichnung der vorherrschenden Lawinenprobleme erfolgt im Lawinenlagebericht auch mithilfe von Grafiken, die im Folgenden bei der kurzen Vorstellung der einzelnen Lawinenprobleme ebenfalls angeführt werden.

Neuschneeproblem



„Das Problem entsteht durch aktuelle Schneefälle oder kurz zuvor gefallenem Neuschnee. Der Haupteinflussfaktor ist die kritische Neuschneemenge, die von mehreren Faktoren, wie zum Beispiel Temperatur oder Eigenschaften der alten Schneeoberfläche abhängt.“ (LWD Tirol 2021⁵)

Abb. 11: Symbol für das Neuschneeproblem (Quelle: LWD Tirol 2021⁵)

Triebsschneeproblem



Beim Triebsschneeproblem liegt die Ursache der Gefahr bei windverfrachtetem Schnee. Durch starken Wind werden bevorzugt in Windschattenhängen sogenannte Triebsschneeansammlungen erzeugt, die besonders störanfällig sind. Das Problem kann während aber auch ohne gleichzeitigen Schneefall auftreten. (vgl. LWD Tirol 2021⁵)

Abb. 12: Symbol für Triebsschneeproblem (Quelle: LWD Tirol 2021⁵)

Altschneeproblem



Das Altschneeproblem wird durch vorhandene Schwachschichten in der Altschneedecke hervorgerufen und zeichnet sich typischerweise in Form von eingeschneitem Oberflächenreif oder Schwimmschnee aus und ist aufgrund der Lage der Schwachschichten tief in der Schneedecke ohne Hintergrundwissen zu Winter- und Wetterverlauf nur schwer zu erkennen. (vgl. LWD Tirol 2021⁵)

Abb. 13: Symbol für Altschneeproblem (Quelle: LWD Tirol 2021⁵)


Nassschneeproblem



Wird bei Regen oder Schmelze durch den zusätzlichen Wassereintrag die Stabilität der Schneedecke geschwächt, so spricht man von einem Nassschneeproblem. (vgl. LWD Tirol 2021⁵)

Abb. 14: Symbol für das Nassschneeproblem (Quelle: LWD Tirol 2021⁵)

Gleitschneeproblem



Das Gleitschneeproblem wirkt sich in Form von sogenannten Grundlawinen aus, bei dem die gesamte Schneedecke auf glattem Untergrund abgleitet (vgl. Kapitel 6.2.4: gm.2 Gleitschnee). Der Zeitpunkt des Lawinenabganges lässt sich bei Gleitschneelawinen noch schwieriger prognostizieren als bei allen anderen Lawinenproblemen. (vgl. LWD Tirol 2021⁵)

Abb. 15: Symbol für das Gleitschneeproblem (Quelle: LWD Tirol 2021⁵)

Zu jedem der fünf Lawinenprobleme wurden zusätzlich Merkmale definiert, anhand derer man auch im Gelände auf das Auftreten der Probleme schließen und somit die Gefahr eines Lawinenunfalls reduzieren kann. Eine weitere Vertiefung zu diesem Thema ist aufgrund der höheren Bedeutung der Gefahrenmuster im Rahmen dieser wissenschaftlichen Arbeit jedoch nicht angestrebt, weshalb im folgenden Kapitel ein ausgedehnter Fokus auf die angesprochenen Gefahrenmuster als zusätzliches Mittel der Gefahrenbeschreibung gelegt wird.

6.2.4. Gefahrenbeurteilung mittels Gefahrenmuster

Ähnlich wie die soeben in Kapitel 6.2.3 beschriebenen Lawinenprobleme sollen auch die Lawinengefahrenmuster, die in der vierten Ebene der Informationspyramide zur detaillierten Gefahrenbeschreibung herangezogen werden, auf typische, sich wiederholende und meist offensichtliche Gefahrensituationen hinweisen.

„Der Unterschied liegt in der Betrachtungsebene. Während Lawinenprobleme einen ersten groben Überblick über mögliche Gefahrenquellen (z. B. Neuschnee) geben, wird bei den Gefahrenmustern tiefer in die Materie eingetaucht und nach den Ursachen des Problems gesucht (z. B. Problem durch zu große Neuschneeauflast auf einer Schwachschicht). Gefahrenmuster beschreiben somit mögliche Szenarien bzw. Prozesse, die zu dem jeweiligen Lawinenproblem führen.“ (LWD Tirol 2021¹)

Die Leiter des Lawinenwarndienstes Tirols Rudi Mair und Patrick Nairz widmeten 2010 ihr Buch „Lawine. Die 10 entscheidenden Gefahrenmuster erkennen“ ebendiesen Gefahrenmustern und konnten, wie der Buchtitel bereits verrät, 10 typische Gefahrenmuster erarbeiten, mit denen sich laut eigener Aussage in Summe rund 98% sämtlicher während einer Wintersaison auftretender Gefahrensituationen abdecken lassen. (vgl. MAIR und NAIRZ 2010: 16)

Diese 10 Gefahrenmuster und die Auswirkungen der meteorologischen Veränderungen auf ihr Auftreten sind Hauptobjekt der Untersuchungen in dieser Arbeit und werden daher im Folgenden näher vorgestellt.

„Bei den (...) vorgestellten Mustern handelt es sich um wiederkehrende Situationen bzw. Ereignisse, welche sich in Klassen untergliedern lassen. Konkret geht es um die Aufdeckung klar definierbarer, immer wiederkehrender, offensichtlicher Gefahrensituationen.“ (ebd.: 13)

Beschreiben lassen sich diese Gefahrenmuster anhand bestimmter Bedingungen, die über viele Winter hinweg wiederholt auftreten und somit vergleichbare Gefahrenpotenziale hervorrufen. Vorrangig wird dabei auf den Schneedeckenaufbau, das vorangegangene und das folgende Wettergeschehen Bezug genommen. Durch langjährige Beobachtungen und Analysen konnte das Auftreten der einzelnen Gefahrenmuster zeitlich innerhalb eines Winters und räumlich auf verschiedene Expositionen und Höhenlagen eingegrenzt werden, die beim Erkennen und richtigen Einschätzen der Gefahr helfen sollen.

Die Abbildungen, die im Zuge der detaillierten Vorstellung der einzelnen Muster herangezogen werden, um Informationen zu Gefahrenbereichen und -zeiten zu vermitteln, wurden nach Anfrage als Grafiken direkt vom LWD Tirol zur Verfügung gestellt. Diese Informationen zu Zeitpunkt und Ort des Auftretens sind jedoch lediglich als Richtwerte anzusehen, da sich unter speziellen Bedingungen diese Muster auch zu anderen Zeitpunkten während eines Winters oder in unterschiedlichen Expositionen und Höhenlagen finden lassen.

„Lawinensituationen lassen sich in der Regel recht gut und eindeutig einem jeweils entscheidenden Gefahrenmuster zuordnen. Am einfachsten ist dies zu Winterbeginn sowie gegen Winterende. Während des Winters hingegen überlagern sich häufig mehrere unterschiedliche Gefahrenmuster, wobei in der Regel immer eines davon dominant ist.“ (ebd.: 26)

Im Lawinenlagebericht werden die vorherrschenden Gefahrenmuster immer entsprechend ausgewiesen und aufgrund der Bedeutung bei der anschließenden Datenanalyse werden die 10 entscheidenden Gefahrenmuster im Folgenden näher vorgestellt.

gm.1 Bodennahe Schwachschicht

„Zu Winterbeginn beobachtet man Schneebrettlawinen vermehrt nach dem zweiten bedeutsamen Schneefall, und zwar in hohen (>2000 m) und hochalpinen (>3000 m) Lagen im schattigen, sehr steilen Gelände. Dies hat damit zu tun, dass sich im Herbst nach den ersten großen Schneefällen meist eine längere, stabile Hochdruckwetterlage bzw. niederschlagsfreie Zeit einstellt. Dann herrschen ideale Bedingungen für die zumindest teilweise Umwandlung dieses Schnees zu lockeren Kristallen, die wiederum eine bodennahe Schwachschicht für die nachfolgenden Schneefälle bilden können.“ (LWD Tirol 2021¹)

Aufgrund dieser typischen Situation zu Winterbeginn, durch die sich nach der ersten Schneeeauflage und dem zweiten Schneefall mitunter eine ausgeprägte und von Wintersportlern leicht zu störende Schwachschicht bilden kann, wurde dieses Gefahrenmuster ursprünglich als gm.1: Der zweite Schneefall bezeichnet. (vgl. MAIR und NAIRZ 2010: 31)

„Mit dem zweiten Schneefall ist nicht unbedingt immer exakt der zweite gemeint, sondern der zweite relevante Schneefall, der auf eine vom ersten Schnee des Winters gebildete Altschneedecke trifft. In der Regel liegt zwischen dem ersten und dem zweiten Schneefall ein längerer zeitlicher Abstand von zumindest einer Woche, nicht selten auch mehreren Wochen.“ (ebd.: 38)

Da das Gefahrenmuster jedoch nicht ausschließlich beim zweiten großen Schneefall, sondern während schneearmer Winter häufig auch noch später auftritt, wurde der Name nachträglich angepasst und wird heute als bodennahe Schwachschicht beschrieben.

„Schneebrettlawinen treten nach dem zweiten Schneefall nur dort auf, wo eine zusammenhängende Altschneedecke vorhanden ist, die anschließend von Triebsschnee überlagert wurde. Dieses Gefahrenmuster findet sich bevorzugt in schattigem, sehr steilem und kammnahem Gelände in hohen und hochalpinen Lagen“ (ebd.: 34) (siehe Abb. 16), da sich dort die angesprochene zusammenhängende Altschneedecke auch bei hohen Temperaturen hält und so die Grundlage für die Lawinengefahr bildet, während in sonnenexponierten Hängen der erste Schneefall oftmals nicht lange liegen bleibt beziehungsweise die aufbauende Umwandlung, die zur Bildung der späteren Schwachschicht führt, nicht einsetzt. Naturgemäß sind die Bereiche, in denen Gefahrenmuster 1 auftritt, räumlich stark begrenzt und prinzipiell recht gut zu lokalisieren. (vgl. ebd.)




Abb. 16: Räumliche Verteilung von gm.1 (Quelle: LWD Tirol)



Abb. 17: Zeitliche Verteilung von gm.1 (Quelle: LWD Tirol)

gm.2 Gleitschnee

„Gleitschneelawinen zählen hinsichtlich des Abgangszeitpunktes zu den am schwierigsten vorhersagbaren Lawinen, weil diese auch bei allgemein stabilen Schneeverhältnissen zu jeder Tages- und Nachtzeit, sowohl am kältesten als auch am wärmsten Tag eines Winters abgehen können. [Anm.: siehe Abb. 19] Zudem sind Gleitschneelawinen nicht durch Zusatzbelastung auszulösen.“ (MAIR und NAIRZ 2010: 45)

„Bei aller Unberechenbarkeit ihres Abgangszeitpunktes lassen sich Gleitschneelawinen zumindest hinsichtlich des Abgangsortes leicht erkennen. Sie kündigen sich zumeist über längere Zeiträume durch gut sichtbare, teilweise mehrere Meter tiefe Risse in der Schneedecke, sogenannte Gleitschneemäuler, an. Zudem fällt bei Beobachtung während mehrerer Winter auf, dass Gleitschneelawinen sehr häufig an denselben Stellen abgehen.“ (ebd.: 51)

„Ein Gleitschneemaule deutet auf die Möglichkeit einer Gleitschneelawine hin, sagt jedoch nichts darüber aus, ob und wann die Schneemasse tatsächlich als Gleitschneelawine abgeht“ (ebd.: 45).

„Es gibt nur ein offensichtliches Kriterium für eine Häufung von Gleitschneelawinen, und zwar die fortschreitende Durchnässung der Schneedecke: Je nasser die Schneedecke, desto mehr Gleitschneelawinen wird man beobachten“ (ebd.: 49).

„Gleitschnee steht für die hangparallele Bewegung der Schneedecke. Eine solche Bewegung wird maßgeblich von der Bodenrauigkeit beeinflusst. Je glatter der Untergrund, desto eher muss man mit dem Auftreten von Gleitschneelawinen rechnen.“ (ebd.: 52)

Grundsätzlich gleitet Schnee bei Gleitschneelawinen auf steilen, glatten Flächen, wie steilen Wiesenhängen oder glattem felsigem Untergrund talwärts und umfasst dabei die gesamte Schneedecke, da der Übergang der Schneedecke zum Boden in diesem Fall aufgrund des Reibungsverlusts auf einer wassergesättigten Schicht als Schwachschicht fungiert. (vgl. LWD Tirol 2021⁵)

„Das wichtigste Kriterium für einen möglichen Lawinenabgang stellt die Beschaffenheit der Grenzfläche zwischen Boden und Schnee dar. Freies Wasser bzw. ein dünner Wasserfilm an dieser Grenzfläche fördert die Gleitbewegung und in Folge die Abgangsbereitschaft von Gleitschneelawinen. Somit erhöhen Regen sowie massive Erwärmung die Wahrscheinlichkeit von (Gleitschnee-) Lawinenabgängen. Begünstigend ist auch ein frühes, massives Einschneien, da die Bodentemperatur dann relativ warm und der erwähnte Wasserfilm dadurch ausgeprägter ist.“ (MAIR und NAIRZ 2010: 53f)




Abb. 18: Räumliche Verteilung von gm.2 (Quelle: LWD Tirol)



Abb. 19: Zeitliche Verteilung von gm.2 (Quelle: LWD Tirol)

gm.3 Regen

„Regen gilt als klassisches Alarmzeichen in der Schnee- und Lawinenkunde, weil er einerseits zusätzliches Gewicht in die Schneedecke bringt und andererseits zu einem raschen Festigkeitsverlust führt. Lawinen sind deshalb vorprogrammiert. Regen kann in jedem Abschnitt eines Winters auftreten. [Anm.: siehe Abb. 21] Der große Vorteil: Kein Gefahrenmuster kann leichter erkannt werden als Regen.“ (MAIR und NAIRZ 2010: 61)

„Bei intensivem Regen dauert es nie lange, bis man die ersten spontanen Lawinenabgänge beobachten kann. Dies geht umso rascher vor sich, je frischer und lockerer der Schnee ist, auf den der Regen fällt, und je abrupter der Temperaturanstieg ausfällt.“ (ebd.: 64)

„Regen führt kurzfristig fast immer zu einer Zunahme der Lawinengefahr! Zum einen stellt das Wasser, das dadurch in die Schneedecke einsickert, eine große Zusatzbelastung dar. Zum anderen zerstört der Regen die Verbindungen, die die Schneekristalle untereinander haben, und wirkt gleichsam wie ein Gleitmittel.“ (ebd.: 68)

„Mittel- bzw. langfristig kann der Regen aber durchaus auch einen stabilisierenden Effekt haben, und zwar dann, wenn die Temperaturen nach dem Regen sinken (u.a. auch Abkühlung während der Nacht). Dadurch gefriert das freie Wasser in den Poren, und die Schneedecke verfestigt sich. Es entstehen – je nach Kälteexposition – mitunter sehr dicke Schmelzharschdeckel mit den typischen zusammengefrorenen, glasigen Rundkörnern.“ (ebd.: 70) Ausführlichere Informationen zu Prozess und Auswirkung von solchen Schmelzharschdeckeln sind in Kapitel 5.2.2 im Unterkapitel Schmelzmetamorphose zu finden.




Abb. 20: Räumliche Verteilung von gm.3 (Quelle: LWD Tirol)



Abb. 21: Zeitliche Verteilung von gm.3 (Quelle: LWD Tirol)

gm.4 Kalt auf warm/Warm auf kalt

„Unter den Begriffen „kalt auf warm“ bzw. „warm auf kalt“ ist zu verstehen, dass sich auf Grund starker Temperaturänderungen zwischen zwei Wetterphasen die Temperaturen der liegenden Schneedecke und des hinzukommenden Neuschnees deutlich (mehr als 5°C) unterscheiden.“ (MAIR und NAIRZ 2010: 84)

Entscheidend ist bei beiden Vorgängen derselbe Effekt: Es entsteht ein großer Temperaturunterschied innerhalb nur weniger Zentimeter der Schneedecke, der die aufbauenden Umwandlungsprozesse innerhalb der Schneedecke begünstigt. Es entstehen mögliche Schwachschichten.

„Meist ist die Kombination kalt auf warm bzw. warm auf kalt mit der Bildung einer Schmelzharschschicht verbunden: Entweder wird eine relativ warme, feuchte Schneeoberfläche durch einsetzende fallende Temperaturen verharscht oder eine kalte Schneeoberfläche von der beginnenden Erwärmung (oder nassem Schneefall bzw. Regen) angefeuchtet, worauf es auch hier zur Bildung einer meist dünnen Harschschicht kommen kann.“ (ebd.: 85)

„Im Grenzbereich zu einem Harschdeckel bildet sich fast immer eine dünne Schwachschicht aus aufbauend umgewandelten Schneekristallen. Schneit es bei tiefen Temperaturen auf eine relativ warme Altschneedecke, bildet sich diese Schwachschicht im Normalfall unter dem Harschdeckel. Schneefall bei relativ warmen Temperaturen auf eine kalte Altschneedecke sorgt hingegen für vermehrte Umwandlung über dem Harschdeckel.“ (ebd.: 86)

Besonders gefährlich an dieser Situation ist, dass sich die angesprochene Schwachschicht nicht unmittelbar nach dem Schneefall, sondern häufig erst im Verlauf der folgenden Tage ausbildet. Somit kommt es zu einem Anstieg der Lawinengefahr, der jedoch nicht durch das unmittelbare Wettergeschehen oder andere äußere Hinweise erkennbar ist. (vgl. ebd.: 86)

Das Gefahrenmuster kann in allen Lagen auftreten (siehe Abb.22), hochalpin und schattseitig ist es jedoch deutlich unwahrscheinlicher, da hier die Temperaturunterschiede beim Einschneien meist nicht so groß ausfallen.




Abb. 22: Räumliche Verteilung von gm.4 (Quelle: LWD Tirol)



Abb. 23: Zeitliche Verteilung von gm.4 (Quelle: LWD Tirol)

gm.5 Schnee nach langer Kälteperiode

Das Gefahrenmuster 5 tritt, wie die Namensgebung bereits erahnen lässt, bei Neuschnee nach einer langen Kälteperiode auf. Zusätzlich weht oft kräftiger Wind, wodurch in kürzester Zeit eine sehr heikle Lawinensituation hervorgerufen wird. Der Grund dafür liegt in der aufbauenden Metamorphose, die die Schneedecke in der langen Kälteperiode verändert hat, worauf in Kapitel 5.2.2 bereits ausführlicher Bezug genommen wurde.

„Ist die gesamte Schneedecke aufbauend umgewandelt, so ist das an sich noch nicht gefährlich, im Gegenteil: Man hat eine weitgehend spannungsarme Schneedecke mit feinstem „Pulverschnee“. Kritisch wird es erst, wenn dieses lockere, bindungslose Fundament von frischem Neuschnee unter Windeinfluss überlagert wird.“ (MAIR und NAIRZ 2010: 106)

„Eine lange Kälteperiode kann an mehreren Stellen der Schneedecke zur Bildung von Schwachschichten führen“ (ebd.).




Abb. 24: Räumliche Verteilung von gm.5 (Quelle: LWD Tirol)



Abb. 25: Zeitliche Verteilung von gm.5 (Quelle: LWD Tirol)

gm.6 Lockerer Schnee und Wind

Die große Bedeutung des Windes für die Lawinengefahr wurde in Kapitel 5.2.1 bereits näher erläutert. Dabei wurde erwähnt, dass es sich beim Wind um einen der wesentlichsten lawinenbildenden Faktoren handelt und der Einfluss sowohl während als auch nach dem Schneefall verschärfend auf die Gefahrensituation wirken kann. Durch ausgelöste Verfrachtungen ist speziell bei lockerem, trockenem Schnee immer mit einer kurzfristigen Zunahme der Lawinengefahr zu rechnen. (vgl. MAIR und NAIRZ 2010: 113)

Das gm.6 gilt als eines der am häufigsten auftretenden Gefahrenmuster und kann in allen Höhenlagen und Expositionen zu einem Anstieg der Lawinengefahr führen (siehe Abb. 26), weshalb es wichtig ist, die Gefahrenzeichen erkennen und verstehen zu können.

Die vom Wind ausgelöste Schneeverfrachtung kann dabei verschiedene Formen annehmen, die als Wechten, Dünen und Windgangeln zu differenzieren sind. Das wichtigste Unterscheidungsmerkmal zwischen diesen Ausprägungen besteht darin, dass es sich bei Wechten und Dünen um Schneeablagerungen handelt und die windzugewandte Seite (Luv) als flachere Seite erkennbar ist.

Während Dünen in Hanglagen und flacheren Passagen vorzufinden sind, bilden sich Wechten an einem Grat oder Kamm. Der Gefahrenbereich liegt hierbei vor allem im steileren und windabgewandten Bereich (Lee), da sich der verfrachtete Schnee hier sammeln und oftmals ein Tribschneeproblem (siehe Kapitel 6.2.3) hervorrufen kann. Bei sogenannten Windgangeln handelt es sich im Gegensatz dazu um eine Erosionsform, bei der die steile, erodierte Seite dem Wind zugewandt im Luv liegt. (vgl. EAWS 2022)




Abb. 26: Räumliche Verteilung von gm.6 (Quelle: LWD Tirol)



Abb. 27: Zeitliche Verteilung von gm.6 (Quelle: LWD Tirol)

gm.7 Schneearme Bereiche in schneereichen Wintern

„In schneereichen Wintern passieren normalerweise deutlich weniger Lawinenunfälle als in schneearmen Wintern, weil der Schneedeckenaufbau im Allgemeinen günstiger ist. Dennoch beobachtet man auch in schneereichen Wintern regelmäßig das Phänomen, dass aufgrund vorherrschender Wetterlagen windexponierte Hänge relativ schneearm sind. Dementsprechend ungünstiger gestaltet sich dort der Schneedeckenaufbau, und umso wahrscheinlicher werden genau dort Lawinen von Wintersportlern ausgelöst.“ (MAIR und NAIRZ 2010: 133)

Das liegt vorrangig daran, dass in der Schneedecke vorhandene Schwachschichten in schneereichen Wintern flächendeckend keine große Rolle spielen, da sie tief unterhalb der Schneeoberfläche begraben liegen und eine Auslösung damit einer immensen Zusatzbelastung bedarf. In schneearmen Gebieten ist die Schneedecke jedoch deutlich schwächer ausgeprägt, wodurch eine Störung der Schwachschicht durch eine Einzelperson möglich ist und es zu Lawinenabgängen kommen kann.

Besonders anfällig werden hier nordwestlich exponierte Hänge angesehen (siehe Abb. 28), da starke Winde im Alpenraum oftmals mit Nordwestwetterlagen in Verbindung stehen und sich besonders in diesen Expositionen schneearme Bereiche in schneereichen Wintern ausbilden können. Zu beobachten ist dieses Phänomen hauptsächlich im Hochwinter (siehe Abb. 29), da es sich hierbei üblicherweise um die schneereichste Zeit des Winters handelt.




Abb. 28: Räumliche Verteilung von gm.7 (Quelle: LWD Tirol)



Abb. 29: Zeitliche Verteilung von gm.7 (Quelle: LWD Tirol)

gm.8 Eingeschneider Oberflächenreif

Oberflächenreif bildet sich durch aufbauende Umwandlung der Schneekristalle vorrangig in kalten Schönwetterperioden an der Schneeoberfläche und verursacht vorerst keinen Anstieg der Lawinengefahr.

„Erst wenn er von neuen, gebundenen Schneeschichten überdeckt wird, wird er gefährlich und gilt deshalb zu Recht als eine der kritischsten Schwachschichten der Schnee- und Lawinenkunde“ (MAIR und NAIRZ 2010: 149).

Die Tatsache, dass die Gefährdung auf der vorangegangenen Entwicklung der Schneedecke beruht, macht die längerfristige Beobachtung der Wettergeschehnisse bei diesem Gefahrenmuster noch wichtiger als sie in der Lawinenwarnung ohnehin ist. Vor Ort ist ein Erkennen der Gefahr ohne Vorwissen, beispielsweise aus dem Lawinenlagebericht oder dem Erstellen eines Schneeprofiles, bei diesem Gefahrenmuster kaum möglich.

Die Bildung von Oberflächenreif tritt verstärkt bei wolkenlosen Bedingungen auf, da dadurch eine Ausstrahlung von Wärmestrahlung zu einer deutlichen Abkühlung der Schneedecke unter die Lufttemperatur führt. Unter diesen Umständen lagert sich die feuchte, wärmere Luft an der kalten Schneeoberfläche ab und es kommt, meist über Nacht, zur Bildung von Oberflächenreif. Die dafür notwendige Feuchtigkeit kann jedoch auch aus dem Inneren der Schneedecke aufsteigen. (vgl. ebd.: 156f)

„Wird Oberflächenreif von Neuschnee überlagert, entsteht, besonders unter Windeinfluss, schlagartig eine sehr schwache, lockere Schicht aus bindingslosen Kristallen. Lagern sich darauf nun gebundene Schneeschichten, kann diese Zusatzbelastung häufig nicht mehr getragen werden. Dann beobachtet man sogar bei geringen Neuschneemengen Selbstauslösungen von Schneebrettlawinen.“ (ebd.: 158)

Eine besondere Form der Oberflächenreifbildung, die vorwiegend im Frühwinter sowie im Frühjahr in größeren Höhen zu beobachten ist, wurde vom Schweizer Bergführer Paul Nigg entdeckt und nach ihm benannt.

Der sogenannte Nigg-Effekt tritt auf, wenn relativ warme, feuchte Luft über einen Grat oder Kamm in schattseitige Gebiete eindringt, in denen die Schneeoberfläche aufgrund der fehlenden Erwärmung durch Sonneneinstrahlung deutlich kühler als die Luft ist. Die in der Luft enthaltene Feuchtigkeit sublimiert in der Folge nur in kammnahen, oft steilen Gebieten zu Oberflächenreifkristallen, während hundert Höhenmeter tiefer häufig keine Bildung von Oberflächenreif stattfindet. Der Nigg-Effekt kann so eine sehr kleinräumige, aber heimtückische Gefahr werden, wenn die Oberflächenreifeissschicht von Neuschnee überlagert wird und gilt auch für Experten als sehr schwer einzuschätzen. (vgl. ebd.: 160f)




Abb. 30: Räumliche Verteilung von gm.8 (Quelle: LWD Tirol)




Abb. 31: Zeitliche Verteilung von gm.8 (Quelle: LWD Tirol)

gm.9 Eingeschneiter Graupel

Graupel lagert sich bei gewitterartigen Niederschlägen ab und kann zur Bildung einer Schwachschicht führen. Wie beim Oberflächenreif wird es jedoch erst zu einem Problem, sobald sich darüber Neuschnee abgelagert und ist daher zum Zeitpunkt der Gefährdung, ohne einen Blick in die Schneedecke zu werfen, nicht offensichtlich erkennbar.

Eine eingelagerte Graupelschicht in der Schneedecke kann aufgrund der kugelförmigen Niederschlagsform anhand eines Kugellagers erklärt werden, auf dem der darauf liegende Schnee sehr leicht abgleitet, da keine Bindung zwischen den unterschiedlichen Schichten vorhanden ist.

Graupel ist häufig kleinräumig verteilt und tritt bevorzugt im Frühjahr (siehe Abb. 33) bei gewitterartigen Schauern auf. Das hervorgerufene Gefahrenmuster ist selbst von Experten nur schwer zu erkennen, stellt jedoch meist nur kurzfristig ein Problem dar. (vgl. MAIR und NAIRZ 2010: 167)




Abb. 32: Räumliche Verteilung von gm.9 (Quelle: LWD Tirol)



Abb. 33: Zeitliche Verteilung von gm.9 (Quelle: LWD Tirol)

gm.10 Frühjahrssituation

„Eine besondere Herausforderung für den Wintersportler, aber auch für Lawinenprognostiker sowie Lawinenkommissionsmitglieder stellt das Frühjahr dar. Selten liegen ‚sicher‘ und ‚gefährlich‘ zeitlich so eng beieinander und somit ist auch die Bandbreite der während eines Tages ausgegebenen Gefahrenstufen so weit gefächert. Einerseits ist die Lawinengefahr kaum einmal leichter einzuschätzen als bei stabilen Firnverhältnissen, andererseits werden aber auch kaum jemals während eines Winters so große Lawinenabgänge verzeichnet wie während kritischer Frühjahrssituationen. Dabei spielt neben dem Schneedeckenaufbau das zum Teil komplexe Wechselspiel aus Lufttemperatur, Luftfeuchte, Strahlungseinfluss und Wind eine entscheidende Rolle.“ (MAIR und NAIRZ 2010: 185)

„Das sehr komplexe Zusammenspiel von Lufttemperatur, Feuchte und Strahlung (fallweise auch Wind) führt dazu, dass sich die Lawinensituation im Frühjahr innerhalb kürzester Zeit – es geht meist um ein, zwei Stunden – markant zuspitzen kann. Entscheidend dabei ist immer die durch diese Parameter bestimmte zunehmende Durchfeuchtung bzw. Durchnässung der Schneedecke, welche einen raschen Stabilitätsverlust zur Folge hat.“ (ebd.: 190)

Das Gefahrenmuster der Frühjahrssituationen lässt sich dabei in zwei Phasen eingliedern, deren Unterschiede hinsichtlich der räumlichen Gefahrenbereiche aus Abbildung 24 zu entnehmen sind.

„Das erste Gesicht der Frühjahrssituation zeigt sich mit zunehmender Strahlungsintensität meist ab Mitte Februar. Der dadurch bedingte Wärmeeintrag führt zu erhöhten Kriechbewegungen (...) in der Schneedecke und damit zu einer erhöhten Auslösewahrscheinlichkeit durch Wintersportler. (...) Das zweite Gesicht der Frühjahrssituation zeigt sich regelmäßig in einer sehr lawinenaktiven Zeit meist ab Mitte März. Dabei geht während weniger Tage nicht selten ein Großteil der spontanen Lawinen einer Wintersaison in Form von Nassschneelawinen ab. Solche Situationen lassen sich inzwischen mit Hilfe von Wetterstationsgrafiken recht gut erkennen. Entscheidend ist die hohe Lufttemperatur, die zunehmende Luftfeuchte bei allgemein hoher Strahlungsintensität und geringem Windeinfluss, wobei sich die Schneeoberflächentemperatur der Nullgradgrenze nähert und diese erreicht.“ (ebd.: 195)

„Unter einer ‚typischen‘ Frühjahrssituation versteht man im Allgemeinen die Zeit, wenn sich der Winter langsam zurückzieht und steigende Temperaturen und zunehmende Sonneneinstrahlung für sehr spezielle Verhältnisse in den Tourengebieten sorgen“ (ebd.: 194).

Die Analyse von Wetterstationsdaten kann bei der Erkennung und Beurteilung der Frühjahrssituation daher eine sehr große Rolle zugeschrieben werden.




Abb. 34: Räumliche Verteilung von gm.10 (Quelle: LWD Tirol)



Abb. 35: Zeitliche Verteilung von gm.10 (Quelle: LWD Tirol)

6.2.5. Zusatzinformationen und Messwerte

Im Lawinenlagebericht wird oft auch auf zusätzliche Informationen verwiesen, um die Lawinengefahr in Textform noch detaillierter beschreiben zu können. Umgesetzt wird das seit einigen Jahren mittels vorgefertigter Textbausteine in einem Satzkatalog, der laut Aussagen von Patrick Nairz im Zuge eines Interviews (siehe Anhang 1.2) laufend erweitert wird. Das Ziel dieses Kataloges ist es, die Informationen möglichst einfach und einheitlich vermitteln zu können, um für den Leser selbst bei komplexen Situationen verständlich zu bleiben und die Kommunikation somit weiter zu verbessern. Ein weiterer Vorteil dieses Satzkataloges ist die Möglichkeit, bei einmaliger Ausarbeitung der gewünschten Textteile eine Publikation in verschiedenen Sprachen zu erstellen, wodurch der Lawinenlagebericht des Lawinenwarndienst Tirol mittlerweile in sieben Sprachen verfügbar ist und das ganz ohne Notwendigkeit eines Übersetzers, wie es vor der Einführung dieser Methode noch der Fall war.

Bei diesen Textpassagen wird neben Informationen zum Aufbau der Schneedecke, die meist durch das Erstellen von repräsentativen Schneeprofilen gewonnen werden, auch gezielt Bezug auf den Einfluss des Wetters genommen.

Zur besseren Informationsgewinnung diesbezüglich unterhalten die meisten Lawinenwarndienste eigene Wetterstationen an alpinen Standorten. Die meteorologischen Messergebnisse sollen dabei helfen die Lawinengefahr noch genauer begründen zu können und dienen somit als eine der wichtigsten Informationsquellen der Lawinenwarndienste. Die Rohdaten sind aus diesem Grund in der Informationspyramide als unterste Ebene verzeichnet und können als Basis aller darüberliegender Informationen verstanden werden. Nähere Details zur Messung der einzelnen meteorologischen Parameter wurden in Kapitel 5.2 thematisiert.

6.3. Lawinenlagebericht

Die Gesamtheit der oben beschriebenen Informationen wird von Lawinenwarndiensten über die Wintermonate im täglich erscheinenden Lawinenlagebericht veröffentlicht. Dieser dient dazu, die spezifischen Informationen zur Lawinengefahr geballt und für ein breites Zielpublikum verständlich zu publizieren und enthält sämtliche Informationen, die laut der Informationspyramide (siehe Abb. 8) für eine akkurate Gefahreinschätzung essenziell sind.

„Wer den Text sorgfältig liest, erfährt u.a. wichtige Details über die für eine Lawinenauslösung notwendige Zusatzbelastung sowie den Schneedeckenaufbau, insbesondere auch, wo mit kritischen und wo mit weniger kritischen Bereichen zu rechnen ist“ (MAIR und NAIRZ 2010: 215).

In Abbildung 36 ist ein Beispiel aus dem Lawinenlagebericht Tirol vom 6.12.2020 (LWD Tirol 2021³) zu sehen, an dem die Lawinengefahr in den betrachteten Subregionen als sehr groß eingestuft wurde.

Gefahrenstufe 5 - Sehr Groß





Tendenz: Lawinengefahr nimmt ab
 am Montag, den 07.12.2020



Neuschnee







Gleitschnee



2600m

Mit Neuschnee und Wind sehr große Lawinengefahr. Exponierte Teile von Verkehrswegen und exponierte Siedlungen können gefährdet sein.

Gefährliche Lawinensituation. Mit Neuschnee und Sturm nehmen Anzahl und Größe der Gefahrenstellen im Tagesverlauf zu. Die spontane Lawinenaktivität nimmt zu.

Aus hoch gelegenen Einzugsgebieten sind im Tagesverlauf spontane Lawinen zu erwarten, vereinzelt auch extrem große. Dies an allen Expositionen.

An steilen Grashängen sind unterhalb von rund 2600 m vermehrt große und vereinzelt sehr große Gleitschneelawinen zu erwarten. Gebietsweiser Anstieg der Gefahr von Gleitschneelawinen mit dem Regen. Spontane Lawinen bestätigen die gefährliche Lawinensituation.

Schneedecke

Gefahrenmuster gm.6: lockerer schnee und wind gm.2: gleitschnee

In den Hauptniederschlagsgebieten fielen 80 bis 140 cm Schnee. Am Sonntag fallen verbreitet 60 bis 110 cm Schnee, lokal auch mehr. Verbreitet starker Südwind. Im Tagesverlauf wachsen die Tribschneeanisammlungen deutlich an. Neu- und Tribschnee liegen oft auf weichen Schichten. Die Altschneedecke ist teils schwach, mit einer aus lockerem Schnee bestehenden Oberfläche, die auf einer kaum tragfähigen Schmelzharschkruste liegt, besonders an steilen Schattenhängen oberhalb der Waldgrenze.

Tendenz

Allmählicher Rückgang der Lawinengefahr mit dem Abklingen der Schneefälle. Vorsicht in Hängen mit Gleitschneerissen.

Abb. 36: Auszug aus dem Lagebericht vom 06.12.2020 (Quelle: LWD Tirol 2021³)

7. Datenanalyse

Dieses Kapitel behandelt die praktische Umsetzung der Datenanalyse, wobei die verschiedenen Arbeitsschritte detailliert dokumentiert und das praktische Vorgehen zur Erreichung der Forschungsziele genauestens beschrieben werden. Dabei stehen neben der Auswahl der zu verwendenden Wetterstationen besonders Datenverfügbarkeit und -qualität als essenzielle Vorbereitungsschritte im Fokus, bevor in Kapitel 7.4 der praktische Teil der Datenanalyse in all seinen Einzelheiten näher unter die Lupe genommen wird.

7.1. Auswahl repräsentativer Wetterstationen

Zur Beantwortung der wissenschaftlichen Fragestellung und Durchführung der angedachten Datenanalyse sind die Messdaten ausgewählter Wetterstationen notwendig, die den Zusammenhang zwischen den meteorologischen Gegebenheiten und den, vom Lawinenwarndienst ausgerufenen Gefahrenmustern bestmöglich aufdecken sollten. Um diesen Zusammenhang möglichst repräsentativ und aussagekräftig darstellen zu können, sind die zu verwendenden Wetterstationen nicht einfach zufällig auszuwählen, sondern basierend auf mehreren Kriterien zu selektieren.

Von den 199 Wetterstationen, die laut dem Lawineninformationssystem LAWIS, im Bundesland Tirol von LWD Tirol, ZAMG (Zentralanstalt für Meteorologie und Geodynamik) und mehreren Betrieben wie unter anderem ÖBB oder HD Tirol betrieben werden (vgl. LAWIS 2021²), müssen die Standorte auf ihre Tauglichkeit für die Verwendung zur Datenanalyse überprüft werden, da beispielsweise viele der Stationen nur Werte zur Lufttemperatur und Schneehöhe aufzeichnen und durch das Fehlen zusätzlicher Parameter oder schon durch ihren Standort in Tallagen ungeeignet für die angestrebten Untersuchungen sind.

In einem ersten Schritt wurden die Hauptgefahrenbereiche hinsichtlich der Höhenlage und Exposition der häufigsten Gefahrenmuster (gm.1, gm.2, gm.6 und gm.10), die im Weiteren untersucht werden sollten, genauer unter die Lupe genommen, um die Stationsselektion näher eingrenzen zu können. Eine Begründung für die Auswahl der genannten Gefahrenmuster für die Untersuchung wird in Kapitel 7.4 in Tabelle 1 nachgereicht und intensiver behandelt. Wie bereits in Kapitel 6.2.4 detailliert beschrieben, wurde für jedes der 10 Gefahrenmuster von MAIR und NAIRZ (2010) ein Hauptgefahrenbereich definiert, in dem die jeweiligen Gefahrenmuster besonders häufig anzutreffen sind. Wenngleich diese Hauptgefahrenbereiche teilweise sehr kleinräumig einzugrenzen sind, wie beispielsweise bei gm.1 bodennahe Schwachschicht, wo ein Auftreten auf Grund der Charakteristik des Gefahrenmusters fast ausschließlich auf den nördlichen, sonnenabgewandten Expositionssektor beschränkt werden kann, so sind einige Gefahrenmuster, wie beispielsweise gm.6 (vgl. Abb. 26) weder in Exposition noch in Höhenlage einzuschränken, was eine Auswahl einer repräsentativen Station deutlich erschwert.

Der Grund für eine wohlüberlegte Auswahl der Wetterstationen liegt schlussendlich darin, dass in keiner Datenbank tatsächlich festgehalten wird, ob an einem Standort das für die Subregion und den jeweiligen Tag ausgerufene Gefahrenmuster auch wirklich anzufinden ist und eine Gefahr darstellt. Die Wahrscheinlichkeit darauf kann also insofern erhöht werden, dass die Hauptgefahrenbereiche bei der Auswahl der Wetterstationen berücksichtigt und später auch bei der Analyse der Ergebnisse miteinbezogen werden.

Im Falle von gm.1 liegt eine repräsentative Messstation, an der das Gefahrenmuster also typischerweise anzutreffen ist, in nordwestlicher bis nordöstlicher Exposition auf einer Seehöhe von über 1500m. Die Wahrscheinlichkeit eines Auftretens von gm.1 steigt jedoch zunehmend mit der Seehöhe, weshalb höher gelegene Stationen im Nordsektor hier als repräsentativ anzusehen sind und für die Datenanalyse somit am besten geeignet zu sein scheinen. Jener Bereich im hochalpinen Nordsektor ist gleichzeitig bei gm.2 Gletschnee jedoch der einzige Bereich, an dem ein Auftreten als äußerst unwahrscheinlich einzustufen ist.

Diese Unterschiede und die Komplexität der verschiedenen Gefahrenmuster, man nehme als Beispiel gm.10 Frühjahrssituation, wo die beiden Phasen komplett unterschiedliche Gefahrenbereiche betreffen (siehe Abb. 34), machen eine ideale Auswahl von Wetterstationen für die Datenanalyse so gesehen unmöglich. Um der Datenanalyse trotzdem eine Relevanz und Repräsentativität zu gewährleisten, wurde die Auswahl der behandelten Messstationspunkte sowohl regional als auch in ihrer Höhenlage und Exposition auf den gesamten Untersuchungsraum Tirol verteilt. Dadurch wird gewährleistet, dass Zusammenhänge sowohl an typischen Auftrittsstandorten der Gefahrenmuster überprüft werden können, gleichzeitig aber die Überprüfung an untypischen Standortdaten mögliche Unterschiede dazu aufdecken kann.

Übersicht der ausgewählten Wetterstationen

Basierend auf den zuvor thematisierten Kriterien wurde eine Auswahl von sieben Wetterstationen getroffen, die räumlich über das Bundesland Tirol verteilt liegen und in ihren Standorteigenschaften Exposition und Höhenlage ein möglichst breites Spektrum abzubilden versuchen, wodurch eine überregional repräsentative Prognose der Gefahrenmuster auf Basis der übermittelten 123 Messdatensätze zu den einzelnen meteorologischen Parametern aufgestellt werden soll.

Eine Übersicht über die wichtigsten Standorteigenschaften wird in Tabelle 1 bereitgestellt und in Abbildung 44 ist die Lage der sieben beschriebenen Stationen auf einer Inselkarte des Bundeslandes Tirol verortet, um die regionale Verteilung besser zu veranschaulichen.

Nr.	Stationsname	Subregion	Seehöhe	Exposition
1	Tuxerjoch	Westliche Tuxer Alpen (AT-07-15)	2380m & 2518m	NO
2	Magdeburger Hütte & Hechenberg	Karwendel (AT-07-04)	1646m & 1922m	NW
3	Mosesgipfel	Östliche Deferegger Alpen (AT-07-27)	2235m & 2550m	SO
4	Nachtweide & Palinkopf	Samnaungruppe (AT-07-13)	2030m & 2864m	W
5	Rendl Riffel 1 & Salzboden	Westliche Verwallgruppe (AT-07-10)	1895m & 1985m	N
6	St. Veit	Östliche Rieserfernergruppe (AT-07-25)	2115m & 2630m	S
7	Valdafur & Tscheyegg	Glockturmgruppe (AT-07-19)	2500m & 2668m	SW

Tabelle 1: Übersicht der ausgewählten Wetterstationen

Bei der Auswahl der Stationen wurde versucht, eine räumliche Verteilung über den gesamten Untersuchungsraum Tirol zu gewährleisten, während weitere wichtige Auswahlkriterien wie Vollständigkeit der Parameter oder ausreichende Datensätze für Untersuchungen nicht vernachlässigt werden durften. Resultierend wurden manche Regionen wie der Nordosten Tirols bei der Auswahl nicht berücksichtigt, was unter anderem auf fehlende Messparameter bei vielen Stationen und eine geringere Dichte an, vom LWD Tirol betriebenen Messstellen in dieser Region zurückzuführen ist. Nichtsdestotrotz kann die räumliche Verteilung über den Untersuchungsraum als ausreichend angesehen werden, da vom äußersten Westen des Bundeslandes bis nach Osttirol Messstationen für die Datenanalyse berücksichtigt wurden.




Abb. 37: Übersichtskarte der ausgewählten Wetterstationen (Quelle: eigene Darstellung)

Im Folgenden wird nun die Auswahl der einzelnen Stationen begründet, ihre geographische Lage genauer beschrieben und in Form selbsterstellter Standortkarten im Maßstab 1:10.000 bzw. 1:20.000 auf Datengrundlagen von basemap.at, data.gv.at und dem LWD Tirol visualisiert. Eine Übersichtskarte des Bundeslandes Tirol im Maßstab 1:4.000.000 wurde hinzugefügt, um eine Verortung im Untersuchungsraum zu ermöglichen.

Station 1: Tuxerjoch

Die Wetterstation Tuxerjoch liegt in der Subregion der Westlichen Tuxer Alpen im Tiroler Unterland im Bereich des Skigebietes Hintertuxer Gletscher und wurde im Jahr 2012 erneuert. Wie bei den meisten Wetterstationen liegen die Messstandorte für Schnee und Wind aufgrund der unterschiedlichen Anforderungen an aussagekräftige Messwerte an unterschiedlichen Standorten.

So liegt die Schneestation, an der neben der Schneehöhe auch Lufttemperatur, relative Luftfeuchte und Globalstrahlung aufgezeichnet werden, auf 2380m in unmittelbarer Nähe zur Bergstation der 4er-Tuxerjoch Bergbahn in nordöstlicher Exposition. Die Geländeform am Standort kann, wie der Name Tuxerjoch bereits erahnen lässt, am besten mit Joch oder Sattel beschrieben werden, da das flache Plateau, auf dem auch ein künstlicher Speicherteich für die Beschneigung des Skigebietes angelegt wurde, nördlich vom Pfannköpfl (2388m) und südlich von der Frauenwand (2541m) eingeschlossen wird und in Ost-West Richtung eine natürliche Windschneise vorliegt. Aufgrund dieser Windschneise wäre der Standort für die Messung der Windgeschwindigkeit und -richtung nicht angebracht, da der Wind hier in Ost-West Richtung gebündelt und dadurch verstärkt wird und die tatsächlich vorliegenden Bedingungen dadurch verzerrt dargestellt würden.

Aus diesem Grund wurde die Windstation etwas südlich von der Bergstation am Gipfel der Weißen Wand auf 2518m Seehöhe installiert, um unverzerrte Messwerte zu Windgeschwindigkeit und -richtung zu gewährleisten. Zusätzlich wird auch an dieser Station die relative Luftfeuchte und die Lufttemperatur aufgezeichnet, die aufgrund der windexponierteren Lage und größeren Höhe in der Regel knapp unter den Messwerten der Schneestation liegt.




Abb. 38: Standortkarte Station Tuxerjoch (Quelle: eigene Darstellung)

Station 2: Magdeburger Hütte & Hechenberg

Die Station Magdeburger Hütte & Hechenberg liegt in unmittelbarer Nähe zur Tiroler Landeshauptstadt Innsbruck am südwestlichen Fuße der Nordkette in der Subregion des Karwendels und nur rund 2km von Stadt und Inn entfernt.

Die Station Magdeburger Hütte liegt direkt neben dem beliebten gleichnamigen Ausflugsziel auf 1646m Seehöhe auf einem kleinen Plateau das nördlich vom Großen Solstein (2541m), dem westlichsten Gipfel der Nordkette und südlich vom Kirchbergköpfl (1943m) eingeschlossen wird. Unterhalb der Hütte fällt das Gelände in nordwestlicher Ausrichtung ins Wörgltal bis auf 1100 Höhenmeter ab. Die Station erfasst seit 2014 Daten zu Lufttemperatur, Schneehöhe, Globalstrahlung, sowie die Schneetemperatur in Abständen von 20cm bis hin zu 80cm. Diese Information zur Schneetemperatur ist besonders dafür geeignet, die Metamorphosen innerhalb der Schneedecke nachvollziehen und einen Temperaturgradienten erstellen zu können.

Die Station Hechenberg liegt rund 1km südöstlich der Magdeburger Hütte auf dem Kamm zwischen angesprochenem Kirchbergköpfl (1943m) und Hechenberg (1912m) auf 1922m Seehöhe. Neben der Messung von Windgeschwindigkeit und -richtung werden auch an diesem Standort Lufttemperatur und relative Luftfeuchte gemessen.

Die Lage dieser Station ist besonders deswegen interessant, da in der Subregion Karwendel aufgrund des dortigen Naturschutzgebietes kaum Wetterstationen betrieben werden, gleichzeitig die Region aber besonders stark von den im Winter typischen, häufig schneebringenden Nordwestwetterlagen beeinflusst wird.




Abb. 39: Standortkarte Station Magdeburger Hütte & Hechenberg (Quelle: eigene Darstellung)

Station 3: Mosesgipfel

Die Wetterstation Mosesgipfel liegt in den Östlichen Deferegger Alpen in Osttirol westlich der Ortschaft Eggeberg im abgelegenen Talschluss des Villgratentals nahe der italienischen Grenze.

Die Schneestation liegt auf einem Rücken in südöstlicher Exposition auf 2235m Seehöhe, wobei das Gelände sowohl nach Norden, Osten und Süden bis zum Talboden auf rund 1500 Höhenmeter abfällt. Meteorologische Daten werden hier seit 2018 zu Lufttemperatur, relativer Luftfeuchte sowie Schneehöhe aufgenommen.

Die Windstation ist am Gipfel des Mosesgipfel auf 2550m angesiedelt, der durch einen Grat mit der nördlich gelegenen Kreuzspitze (2624m) verbunden ist. Auch hier wird, wie bei den meisten Windstationen, neben Windgeschwindigkeit und -richtung auch die Lufttemperatur gemessen.




Abb. 40: Standortkarte Station Mosesgipfel (Quelle: eigene Darstellung)

Station 4: Nachtweide & Palinkopf

Dass diese beiden Messstandorte aus der Subregion Samnaungruppe in LAWIS zu einer Station zusammengefügt werden, erscheint aufgrund der großen Distanz von rund 3,5km Luftlinie zwischen Nachtweide und Palinkopf verwunderlich, kann aber damit begründet werden, dass beide Standorte im grenzübergreifenden Skigebiet Ischgl-Samnaun liegen.

Die Messtation Nachtweide liegt nahe der gleichnamigen Nachtweidebahn neben einer Lagerhalle der Lawinenkommission Ischgl auf 2030m unterhalb der Idalpe (2320m) in einem nach Westen abfallenden Hang. Aufgrund der Funktion als Lagerhalle von Lawinensprengstoff sowie als Parkgarage für Pistenraupen wird dieser Standort regelmäßig von Mitarbeitern der Lawinenkommission aufgesucht, weshalb auch die Wartung der Wetterstation deutlich einfacher zu handhaben ist als bei abgelegeneren Standorten. Hier erfolgt eine Messung der Lufttemperatur, relativen Luftfeuchte, Schneehöhe sowie der Schneetemperatur.

Die Messung der in LAWIS dargestellten Winddaten dieser Station erfolgt am Gipfel des Palinkopfs auf 2864m direkt an der Schweizer Landesgrenze und stellt damit gleichzeitig die höchstgelegene der in dieser Arbeit verwendeten Wetterstationen dar. Um eine angemessene Wartung der Station in einer solch großen Höhe gewährleisten zu können, wurde die Messstelle neben der Bergstation der Gampenbahn montiert. Die Aufnahme von Lufttemperatur, Windgeschwindigkeit und -richtung wird hier zusätzlich durch eine Messung des Luftdrucks ergänzt und liefert einen wichtigen Anhaltspunkt für Entscheidungen der Lawinenkommission eines der größten Skigebiete der Alpen.




Abb. 41: Standortkarte Station Nachtweide & Palinkopf (Quelle: eigene Darstellung)

Station 5: Rendl Riffel 1 & Salzboden

Orographisch rechts des Moosbaches, der bei St. Anton am Arlberg in die Rosanna mündet, sind diese beiden Stationen zu finden. Sie liegen in der Subregion der Westlichen Verwallgruppe im äußersten Westen des Bundeslandes Tirol und gleichzeitig am südlichsten Rand Österreichs größten Skigebietes, dem Arlberg.

Die Station Salzboden liegt dabei direkt im Bereich des Skigebietes unterhalb der Riffelscharte (2645m) auf einer flacheren Stelle im Hang auf 1985m Seehöhe. An diesem Standort werden neben der, für die Datenanalyse verwendeten Windgeschwindigkeit auch Lufttemperatur, relative Luftfeuchte und Windrichtung gemessen.

Die Station Rendl Riffel 1 liegt rund 2,7 km südlich davon im Tal in unmittelbarer Nähe des Moosbaches, rund 1 km nördlich des Kartellspeichers im Talboden auf einer Seehöhe von 1895m. Für die Datenanalyse wurden die Messwerte zu Lufttemperatur, Schneehöhe, relativer Luftfeuchte und Globalstrahlung verwendet, während die gemessenen Daten zu Schneetemperatur und Luftdruck keine Verwendung fanden.

Diese Station soll vor allem die Verhältnisse in hochalpinen Seitentälern repräsentieren, weshalb dieser Standort trotz seiner Besonderheit mit Winddaten, die nicht auf einem Gipfel oder Kamm gemessen wurden, bewusst ausgewählt wurde.




Abb. 42: Standortkarte Station Rendl Riffel 1 & Salzboden (Quelle: eigene Darstellung)

Station 6: St. Veit

Nördlich von St. Veit in Deferegggen in Osttirol gelegen, stellt diese Station insofern eine Besonderheit dar, dass sie im Nationalpark Hohe Tauern und somit zumindest im Gegensatz zu vielen bereits vorgestellten Stationen nicht im Gebiet eines touristisch erschlossenen Skigebietes liegt. Ganz im Gegenteil gilt das Defereggental als eines der am dünnsten besiedelten Täler der österreichischen Alpen, was unter anderem an den extremen Wetterbedingungen liegen könnte, die für die Region typisch sind. Das Defereggental genießt den Ruf als einer der Kältepole Österreichs, was sich regelmäßig darin widerspiegelt, dass die kältesten Temperaturen des Landes hier gemessen werden. Neben der südlichen Exposition, die in dieser Art noch nicht in der Auswahl vertreten war, galt das als Hauptgrund für die Berücksichtigung dieses Stationsstandortes, der der Subregion der Östlichen Rieserfernergruppe zuzuordnen ist.

Die Windstation liegt knapp unterhalb des Speikboden (2653m) auf einer Seehöhe von 2630m. Es werden hier lediglich die für Windstationen als Standard geltenden Parameter Lufttemperatur, relative Luftfeuchte, sowie Windgeschwindigkeit und -richtung gemessen.

Die Schneestation St. Veit Zischke liegt am Südhang des Speikboden auf einem kleinen Rücken auf 2115m Seehöhe und damit deutlich über dem Talboden (~ 1300m) und der dort fließenden Schwarzach. Aufgezeichnet werden hier die Daten zu Lufttemperatur, relativer Luftfeuchte, Schneehöhe und Globalstrahlung, die allesamt auch in der Datenanalyse verwendet wurden.




Abb. 43: Standortkarte Station St. Veit (Quelle: eigene Darstellung)

Station 7: Valdafur & Tscheyegg

Die siebente und gleichzeitig letzte Station, die für die Analyse gewählt wurde, liegt südwestlich der Station Rendl Riffel 1 & Salzboden in der Subregion Glockturmgruppe im Bezirk Landeck in den Ötztaler Alpen am Rande des Skigebietes Nauders am Reschenpass, der seinerseits das Tiroler Oberinntal und das Südtiroler Vinschgau miteinander verbindet.

Der Messstandort Valdafur liegt dabei am Hang des Scharthkopfs (2808m) auf einer Höhe von 2500m in südwestlicher Exposition und verzeichnet meteorologische Werte zu Lufttemperatur, Schneehöhe, relativer Luftfeuchte, sowie Schneetemperatur.

Die Wetterstation Tscheyegg liegt am Gipfel des gleichnamigen Berges auf 2668m Seehöhe in unmittelbarer Nähe zur Bergstation der Tscheyeggbahn. An diesem exponierten und daher für Windmessstationen typischen Standort werden neben der Windgeschwindigkeit und -richtung, wie an vielen anderen vergleichbaren Stationen auch Lufttemperatur und relative Luftfeuchte gemessen, die jedoch nicht in die spätere Analyse einbezogen wurden.




Abb. 44: Standortkarte Station Valdafur & Tscheyegg (Quelle: eigene Darstellung)

7.2. Datenverfügbarkeit und Qualität

Im anschließenden Kapitel werden Datenverfügbarkeit und -qualität diskutiert, wobei die Vorstellung erster Arbeitsschritte zur Vorbereitung der Daten auf die angestrebte Analyse Auskunft über notwendige Bearbeitungen der vorliegenden Datensätze liefern soll.

Sowohl die 123 Datensätze zu den meteorologischen Messdaten, der in Kapitel 7.2 vorgestellten Stationsauswahl, als auch die Daten zu den Gefahrenmustern stammen aus dem Archiv des Lawinenwarndienstes Tirol und wurden auf Nachfrage per Mail in csv-Dateien übermittelt. Die Bearbeitung wurde, wie die anschließende Analyse, mit dem Statistikprogramm RStudio durchgeführt.

Die meteorologischen Daten wurden für die ausgewählten Messstationen als Rohdaten in 10-Minuten Intervallen in Form von csv-Tabellen (siehe Abb 45.) zu jedem angeforderten Parameter separat zur Verfügung gestellt und mussten für die Untersuchung des gewünschten Zeitraumes in einem ersten Schritt generalisiert werden, um statistisch wertvolle Analysen durchführen zu können und aussagekräftige Ergebnisse zu erhalten, ohne den Datenrahmen zu sprengen und auf tageszeitliche Schwankungen zu viel Fokus zu richten.

Eine Berechnung von Tagesmittelwerten schien angemessen, da eine solche Generalisierung über den Untersuchungsraum von einer Wintersaison keinen allzu großen Datenverlust darstellt, da die tageszeitlichen und vor allem 10-minütigen Entwicklungsintervalle ohnehin nicht vordergründig von Interesse sind und gleichzeitig die essenziellen Informationen über die Entwicklung der Wettergeschehnisse im Verlauf des Winters mittels Tagesmittelwerten übermittelt werden und eine aussagekräftige Analyse durchgeführt werden kann.

Um diese Bearbeitungs- und Generalisierungsschritte durchführen zu können, mussten die Datensätze anfangs ins Statistikprogramm RStudio eingespielt werden.

	A	B	C
16	Datum	Uhrzeit	Wert[°C]
17	30.09.2010	00:00:00	2,1
18	30.09.2010	00:10:00	2,2
19	30.09.2010	00:20:00	2,5
20	30.09.2010	00:30:00	2,4
21	30.09.2010	00:40:00	2,3
22	30.09.2010	00:50:00	2,5
23	30.09.2010	01:00:00	2,4
24	30.09.2010	01:10:00	2,3
25	30.09.2010	01:20:00	2,5
26	30.09.2010	01:30:00	2,2
27	30.09.2010	01:40:00	2,2
28	30.09.2010	01:50:00	2,6
29	30.09.2010	02:00:00	2,4
30	30.09.2010	02:10:00	2,2
31	30.09.2010	02:20:00	2,3
32	30.09.2010	02:30:00	2,6
33	30.09.2010	02:40:00	2,8
34	30.09.2010	02:50:00	2,7
35	30.09.2010	03:00:00	2,9
36	30.09.2010	03:10:00	2,8
37	30.09.2010	03:20:00	2,5
38	30.09.2010	03:30:00	2,4
39	30.09.2010	03:40:00	2,6
40	30.09.2010	03:50:00	2,4
41	30.09.2010	04:00:00	2,4
42	30.09.2010	04:10:00	2,7
43	30.09.2010	04:20:00	2,8

Abb. 45: Rohdaten Lufttemperatur
(Datenquelle: LWD Tirol; eigene
Darstellung)

Für das Einlesen der Rohdaten in RStudio wurde eine Funktion erstellt, die spezifische Grenzwerte zu den jeweiligen Parametern erlaubte, um bereits beim Einlesen der Rohdaten fehlende bzw. Fehlerwerte zu eliminieren. Zusätzlich wurden einige Befehle zum fehlerfreien Einlesen der Rohdaten hinzugefügt, die ein Arbeiten mit den Daten ermöglichen und erleichtern sollten. (siehe Abb. 46)

```

rohdaten_lesen <- function(dateiname, wert_name, na_string, minvalFilter, maxvalFilter) {
  rohdaten <- read.csv(file = dateiname, header= TRUE, sep=";", na.strings = "---",
    skip = 15, strip.white =TRUE, stringsAsFactors = FALSE, dec = "," )

  names(rohdaten) <- c("Datum", "Zeit", "wert", "Status")

  rohdaten$Datum <- as.Date(rohdaten$Datum, format= "%d.%m.%Y")

  #nur gueltige werte
  rohdaten <- rohdaten[!is.na(rohdaten$wert),]

  #zu kleine Daten wegfiltern
  if(!is.na(minvalFilter)) {
    rohdaten <- rohdaten[(rohdaten$wert >= minvalFilter),] }

  #zu grosse Daten wegfiltern
  if(!is.na(maxvalFilter)) {
    rohdaten <- rohdaten[(rohdaten$wert <= maxvalFilter),] }

  #Spaltenname der variablen
  #names(rohdaten) <- c("Datum", "Zeit", wert_name, "Status")

  #return value
  rohdaten
}

```

Abb. 46: Einlesen der Rohdaten und entfernen von Ausreißern (Quelle: eigene Darstellung)

Messfehler, die aufgrund der teils hochalpinen Lage der Wetterstationen und der damit vor allem im Hochwinter verbundenen schlechten Erreichbarkeit für Wartungsarbeiten, auftraten, zeigten sich in den Rohdatensätzen stets in Form von konstanten Messwerten. Die Wahrscheinlichkeit, dass über mehrere Tage hinweg tatsächlich die exakt selben Werte an einer Station auftreten, ist als so gering einzustufen, dass diese Werte im Zuge der Generalisierung entfernt wurden, um die Ergebnisse nicht zu verfälschen.

Dies wurde mit einer Funktion (siehe Abb. 47) in RStudio sichergestellt, die den Messwert mit dem vorangegangenen Wert vergleicht und diesen bei exakt gleicher Ausprägung als N/A kennzeichnet und den Messfehler somit aus dem Datensatz entfernt.

```

#Gleichbleibende Daten wegfiltern
messfehler <- function(rohdaten) {
  old_value <- rohdaten[1, "wert"]
  for (row in 2:nrow(rohdaten)) {
    value <- rohdaten[row, "wert"]

    if(old_value == value) {
      rohdaten[row - 1, "wert"] <- NA
    }
    old_value <- value
  }

  rohdaten
}

```

Abb. 47: Ausfiltern von Messfehlern (Quelle: eigene Darstellung)

Da das Auftreten von gleichen Werten in 10-minütigem Abstand nicht automatisch als Messfehler gehandelt werden kann, wurde die Funktion auf die berechneten Tagesmittelwerte angewandt, wodurch sichergestellt werden konnte, dass sämtliche Tageswerte, an denen die Station fehlerhafte Werte verzeichnete, für die Datenanalyse eliminiert wurden.

Grundsätzlich wurden für die Datenanalyse die Tagesmittelwerte zu den entscheidenden Wetterparametern Lufttemperatur, Windgeschwindigkeit, relative Luftfeuchte, Schneehöhe und Globalstrahlung ermittelt, da tageszeitliche Schwankungen für die Beantwortung der

Forschungsfragen als irrelevant und lediglich die Entwicklungen über ganze Tage von Bedeutung angesehen werden konnten. (siehe Abb. 48)

```
tagesmittelwerte <- function(rohdaten) {  
  test_gruppiert <- group_by(rohdaten, Datum)  
  tageswerte <- summarise(test_gruppiert, mean(wert))  
  
  names(tageswerte) <- c("Datum", "wert")  
  
  tageswerte <- messfehler(tageswerte)  
  
  tageswerte  
}
```

Abb. 48: Berechnung der Tagesmittelwerte (Quelle: eigene Darstellung)

In Addition zu den Tagesmittelwerten wurden Tagesdifferenzen berechnet, die in die Analyse miteinbezogen werden konnten, um den Faktor der Wetterveränderung besser sichtbar zu machen. Diese Differenzen wurden über den Zeitraum von einem (siehe Abb. 49) bzw. drei Tagen berechnet und auf mögliche Auswirkungen bei der Modellierung der Gefahrenmuster untersucht.

```
tagesdifferenzen <- function(datensatz, parameter){  
  x <- diff(parameter, lag = 1)  
  x <- c(NA,x)  
  xx<- mutate(datensatz, Differenz = x)  
  
  xx  
}
```

Abb. 49: Berechnung der Tagesdifferenzwerte (Quelle: eigene Darstellung)

Nach Abschluss dieser ersten Bearbeitungsschritte schienen die meteorologischen Datensätze für eine Analyse ausreichend vorbereitet, nachdem Tagesmittelwerte aus den Rohdaten berechnet, Messfehler eliminiert und in Form der Tagesdifferenzen zusätzliche Analyseparameter generiert wurden. Um die Zusammenhänge mit den Gefahrenmusterdaten überprüfen zu können, mussten diese zuvor ebenfalls in RStudio importiert und für die Analyse vorbereitet werden.

Die Datengrundlage für die Gefahrenmuster stellt eine Archivtabelle der Einträge des Lawinenlageberichtes dar, die wie die Messwerte der Wetterstationen im csv-Format übermittelt wurden, wobei zwischen älteren Daten (2010-2018) und neueren Daten (ab 2018) ein grundlegender Unterschied festzustellen war. Das liegt vorrangig daran, dass die Gefahrenmuster seit ihrer Einführung und erstmaligen Erwähnung im Lawinenlagebericht im Jahr 2010 noch für ganz Tirol und damit ohne regionale oder subregionale Unterschiede veröffentlicht wurden. Der Datensatz hierzu war eine einfache Zeitreihentabelle mit den ausgegebenen Gefahrenmustern in den einzigen drei Variablenspalten ohne jeglichen regionalen Bezug. (s. Abb. 50)

	A	B	C	D
1	datum	1.gm	2.gm	3.gm
2	29.11.2010	6	1	2
3	30.11.2010	6	1	2
4	01.12.2010	6	1	2
5	02.12.2010	6	1	2
6	03.12.2010	6	1	2
7	04.12.2010	6	1	2
8	05.12.2010	6	1	2
9	06.12.2010	6		
10	07.12.2010	6	2	
11	08.12.2010	6	4	
12	09.12.2010	6	4	
13	10.12.2010	6	4	
14	11.12.2010	6	4	
15	12.12.2010	6	4	
16	13.12.2010	4	6	2
17	14.12.2010	4	6	2
18	15.12.2010	4	6	2
19	16.12.2010	6	4	2
20	17.12.2010	6	4	2
21	18.12.2010	6	4	2
22	19.12.2010	6	2	
23	20.12.2010	6	2	
24	21.12.2010	6	2	
25	22.12.2010	6	2	
26	23.12.2010	6	2	
27	24.12.2010	3	2	6
28	25.12.2010	4	2	6

Abb. 50: Rohdaten Gefahrenmuster 2010-2018 (Datenquelle: LWD Tirol; eigene Darstellung)

Erst mit der Zusammenlegung des Tiroler Lawinenwarndienstes mit jenen aus Südtirol und Trentino im Zuge des ALBINA-Projektes im Jahr 2018 (vgl. LWD Tirol 2021⁶) wurden die Gefahrenmuster in der Folge auf (sub-)regionaler Ebene betrachtet und ausgegeben, was eine Analyse mit Stationsmesswerten wesentlich besser ermöglichen sollte, da dadurch direkte räumliche Relationen gegeben sind.

Der Quelldatensatz vom Lawinenwarndienst Tirol enthielt neben den regional gefilterten Daten zu den Gefahrenmustern auch sämtliche anderen Informationen aus dem Lawinenlagebericht, von den Gefahrenstufen bis hin zu Textbausteinen, die in den jeweiligen Regionen zur Beschreibung der Lawinensituation verwendet wurden. Ein Ausschnitt aus dieser Tabelle soll die Komplexität der Datenstruktur, im Vergleich zu den Daten der Jahre 2010-2018 (siehe Abb. 50), unterstreichen. (siehe Abb. 51)

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q
1	BulletinId	Date	Daytime	Region	Subregion	DangerRating	DangerRating	DangerRating	DangerRating	DangerRating	DangerRating	DangerRating	DangerRating	DangerRating	DangerRating	DangerRating	DangerRating
2	8112d8ae-33f	04.12.2018	AM	AT-07	26	low	low	medium	one	single	N/A	N/A	N/A	moderate	moderate	medium	two
3	8112d8ae-33f	04.12.2018	AM	AT-07	19	low	low	medium	one	single	N/A	N/A	N/A	moderate	moderate	medium	two
4	8112d8ae-33f	04.12.2018	AM	AT-07	20	low	low	medium	one	single	N/A	N/A	N/A	moderate	moderate	medium	two
5	8112d8ae-33f	04.12.2018	AM	AT-07	21	low	low	medium	one	single	N/A	N/A	N/A	moderate	moderate	medium	two
6	8112d8ae-33f	04.12.2018	AM	AT-07	22	low	low	medium	one	single	N/A	N/A	N/A	moderate	moderate	medium	two
7	8112d8ae-33f	04.12.2018	AM	AT-07	12	low	low	medium	one	single	N/A	N/A	N/A	moderate	moderate	medium	two
8	8112d8ae-33f	04.12.2018	AM	AT-07	23	low	low	medium	one	single	N/A	N/A	N/A	moderate	moderate	medium	two
9	8112d8ae-33f	04.12.2018	AM	AT-07	13	low	low	medium	one	single	N/A	N/A	N/A	moderate	moderate	medium	two
10	8112d8ae-33f	04.12.2018	AM	AT-07	24	low	low	medium	one	single	N/A	N/A	N/A	moderate	moderate	medium	two
11	8112d8ae-33f	04.12.2018	AM	AT-07	25	low	low	medium	one	single	N/A	N/A	N/A	moderate	moderate	medium	two
12	98afe585-dfc	04.12.2018	AM	AT-07	27	no_snow	missing	N/A	N/A	N/A	missing	N/A	N/A	low	low	medium	one
13	98afe585-dfc	04.12.2018	AM	AT-07	28	no_snow	missing	N/A	N/A	N/A	missing	N/A	N/A	low	low	medium	one
14	98afe585-dfc	04.12.2018	AM	AT-07	29	no_snow	missing	N/A	N/A	N/A	missing	N/A	N/A	low	low	medium	one
15	a31211de-51f	04.12.2018	AM	AT-07	5	no_snow	missing	N/A	N/A	N/A	missing	N/A	N/A	no_snow	missing	N/A	N/A
16	a31211de-51f	04.12.2018	AM	AT-07	6	no_snow	missing	N/A	N/A	N/A	missing	N/A	N/A	no_snow	missing	N/A	N/A
17	a31211de-51f	04.12.2018	AM	AT-07	17	no_snow	missing	N/A	N/A	N/A	missing	N/A	N/A	no_snow	missing	N/A	N/A
18	a31211de-51f	04.12.2018	AM	AT-07	18	no_snow	missing	N/A	N/A	N/A	missing	N/A	N/A	no_snow	missing	N/A	N/A
19	c542af57-a7a	04.12.2018	AM	AT-07	4	low	low	medium	one	single	low	one	single	low	low	medium	one
20	c542af57-a7a	04.12.2018	AM	AT-07	15	low	low	medium	one	single	low	one	single	low	low	medium	one
21	c542af57-a7a	04.12.2018	AM	AT-07	16	low	low	medium	one	single	low	one	single	low	low	medium	one
22	c542af57-a7a	04.12.2018	AM	AT-07	7	low	low	medium	one	single	low	one	single	low	low	medium	one
23	c542af57-a7a	04.12.2018	AM	AT-07	8	low	low	medium	one	single	low	one	single	low	low	medium	one
24	c542af57-a7a	04.12.2018	AM	AT-07	9	low	low	medium	one	single	low	one	single	low	low	medium	one
25	c542af57-a7a	04.12.2018	AM	AT-07	10	low	low	medium	one	single	low	one	single	low	low	medium	one

Abb. 51: Rohdaten Gefahrenmuster 2018-2020 (Datenquelle: LWD Tirol; eigene Darstellung)

Daher musste beim Einlesen dieser Dateien auf die Auswahl der relevanten Variablen geachtet und für die weitere Verwendung auch regionale und subregionale Filter angewendet werden. Da an manchen Tagen auch tageszeitliche Unterschiede bei den Gefahrenstufen im Lawinenlagebericht gekennzeichnet werden, dies aber nicht an allen Tagen geschieht, wurden für die einheitliche Auswahl der Daten und zur Vermeidung von doppelten Daten für einzelne Tage stets die für den Vormittag ausgegebenen Daten verwendet. Das ist insofern zu argumentieren, dass sich Gefahrenmuster im tageszeitlichen Verlauf in der Regel nicht ändern, sondern lediglich aufgrund von bestimmten Wetter- oder Schneedeckenbedingungen die Gefahrenstufe zwischen Vormittag und Nachmittag variieren kann, was dann so auch im Lagebericht kommuniziert wird. Da die Gefahrenstufe auf diese Datenanalyse keinen direkten Einfluss hat, wurden somit zur Vereinfachung des Einleseprozesses einheitlich die Vormittagsdaten verwendet.

Die Gefahrenmuster wurden als Faktorvariable eingelesen und im Zuge dessen mit den dazugehörigen Kategorienamen von 1 bis 10 gekennzeichnet. (siehe Abb. 52)

```
gmdate_n_lesen <- function(dateiname, Regionswahl, Subregionswahl, Daytimewahl) {  
  gmdate_n <- read.csv(file = dateiname, header = TRUE, sep = ";", na.strings = "N/A")  
  gmdate_n <- filter(gmdate_n, Region == Regionswahl, Subregion == Subregionswahl, Daytime == Daytimewahl)  
  gmdate_n <- select(gmdate_n, Date, Region, Subregion, DangerPattern1, DangerPattern2)  
  names(gmdate_n) <- c("Datum", "Region", "Subregion", "DangerPattern1", "DangerPattern2")  
  
  gmdate_n$Datum <- as.Date(gmdate_n$Datum, format = "%d.%m.%Y")  
  
  gmdate_n$DangerPattern1 <- factor(gmdate_n$DangerPattern1, levels = c(1,2,3,4,5,6,7,8,9,10))  
  gmdate_n$DangerPattern2 <- factor(gmdate_n$DangerPattern2, levels = c(1,2,3,4,5,6,7,8,9,10))  
  
  gmdate_n  
}
```

Abb. 52: Einlesen der Gefahrenmusterdaten (Quelle: eigene Darstellung)

Für das Einlesen der älteren Gefahrenmusterdaten, bei denen aufgrund der bundeslandweiten Bestimmung noch bis zu 3 Gefahrenmuster ausgerufen wurden, musste dieser Code insofern angepasst werden, dass einfach eine dritte Variable hinzugefügt wurde.

Auf Grund der Tatsache, dass die Gefahrenmuster erst ab dem Winter 2018/19 auf Subregionsebene ausgegeben wurden und daher deutlich engere Zusammenhänge mit regionalen Wetterdaten angenommen werden können, wurde für die Erstellung der Modelle, die später ein Auftreten der Gefahrenmuster ermitteln sollten, stets Daten aus den Wintersaisons 2018/19 bzw. 2019/20 verwendet, mehr dazu jedoch in Kapitel 7.4. Zuvor wird, nach dem erfolgreichen Vorbereiten und Einlesen der Daten die Aufbereitung ebendieser behandelt, was als wichtiger Zwischenschritt angesehen werden kann.

7.3. Aufbereitung der Daten

Um einen Einblick in die Verteilung der Gefahrenmuster im Verlauf eines Winters zu bekommen, wurden nach dem Einlesen und ersten Bearbeitungsschritten der Daten in RStudio verschiedene Grafiken erstellt, die die Gefahrenmuster kombiniert mit anderen Variablen wie den Lawinengefahrenstufen, der Schneehöhe, der relativen Luftfeuchte sowie der Lufttemperatur zeigen und mögliche Zusammenhänge erahnen lassen sollen.

Diese Darstellungen wurden zur besseren Anschaulichkeit der Datensätze erstellt und sollen vorrangig die saisonalen Schwankungen der Gefahrenmuster und anderer Parameter gegenüberstellen, um erste Eindrücke von möglichen Relationen zwischen den Einflussvariablen zu bekommen und Erkenntnisse in die folgende Datenanalyse und Ergebnisinterpretation einfließen lassen zu können.




Abb. 53: Gefahrenmuster und Gefahrenstufen in den Östlichen Tuxer Alpen im Winter 2018/19 (Quelle: eigene Darstellung)




Abb. 54: Gefahrenmuster und Gefahrenstufen in den Östlichen Tuxer Alpen im Winter 2019/20 (Quelle: eigene Darstellung)

Abb. 53 und Abb. 54 stellen neben der zeitlichen Verteilung der Gefahrenmuster in den Östlichen Tuxer Alpen in den beiden Wintersaisons 2018/19 und 2019/20 auch die Gefahrenstufe an den jeweiligen Tagen dar. Daraus geht hervor, dass neben gm.6: Kalter lockerer Schnee und Wind, das im Untersuchungszeitraum deutlich am häufigsten ausgerufen wurde und in beiden Wintern fast durchgehend als Problem angesehen wurde, vor allem gm.2: Gleitschnee und gm.10: Frühjahrssituation häufig im Lawinenlagebericht erwähnt wurden. Gleichzeitig gibt es Gefahrenmuster, die in manchen Wintern kein einziges Mal im Lagebericht erscheinen, wie beispielsweise in der betrachteten Subregion gm.7: Schneearme Bereiche in schneereichen Wintern in der Saison 2018/19 oder gm.8: Eingeschneiter Oberflächenreif im Folgejahr.

Bei einer Gegenüberstellung mit den ausgerufenen Gefahrenstufen fällt auf, dass bei gm.5: Schnee nach langer Kälteperiode oder gm.9 Eingeschneiter Graupel ein Auftreten des Gefahrenmusters meist mit einer erheblichen oder gar hohen Lawinengefahr verbunden ist, während gm.3: Regen in den meisten Fällen in Kombination mit einer mäßigen oder gar geringen Gefahrenstufe auftritt.

Wichtig zu erwähnen ist allemal, dass es sich hierbei jedoch lediglich um die Auswertungen der Daten einer einzelnen Subregion über den sehr kurzen Untersuchungsraum von zwei Jahren handelt und daher keine grundsätzlich geltenden Aussagen getroffen werden können, sondern lediglich ein Überblick über die beiden, für die Modellerstellung im nächsten Schritt der Datenanalyse relevanten Wintersaisons in Hinblick auf die Gefahrenmusterverteilung gegeben wird.

Mit den Wetterstationsdaten des Standortes Sonntagsköpfl, der auf 2000m Seehöhe in der eingangs untersuchten Subregion Östliche Tuxer Alpen liegt, wurden die Auftritte der Gefahrenmuster in einem weiteren Schritt mit den meteorologischen Messwerten gegenübergestellt, um hier mögliche Zusammenhänge aufzudecken und einen besseren Einblick in die saisonalen Verläufe beiden Wintersaisons zu erhalten.

Die Ergebnisse dieser Gegenüberstellungen werden in den Abbildungen 55 – 60 grafisch in Form von Zeitreihendiagrammen dargestellt und sollen neben Zusammenhängen auch offensichtliche Unterschiede zwischen den beiden Jahren aufdecken.




Abb. 55: Schneehöhen und Gefahrenmuster in den Östlichen Tuxer Alpen im Winter 2018/19 (Quelle: eigene Darstellung)




Abb. 56: Schneehöhen und Gefahrenmuster in den Östlichen Tuxer Alpen im Winter 2019/20 (Quelle: eigene Darstellung)

Aus den Schneehöhendiagrammen (Abb. 55 und Abb. 56) geht beispielsweise schon auf den ersten Blick heraus, dass es sich beim Winter 2018/19 um einen deutlich schneereicheren handelte als es im Folgejahr der Fall war. Bei der zeitlichen Abfolge der Gefahrenmuster sind anhand der Diagramme und Schneehöhendaten keine Erkenntnisse zu ziehen, lediglich die Dominanz von gm.6 lässt sich durch hohe Auftretszahlen über die gesamten Untersuchungszeiträume erkennen.




Abb. 57: Luftfeuchte und Gefahrenmuster in den Östlichen Tuxer Alpen im Winter 2018/19 (Quelle: eigene Darstellung)




Abb. 58: Luftfeuchte und Gefahrenmuster in den Östlichen Tuxer Alpen im Winter 2019/20 (Quelle: eigene Darstellung)

Bei den Gegenüberstellungen der Messwerte zur Luftfeuchte und den Auftritten der Gefahrenmuster am Standort Sonntagsköpfl (siehe Abb. 57 und Abb. 58) ist es aufgrund der starken Schwankungen in den meteorologischen Daten nicht möglich, gezielte Aussagen zu treffen. Rückschlüsse zu Zusammenhängen zwischen bestimmten Ausprägungen des untersuchten Wetterparameters und Auftritten eines speziellen Gefahrenmusters können hier mit den Daten zu Luftfeuchte ebenso wenig gezogen werden, wie zuvor mit den Daten zu Schneehöhen.




Abb. 59: Lufttemperatur und Gefahrenmuster in den Östlichen Tuxer Alpen im Winter 2018/19 (Quelle: eigene Darstellung)




Abb. 60: Lufttemperatur und Gefahrenmuster in den Östlichen Tuxer Alpen im Winter 2019/20 (Quelle: eigene Darstellung)

Ebenso wie bei den zuvor untersuchten Zusammenhängen zwischen Luftfeuchte und Auftritten der Gefahrenmuster, lassen auch die Messwerte zur Lufttemperatur anhand der Diagrammdarstellungen (Abb. 59 und Abb. 60) keine präzisen Aussagen diesbezüglich zu. Korrelationen zwischen Lufttemperaturen über der Nullgradgrenze und Auftritten von gm.10 können beispielsweise nur vermutet werden.

Konkrete Zusammenhänge zwischen bestimmten Ausprägungen der meteorologischen Parameter und dem Auftreten von bestimmten Gefahrenmustern können anhand der Grafiken zusammenfassend somit nicht aufgedeckt werden, weshalb eine detaillierte Datenanalyse weitere Aufschlüsse und insbesondere statistische Nachweise diesbezüglich liefern soll.

7.4. Analysemethode

Ziel der Datenanalyse ist grundsätzlich die Feststellung des Einflusses der Wetterparameter auf das Auftreten einzelner Gefahrenmuster. Bevor eine solche Analyse durchgeführt werden konnte, musste eine, an die vorhandenen Datentypen angepasste Methode gefunden werden. Im Folgenden wird anfangs auf den Prozess eingegangen, der zur Auswahl des Analyseverfahrens führte, bevor dessen Teilschritte detailliert und mithilfe der verwendeten Codes vorgestellt werden. Dabei werden sowohl nötige Vorbereitungsschritte bis hin zur Durchführung der Analyse dokumentiert als auch relevante Parameter zur Ergebnisinterpretation erläutert.

Grundsätzlich lag mit den Gefahrenmustern eine abhängige kategoriale Variable vor, die jedoch durch die mögliche Erwähnung mehrerer Gefahrenmuster pro Tag nicht als klassische kategoriale Variable gehandhabt werden konnte. Die unabhängigen Variablen stellten die meteorologischen Messdaten beziehungsweise die eingangs ermittelten Tagesmittelwerte der verschiedenen Wetterparameter dar.

Das Auftreten der Gefahrenmuster in mehreren Spalten erschwerte eine Untersuchung und um die Auswirkungen der Wetterdaten auf die einzelnen Gefahrenmuster bestmöglich darzustellen, mussten die Gefahrenmuster selektiert und in einer Spalte dargestellt werden. Dazu wurde die Erstellung einer Dummyvariable herangezogen, die lediglich Auskunft über das Auftreten (TRUE) beziehungsweise Nichtauftreten (FALSE) eines ausgewählten Gefahrenmusters geben sollte.

Zur Erstellung dieser Dummyvariable musste eine Funktion überprüfen, ob in einer der beiden Spalten, in denen die Gefahrenmuster in den Datensätzen dokumentiert wurden (in den Rohdaten als „DangerPattern1“ und „DangerPattern2“ gekennzeichnet), an den einzelnen Tagen das gewünschte Gefahrenmuster auftritt. Diese Funktion wurde mithilfe des Codes umgesetzt, der in Abb. 61 zu sehen ist.

```
vergleich <- function( wert1, wert2, gm) {
  if ( is.na(wert1) & is.na(wert2) ) return(NA)

  f1 <- gm == wert1
  f2 <- gm == wert2

  if (is.na(f1)) return(f2)
  if (is.na(f2)) return(f1)

  return(f1 | f2)
}

gm_auswahl <- function(tabelle, gefahrenmuster) {
  print(paste("gm ist ", gefahrenmuster))

  ww <- mutate(tabelle, gefahrenmuster)
  for (zeile in 1:nrow(ww)) {
    dp1 <- ww[zeile, "DangerPattern1"]
    dp2 <- ww[zeile, "DangerPattern2"]
    zz <- vergleich(dp1, dp2, gefahrenmuster)
    ww[zeile, "muster"] <- zz
  }

  ww
}
```

Abb. 61: Auswahl eines Gefahrenmusters (Quelle: eigene Darstellung)

Ist dies der Fall und das untersuchte Gefahrenmuster wurde in den Daten erkannt, wird dieser Tag in der, durch eine mutate-Funktion neu hinzugefügten Spalte „muster“, als TRUE gekennzeichnet. Ist das gefragte Gefahrenmuster an einem Tag in keiner der beiden Spalten im Datensatz erwähnt, so erhält jener Tag den Eintrag FALSE in der neuen Spalte und verweist damit auf das Nichtauftreten des zu untersuchenden Gefahrenmusters an dem jeweiligen Tag.

An Tagen, an denen beispielsweise aufgrund besonders stabiler Lawinensituation kein Gefahrenmuster ausgerufen wurde und somit sowohl die Spalte „DangerPattern1“ als auch „DangerPattern2“ NA-Werte aufweisen, wird dieser Tag in der neuen Spalte ebenso als NA (not available) gekennzeichnet. (vgl. Abb. 62)

Datum	Region	Subregion	DangerPattern1	DangerPattern2	gefahrenmuster	muster
2020-01-14	AT-07	10	2	7	6	FALSE
2020-01-15	AT-07	10	2	7	6	FALSE
2020-01-16	AT-07	10	NA	NA	6	NA
2020-01-17	AT-07	10	NA	NA	6	NA
2020-01-18	AT-07	10	NA	NA	6	NA
2020-01-19	AT-07	10	6	1	6	TRUE
2020-01-20	AT-07	10	6	1	6	TRUE
2020-01-21	AT-07	10	6	NA	6	TRUE

Abb. 62: Hinzufügen einer Dummyvariable (Quelle: eigene Darstellung)

Das Erstellen dieser Dummyvariable ermöglicht die Durchführung einer binären logistischen Regression, die die Auswirkungen mehrerer unabhängiger Variablen auf eine kategoriale (Dummy-) Variable und in diesem Fall auf ein spezifisches Gefahrenmuster berechnet. Dabei wird anhand eines Trainingsdatensatzes der Einfluss der meteorologischen Parameter modelliert und das Modell schließlich an den Datensätzen der anderen Wetterstationen getestet und so Regelmäßigkeiten und Abhängigkeiten aufgedeckt.

Da in den Datensätzen von 2010 bis 2018 die Gefahrenmuster für ganz Tirol ausgegeben wurden, wurden in diesem Zeitraum bis zu drei Gefahrenmuster pro Tag im Lawinenlagebericht erwähnt, was wiederum eine leichte Anpassung des Codes in Form einer Erweiterung um eine weitere Variable zur Folge hatte, die die Ausprägung der Spalte „DangerPattern3“ untersuchen sollte. (siehe Abb. 63)

```

vergleich_alt <- function( wert1, wert2, wert3, gm) {
  if ( is.na(wert1) & is.na(wert2) ) return(NA)

  f1 <- gm == wert1
  f2 <- gm == wert2
  f3 <- gm == wert3

  if (is.na(f1)) return(f2)
  if (is.na(f2)) return(f1)
  if (is.na(f3)) return(f1)

  return(f1 | f2 | f3)
}

gm_auswahl_alt <- function(tabelle, gefahrenmuster) {
  print(paste("gm ist ", gefahrenmuster))

  ww <- mutate(tabelle, gefahrenmuster)
  for (zeile in 1:nrow(ww)) {
    dp1 <- ww[zeile, "DangerPattern1"]
    dp2 <- ww[zeile, "DangerPattern2"]
    dp3 <- ww[zeile, "DangerPattern3"]
    zz <- vergleich_alt(dp1, dp2, dp3, gefahrenmuster)
    ww[zeile, "muster"] <- zz
  }

  ww
}

```

Abb. 63: Angepasste Auswahl eines Gefahrenmusters (Quelle: eigene Darstellung)

Zur Verwendung der Daten für die Analyse mussten die Datensätze zu den meteorologischen Messwerten und der Gefahrenmusterselektion anschließend zu einem gemeinsamen Datensatz zusammengefügt werden, was mithilfe einer join-Funktion umgesetzt wurde. (siehe Abb. 64) In dieser Funktion wurde auch der gewünschte Untersuchungszeitraum mit einem Start- und Enddatum manuell festgelegt und die Datensätze schließlich anhand der Datumsspalte miteinander verknüpft.

```
join <- function(date1, date2, HS, LF, LT, gm) {
  a <- as.Date(date1, format = "%d.%m.%Y")
  b <- as.Date(date2, format = "%d.%m.%Y")
  zeitraum <- data.frame(seq(a,b, "days"))
  names(zeitraum) <- c("Datum")

  daten <- left_join(zeitraum, tagesmittelwerte(HS), by = "Datum")
  daten <- left_join(daten, tagesmittelwerte(LF), by = "Datum")
  daten <- left_join(daten, tagesmittelwerte(LT), by = "Datum")
  names(daten) <- c("Datum", "HS", "LF", "LT")
  daten <- left_join(daten, gm, by = "Datum")

  daten
}
```

Abb. 64: Verknüpfung der Wetter- und Gefahrenmusterdaten (Quelle: eigene Darstellung)

Nachdem die Datensätze für die Analyse vorbereitet und zusammengefügt wurden, konnte mit der Modellerstellung der eigentliche Kernteil der Datenanalyse in Angriff genommen werden.

	Datum	WG	LF	LT	TP	Region	Subregion	DangerPattern1	DangerPattern2	gefahrenmuster	muster	Differenz
94	2020-02-02	5.1661111	85.602083	1.94791667	-0.42937500	AT-07	4	7	3	3	TRUE	-1.2708333
95	2020-02-03	5.6686806	95.849306	2.18750000	1.55861111	AT-07	4	3	6	3	TRUE	0.2395833
96	2020-02-04	5.5557639	87.617361	-3.98819444	-6.07666667	AT-07	4	6	2	3	FALSE	-6.1756944
97	2020-02-05	8.7286111	89.850000	-9.06111111	-10.43062500	AT-07	4	6	9	3	FALSE	-5.0729167
98	2020-02-06	1.7700000	30.127083	-4.59375000	-20.55256944	AT-07	4	6	9	3	FALSE	4.4673611
99	2020-02-07	3.2053472	27.800000	0.76180556	-15.95111111	AT-07	4	6	9	3	FALSE	5.3555556
100	2020-02-08	3.2927778	36.550000	1.18055556	-12.04631944	AT-07	4	6	7	3	FALSE	0.4187500
101	2020-02-09	4.4011806	47.550000	-0.32708333	-10.51729167	AT-07	4	7	2	3	FALSE	-1.5076389
102	2020-02-10	5.7881944	83.526389	-0.91041667	-3.56729167	AT-07	4	6	3	3	TRUE	-0.5833333
103	2020-02-11	5.2461111	94.607639	-4.28125000	-5.05590278	AT-07	4	6	4	3	FALSE	-3.3708333
104	2020-02-12	3.3972222	98.209028	-7.12152778	-7.36027778	AT-07	4	6	4	3	FALSE	-2.8402778
105	2020-02-13	7.0081944	58.393056	-4.46180556	-11.86715278	AT-07	4	6	4	3	FALSE	2.6597222
106	2020-02-14	3.0703472	98.970139	-3.87430556	-4.01041667	AT-07	4	6	4	3	FALSE	0.5875000
107	2020-02-15	3.4273611	31.516667	2.59930556	-15.74944444	AT-07	4	6	4	3	FALSE	6.4736111
108	2020-02-16	5.0899306	21.837500	6.23680556	-14.13229167	AT-07	4	6	2	3	FALSE	3.6375000
109	2020-02-17	3.2352083	51.435417	4.20555556	-6.11895833	AT-07	4	6	2	3	FALSE	-2.0312500
110	2020-02-18	2.2047222	67.038194	-2.29861111	-8.09270833	AT-07	4	6	2	3	FALSE	-6.5041667
111	2020-02-19	3.2041667	85.729167	-6.06111111	-8.28444444	AT-07	4	6	NA	3	FALSE	-3.7625000

Abb. 65: Darstellung der kombinierten Wertetabellen (Quelle: eigene Darstellung)

Die Datenanalyse erfolgt mittels binärer logistischer Regression, wobei anhand eines Trainingsdatensatzes (vgl. Abb. 65) ein Modell für die Gefahrenmusterprognose erstellt wird. Diese binäre logistische Regression wurde für einzelne Gefahrenmuster separat angewandt. Die Einflussfaktoren bzw. unabhängigen Variablen stellen die meteorologischen Parameter dar, genauere Ausführungen zu den verwendeten Parametern folgen bei den Auswertungen der jeweiligen Modelle, da die Charakteristik der einzelnen Gefahrenmuster individuelle Einflussfaktoren für die Analyse voraussetzt.

Im Anschluss an die Modellerstellung wird, insofern mithilfe des Modells Zusammenhänge statistisch nachgewiesen werden konnten und das Modell eine gewisse Güte – Details zur Bestimmung der Modellgüte werden in Kapitel 7.4.1 behandelt – aufweist, die Genauigkeit der Modelle anhand von Testdaten überprüft. Diese Testdaten sind in ihrer Datenstruktur gleich aufgebaut wie die Trainingsdatensätze, beinhalten jedoch die Messwerte aus anderen Jahren bzw. von anderen

Wetterstationsstandorten. Dadurch sollen die an Standort A aufgedeckten Zusammenhänge an Standort B getestet werden, um die Aussagekraft der Modelle zu unterstreichen beziehungsweise zu widerlegen.

Um die Güte des Modells und damit die Prognostizierbarkeit der Gefahrenmuster anhand der meteorologischen Parameter allerdings überprüfen zu können, ist eine gewisse Anzahl an Tagen mit dem jeweiligen Gefahrenmuster vonnöten, weshalb vor der Modellerstellung die Gefahrenmusterdaten aus den Jahren 2010 – 2018 auf absolute Auftrittszahlen überprüft wurden.

In Tabelle 2 sind die Auftrittszahlen nach Gefahrenmuster sortiert und anhand der TRUE-Ausgaben ersichtlich. FALSE bezieht dabei jene Tage, an denen zwar Gefahrenmuster im Lagebericht erwähnt wurden, jedoch nicht das spezifisch untersuchte, während NA's auf jene Tage hinweist, an denen im Untersuchungszeitraum keine Gefahrenmuster ausgerufen wurden.

gm.1	<pre>> summary(gm_daten\$muster) Mode FALSE TRUE NA's logical 787 321 11</pre>	gm.6	<pre>> summary(gm_daten\$muster) Mode FALSE TRUE NA's logical 398 710 11</pre>
gm.2	<pre>> summary(gm_daten\$muster) Mode FALSE TRUE NA's logical 698 410 11</pre>	gm.7	<pre>> summary(gm_daten\$muster) Mode FALSE TRUE NA's logical 993 115 11</pre>
gm.3	<pre>> summary(gm_daten\$muster) Mode FALSE TRUE NA's logical 1033 75 11</pre>	gm.8	<pre>> summary(gm_daten\$muster) Mode FALSE TRUE NA's logical 990 118 11</pre>
gm.4	<pre>> summary(gm_daten\$muster) Mode FALSE TRUE NA's logical 1004 104 11</pre>	gm.9	<pre>> summary(gm_daten\$muster) Mode FALSE TRUE NA's logical 1064 44 11</pre>
gm.5	<pre>> summary(gm_daten\$muster) Mode FALSE TRUE NA's logical 1058 50 11</pre>	gm.10	<pre>> summary(gm_daten\$muster) Mode FALSE TRUE NA's logical 849 259 11</pre>

Tabelle 2: Übersicht über absolute Auftrittszahlen der Gefahrenmuster in Tirol im Untersuchungszeitraum 2010-2018 (Quelle: eigene Darstellung)

Die geringen Auftrittszahlen der anderen Gefahrenmuster lassen eine statistische Modellierung lediglich bei den Gefahrenmustern gm.1, gm.2, gm.6 und gm.10 zu, da zur Auffindung von möglichen Zusammenhängen mit den unabhängigen Wettervariablen eine gewisse Mindestanzahl an Auftritten vorhanden sein muss. In der Folge wurden daher lediglich für die genannten Gefahrenmuster logistische Regressionen berechnet.

Für jedes der vier ausgewählten Gefahrenmuster wurden separat zwischen zwei und drei Stationen ausgewählt, anhand derer eine Modellerstellung in Angriff genommen wurde. Um mögliche saisonale Schwankungen abzudecken und die Repräsentativität der Untersuchung zu gewährleisten, wurden zur Modellerstellung jeweils die Datensätze der Wintersaison 2018/19 sowie 2019/20 herangezogen, da in diesen Jahren die Gefahrenmuster bereits subregional ausgegeben wurden und dadurch ein höherer Zusammenhang mit den Messwerten gegeben ist. Eine Modellerstellung auf Basis früherer Daten, als die Gefahrenmuster zwischen 2010 und 2018 noch für ganz Tirol ausgegeben wurden und keine regionale Unterteilung stattgefunden hat, wäre mit einer zu großen Ungenauigkeit verbunden, da das Auftreten eines Gefahrenmusters nicht zwingend in der betroffenen Region der Wetterstation akut gewesen sein muss und der Zusammenhang mit den Daten daher möglicherweise gar nicht vorzufinden sein kann. Mit der Entscheidung, zur Modellerstellung die Daten aus den Jahren 2018/19 und 2019/20 zu verwenden, konnte dem vorgebeugt werden und zumindest in der Theorie eine höhere Genauigkeit erzielt werden.

Durch die Erstellung von zwei Modellen (2018/19 und 2019/20) je ausgewählter Station, wurden folglich bei zwei beziehungsweise drei ausgewählten Wetterstationen zu jedem der untersuchenden Gefahrenmuster zwischen vier und sechs Modelle berechnet, die dabei helfen sollen, mögliche

Zusammenhänge zwischen den meteorologischen Messwerten und den Auftritten der Lawinengefahrenmuster darzulegen.

Die Ergebnisse der Modellberechnung werden in Kapitel 8 ausführlich vorgestellt und interpretiert.

7.4.1. Entscheidende Werte für Ergebnisinterpretation

Um die Eignung eines Modells für spätere Analysen und im weiteren Verlauf Ergebnisse der Modellberechnungen interpretieren zu können, ist ein Vorwissen über entscheidende Werte als Voraussetzung anzusehen. Bei der Erstellung der Modelle werden vom Programm RStudio Kennzahlen ausgegeben, deren Ausprägungen zur Beschreibung der Modellgüte und folglich der Genauigkeit der Modellprognose herangezogen werden und Rückschlüsse darauf geben sollen, ob die erstellten Modelle zu einer Überprüfung anhand anderer Daten überhaupt geeignet erscheinen. Es folgt eine kurze Beschreibung (vgl. R-bloggers 2021) dieser entscheidenden Werte, um spätere Entscheidungen im Zuge der Ergebnisanalyse transparent und nachvollziehbar zu gestalten.

Fitted values: Beschreibt jenen Grenzwert, ab dem die berechnete Wahrscheinlichkeit eines Auftretens des Gefahrenmusters als ausreichend gehandhabt wird, um die jeweiligen Tage als Auftrittstage des Gefahrenmusters zu zählen. Dieser wurde bei sämtlichen Analysen einheitlich mit 0,5 ausgewiesen, was folglich bedeutet, dass nur Tage als Auftrittstage (Ausgabe TRUE) gekennzeichnet werden, bei denen das Modell eine Wahrscheinlichkeit eines Auftretens von über 50% ausgab, während alle Tage, an denen das nicht zutrifft mit FALSE gekennzeichnet wurden.

Diese werden in einer Tabelle (siehe Abb. 66) zusammengefasst ausgegeben und mit den tatsächlichen Fällen gegenübergestellt, wodurch bereits ein erster und wichtiger Einblick in die Genauigkeit (= Accuracy) der Modellberechnung gewährleistet wird.

n=165		Predicted: NO	Predicted: YES
		True Negative 50	False Positive 10
Actual: NO			
Actual: YES		False Negative 5	True Positive 100

Abb. 66: Beispielauswertung eines Modells (Quelle: R-bloggers 2021)

Accuracy: Die Accuracy oder Genauigkeit eines Modells beschreibt das Verhältnis der richtigen (True Positive und True Negative) Prognosen auf den gesamten Datensatz. Ein Modell erscheint dabei bei einer Genauigkeit von über 70% als gut geeignet, darunterliegende Werte müssen als unzureichende Prognosen eingestuft werden. Im angeführten Beispiel (Abb. 66) liegt die Accuracy bei über 90%, da 150 von 165 Fällen richtig prognostiziert wurden, was folglich darauf schließen lässt, dass dieses Modell für eine weitere Analyse sehr gut geeignet erscheint.

Neben der Accuracy, die durchaus als wichtigster Bestimmungsparameter der Modellgüte anzusehen ist, werden vom Programm weitere Werte ausgegeben, die dabei helfen sollen, die Genauigkeit der Modellprognosen detaillierter zu beschreiben. Im Folgenden werden auch diese Kenngrößen kurz beschrieben, da sie auch im weiteren Verlauf der Datenanalyse von Bedeutung sind.

Recall: Recall wird auch als TPR (True Positive Rate) bezeichnet und beschreibt den Prozentwert, wie viele tatsächliche Auftrittstage auch vom Modell als solche prognostiziert werden. Um wieder auf das Beispiel in Abb. 66 zurückzukommen, ist festzuhalten, dass in diesem Fall der Recall-Wert bei über 95% liegt, da von 105 Auftrittstagen (Actual: YES) 100 vom Modell als solche identifiziert werden konnten.

TNR: Die True Negative Rate beschreibt denselben Effekt für die Tage an denen kein Auftreten des Gefahrenmusters vorlag und somit jenen Prozentwert an prognostizierten Nichtauftritten von den gesamten Nichtauftritten des Gefahrenmusters. Anhand der Daten, die zur Erstellung von Abb. 66 herangezogen wurden, wäre dieser Wert bei 83,3% anzufinden, da 50 (True Negative) von 60 (Actual: NO) Fällen vom Modell bestimmt werden konnten.

Precision: Dieser Wert beschreibt, bei wie vielen der prognostizierten Auftrittsfälle es sich tatsächlich um Auftrittsfälle handelt. Anhand des Beispiels in Abb. 66 liegt der Precision-Wert hier bei über 90%, da es sich bei 100 der 110 prognostizierten (Predicted:YES) um True Positive-Fälle handelt.

F-score: Der sogenannte F-score beschreibt das harmonische Mittel aus Recall und Precision und liegt stets zwischen 0 und 1. Der Wert 1 repräsentiert dabei perfekte Precision und Recall und somit den Fall, in dem das Modell alle Auftritte des Gefahrenmusters auch als solche prognostiziert. Liegt der F-score bei 0 so konnte das Modell kein Auftreten des Gefahrenmusters als solches kennzeichnen.

Auc: Die „area under curve“ symbolisiert einen Lineplot zwischen Recall (=TPR) und TNR und soll ebenfalls über die Güte des Modells Auskunft geben, wobei wiederum 0.7 als statistischer Grenzwert angesehen wird.

Unter Rücksichtnahme auf diese entscheidenden Werte kann die Modellerstellung auf ihre Eignung für die Analyse beurteilt werden, weshalb die Interpretation dieser Größen für die Entscheidungsfindung zu Beginn der Datenanalyse als unabdingbar anzusehen ist. Kann ein Modell die angestrebten Grenzwerte nicht aufweisen, so zeigt das zu geringe beziehungsweise nicht auffindbare Zusammenhänge zwischen den unabhängigen Variablen auf die abhängige Variable auf und es muss auf die weitere Analyse und somit die Überprüfung der Modelle anhand anderer Stationsdaten verzichtet werden, da nicht mit repräsentativen Ergebnissen zu rechnen ist.

Bei der Überprüfung anhand der Testdatensätze kommt die Interpretation dieser Werte erneut zum Einsatz, da diese Kenngrößen wiederum Auskunft über die Genauigkeit der Modellprognose liefern.

7.4.2. Datenlücken

Es kann durchaus vorkommen, dass die nachzuweisenden TRUE-Fälle nicht mit den ausgewiesenen Fällen aus dem jeweiligen Jahr übereinstimmen. Das liegt daran, dass in den Datensätzen der Wetterstationen mitunter Tageswerte einzelner meteorologischer Parameter fehlen und für die Prognose der Gefahrenmuster sämtliche in der Analyse verwendeten Parameter Werte aufweisen müssen, da das Modell ansonsten keine Auftrittswahrscheinlichkeit für den besagten Tag berechnen kann.

<pre>> summary(test_1920\$muster)</pre> <table><tr><th>Mode</th><th>FALSE</th><th>TRUE</th></tr><tr><td>logical</td><td>126</td><td>36</td></tr></table>	Mode	FALSE	TRUE	logical	126	36	<pre>> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5)</pre> <table><tr><th></th><th>FALSE</th><th>TRUE</th></tr><tr><th>FALSE</th><td>114</td><td>4</td></tr><tr><th>TRUE</th><td>3</td><td>21</td></tr></table> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 95.07042</pre>		FALSE	TRUE	FALSE	114	4	TRUE	3	21
Mode	FALSE	TRUE														
logical	126	36														
	FALSE	TRUE														
FALSE	114	4														
TRUE	3	21														

Tabelle 3: Beispielauswertung zum Auftreten vom gm.10 am Stationsstandort Tuxerjoch im Winter 2019/20 (Quelle: eigene Darstellung)

Von den 36 Fällen, in denen an der Station Tuxerjoch im Winter 19/20 Gefahrenmuster 10 ausgegeben wurde (siehe Tabelle 3), konnten insgesamt nur 24 TRUE-Fälle vom Modell bewertet werden, weil in der Saison 2019/20 an insgesamt 12 Tagen, an denen gm.10 auftrat, Werte zur Lufttemperatur fehlen und das Modell folglich keine Prognose für diese Tage anstellen konnte.

Allerdings handelt es sich dabei nicht um die einzigen fehlenden Werte, weshalb im Folgenden eine kurze Übersicht über Datenlücken jegliche Missinterpretationen vorbeugen soll.

An der Station Tuxerjoch erfolgte aufgrund einer Standortänderung die Messung meteorologischer Parameter erst ab dem 19.12.2012. In den für die Modellerstellung verwendeten Wintersaisons 2018/19 und 2019/20 liegt an einem bzw. zwölf Tagen eine Datenlücke vor. Dabei handelt es sich um den 11.04.2019, an dem keine relative Luftfeuchte verzeichnet wurde und um mehrere Tage in der Folgesaison, in der keine Lufttemperatur gemessen werden konnte.

Die Station Magdeburger Hütte & Hechenberg ist erst ab September 2014 in Betrieb, weshalb davor keine Messwerte vorliegen und für diesen Bereich keine Überprüfung der Modelle durchgeführt werden kann.

Der Standort Mosesgipfel ist ebenfalls nicht seit Beginn der Aufzeichnung der Gefahrenmuster in Betrieb und wurde erst im Jahr 2018 installiert, ist aber für die vorhandenen Messdaten als relevant für die Analyse anzusehen.

Die Station Rendl Riffel 1 & Salzboden verzeichnete Ende April 2020 eine längere Absenz sowohl bei Daten zu Windgeschwindigkeit als auch Schneehöhe, während am Standort Salzboden erst ab September 2015 Windgeschwindigkeiten gemessen wurden.

Längere Datenlücken wurden auch an der Station St. Veit verzeichnet. Dabei handelt es sich um fehlende Werte zu Schneehöhe in Jänner und Februar 2020, sowie fehlende Werte zu Windgeschwindigkeit im Jänner 2019. Auch hier wurde erst Oktober 2014 mit der Messung meteorologischer Parameter begonnen.

Lediglich für die Modelle zu gm.2 und gm.10 relevant ist das Fehlen der Messdaten zur Globalstrahlung in der Saison 2019/20 am Stationsstandort Tscheyegg, weshalb für diesen Zeitraum mit dieser Station keine Überprüfung der Modelle durchgeführt werden konnte. Auf die anderen Analysen hat das jedoch keine Auswirkung, da die Globalstrahlung nur bei der Modellerstellung von gm.2 und gm.10 berücksichtigt wurde.

Trotz dieser Datenlücken liefern die ausgewählten Wetterstationen eine mehr als ausreichende Datengrundlage für die anstehende Analyse, weshalb diese im Folgenden unter Berücksichtigung der beschriebenen Methode in Angriff genommen wurde.

8. Analyseergebnisse

Als Folge einer intensiven Auseinandersetzung mit dem theoretischen Konzept und unter Berücksichtigung der definierten Ziele, wurden nach der Bearbeitung und Vorbereitung der zur Verfügung stehenden Daten binäre logistische Regressionen zu den zu untersuchenden Gefahrenmustern gm.1, gm.2, gm.6 und gm.10 berechnet, um mögliche Zusammenhänge zwischen den Wetterstationsdaten und den einzelnen Gefahrenmustern aufzudecken und statistisch zu beschreiben. Im folgenden Kapitel werden die Ergebnisse dieser Analysen näher vorgestellt, Bewertungen zu den jeweiligen Auswertungen angegeben und abschließend Interpretationen zu möglichen Hintergründen für bestimmte aufgedeckte oder nicht aufgedeckte Zusammenhänge angestellt. Dabei werden die Modelle nach dem Gefahrenmuster getrennt angeordnet und auf Outputs der Datenanalyse im Anhang verwiesen, um den Lesefluss aufrechtzuerhalten.

Untersuchtes Gefahrenmuster	Verwendete Stationen zur Modellerstellung
gm.1: Bodennahe Schwachschicht	Modell 1: Tuxerjoch
	Modell 2: St. Veit
	Modell 3: Mosesgipfel
gm.2: Gleitschnee	Modell 1: Mosesgipfel
	Modell 2: Rendl Riffel 1 & Salzboden
gm.6: Lockerer Schnee und Wind	Modell 1: Tuxerjoch
	Modell 2: St. Veit
	Modell 3: Rendl Riffel 1 & Salzboden
gm.10: Frühjahrssituation	Modell 1: Rendl Riffel 1 & Salzboden
	Modell 2: St. Veit

Tabelle 4: Übersicht über erstellte Modelle

Beginnend mit gm.1 werden im Folgenden die zur Modellerstellung verwendeten Trainingsdatensätze als solche gekennzeichnet, die Modellgüte anhand der relevanten Werte interpretiert, Ergebnisse der Modellüberprüfung an den Testdatensätzen kommentiert und zu jedem der vier untersuchten Gefahrenmuster ein abschließendes Fazit über Prognosegenauigkeit und Analyseergebnisse gegeben.

8.1. Gefahrenmuster 1: Bodennahe Schwachschicht

Bei Gefahrenmuster 1 handelt es sich mit der bodennahen Schwachschicht um ein Phänomen, das meist sehr kleinräumig im hohen und hochalpinen Bereich in schattigem, sehr steilem Gelände auftritt. (vgl. MAIR und NAIRZ 2010: 31) Basierend auf diesem Wissen wurde für die Modellerstellung zur Prognose des Gefahrenmusters die Station Tuxerjoch gewählt, die durch ihre Lage auf über 2300m Seehöhe und ihrer nordöstlichen Exposition am Standort sehr geeignet schien, um repräsentative Aussagen zu den Zusammenhängen zwischen den Messdaten und den Auftritten von gm.1 zu liefern, da sowohl Höhenlage als auch Exposition in die ausgewiesenen typischen Gefahrenbereiche fallen. Um die Bedeutung dieser Standortfaktoren bestimmen zu können und mögliche Unterschiede darlegen zu können, wurde zusätzlich ein Modell mit den Wetterdaten der Station St. Veit erstellt, die mit über 2100m Seehöhe zwar im vorrangig anfälligen Höhenbereich des Gefahrenmusters liegt, jedoch in ihrer

südseitigen Exposition deutliche Unterschiede in den meteorologischen Messdaten ausweisen sollte. Zusätzlich wurde nach Sichtung der verfügbaren Daten auch von der Station Mosesgipfel, die ebenso wie St. Veit in Osttirol liegt, ein Modell erstellt, da in den jeweiligen Subregionen in der Wintersaison 2018/19 besonders hohe Auftrittszahlen von gm.1 verzeichnet wurden und anhand der Datenanalyse mögliche Gründe dafür erörtert werden sollten, da die Auftrittszahlen an den anderen Stationen und auch in der Wintersaison 2019/20 vergleichsweise sehr niedrig ausfielen und grundsätzlich hohe Auftrittszahlen zur Bestimmung einer Relation zu den unabhängigen Variablen aufgrund des größeren Untersuchungsrahmens von Vorteil sind. Somit wurden anhand der Messdaten dreier Stationen Modelle zur Prognose von gm.1 berechnet, deren Ergebnisse im Folgenden vorgestellt werden.

Die Modellerstellung wurde auf Basis der Trainingsdatensätze der ausgewählten Stationen mit den Messwerten der Wintersaisons 2018/19 bzw. 2019/20 zu den meteorologischen Parametern Schneehöhe, relative Luftfeuchte, Lufttemperatur, Windgeschwindigkeit sowie eintägiger Differenz der Lufttemperatur durchgeführt.

Modell 1: Tuxerjoch

Trainingsdaten:		
Station:	Tuxerjoch Schneestation und Tuxerjoch Windstation	
Seehöhe:	2380m und 2518m	
Subregion:	Westliche Tuxer Alpen (AT-07-15)	
Exposition:	NO	

Tabelle 5: Trainingsdaten gm.1, Modell 1: Tuxerjoch

Die absoluten Auftrittszahlen von gm.1 lagen in den, für die Modellerstellung verwendeten Wintersaisons 2018/19 und 2019/20 in der Subregion Westliche Tuxer Alpen bei 15 beziehungsweise 2 Tagen.

Aufgrund der geringen Auftrittszahlen in der Saison 2019/20 konnte eine Modellerstellung auf Basis dieses Datensatzes nicht abgeschlossen werden, da das Modell anhand dieser Daten nicht in der Lage war, das Auftreten von gm.1 zu prognostizieren. Mit den Daten aus 2018/19 konnte eine Modellerstellung durchgeführt werden, die zwar hohe Werte bei Accuracy, TNR und Precision aufweist, mit einem Recall von nur 53.3% gleichzeitig aber nur 8 der 15 Auftrittsfälle von gm.1 identifizieren konnte. Aufgrund der hohen Ausprägungen der Werte zu TNR und Precision wurde jedoch die Entscheidung getroffen, das Modell anhand der Daten anderer Stationen zu überprüfen.

Im Anhang 2.1 finden sich neben den relevanten Werten, die im Zuge der Modellerstellung begutachtet wurden, auch die detaillierten Modellprognosen zu den unterschiedlichen Stationen. Zusammenfassend ist zu erwähnen, dass die Prognose von gm.1 anhand dieses Modells nicht ausreichend angestellt werden konnte. In den meisten Fällen liegt die Accuracy unter dem Grenzwert von 70% und in jenen Fällen, in denen die Genauigkeit auf über 70% beziffert wurde, hängt das vorrangig mit einer hohen True Negative Rate zusammen, während die tatsächlichen Auftritte nicht annähernd akkurat prognostiziert werden konnten und das Ziel der Analyse somit nicht als erfüllt angesehen werden kann.

Modell 2: St. Veit

Trainingsdaten:		
Station:	St. Veit Zischke und St. Veit Speikboden	
Seehöhe:	2115m und 2630m	
Subregion:	Östliche Rieserfernergruppe (AT-07-25)	
Exposition:	S	

Tabelle 6: Trainingsdaten gm.1, Modell 2: St. Veit

Die Auswahl dieser Station zur Modellerstellung basierte auf der Annahme, dass aufgrund der hohen Auftrittszahlen (57 Tage) von gm.1 im Winter 2018/19 in der Subregion Östliche Rieserfernergruppe, die Wahrscheinlichkeit eines Auffindens von Zusammenhängen mit den meteorologischen Einflussparametern größer sein sollte als an Standorten mit wesentlich geringeren Auftrittszahlen.

Leider musste diese Hypothese bei der Modellerstellung schnell widerlegt werden, da mit dem Trainingsdatensatz 2018/19 keine Relationen zwischen den unabhängigen Variablen und den Gefahrenmustern aufgezeigt werden konnte. Wie in der Tabelle in Anhang 2.2 zu erkennen ist, konnte das Modell lediglich 5 der 57 Auftrittstage als solche identifizieren, was einer mehr als unzureichenden Recall-Quote von 8.9% entspricht. Zwar wurden von den 85 Tagen ohne gm.1 80 als solche True Negative-Events erkannt, aufgrund der geringen True Positive Rate musste auf eine Überprüfung des Modells an Testdatensätzen anderer Stationen jedoch verzichtet werden, da keine repräsentativen und aussagekräftigen Ergebnisse zu erwarten waren.

Aufgrund keines einzigen Auftrittsfalles im Winter 2019/20 konnte zu diesem Trainingsdatensatz folglich auch keine Modellerstellung in Angriff genommen werden.

Modell 3: Mosesgipfel

Trainingsdaten:		
Station:	Mosesgipfel Schneestation und Mosesgipfel Windstation	
Seehöhe:	2235m und 2550m	
Subregion:	Östliche Deferegger Alpen (AT-07-27)	
Exposition:	SO	

Tabelle 7: Trainingsdaten gm.1, Modell 3: Mosesgipfel

Aufgrund der räumlichen Nähe zum Stationsstandort St. Veit und der auffällig hohen Auftrittszahlen von gm.1 im Winter 2018/19, in der Subregion Östliche Deferegger Alpen 50 Tage, sollte auch mithilfe dieses Trainingsdatensatzes eine Ursache dafür in den meteorologischen Daten aufgedeckt werden. Unter Begutachtung der im Zuge der Modellerstellung identifizierten Kennwerte zur Modellgüte (Anhang 2.3) muss jedoch auch dieser Versuch als gescheitert angesehen werden. 6 von 50 True Positive-Fällen entspricht einem Recall von 12%, was den hohen TNR-Wert ebenso wie bei Modell 2 nebensächlich erscheinen lässt. Eine weitere Untersuchung beziehungsweise Auseinandersetzung mit den übrigen entscheidenden Werten ist in diesem Fall als hinfällig zu betrachten, da das Modell

augenscheinlich keine Zusammenhänge zwischen dem Auftreten von gm.1 und den zur Modellerstellung verwendeten Wetterparametern ausmachen konnte.

Der Trainingsdatensatz 2019/20 konnte aufgrund von fehlenden Auftritten des Gefahrenmusters nicht untersucht werden.

Fazit

Aufgrund der geringen Auftrittszahlen in den Daten von 2019/20 konnte die Modellerstellung an den ausgewählten Stationen von diesem Jahr nicht durchgeführt werden, da die fehlenden Auftritte eine Prognose schlicht unmöglich machten. Daher wurden, anders als bei den anderen analysierten Gefahrenmustern bei denen jeweils Modelle zu beiden Jahren erstellt werden konnte, lediglich anhand der Trainingsdaten der Wintersaison 2018/19 Modelle für die Prognose des Gefahrenmusters erstellt.

Doch auch mit den Daten aus 2018/19 lieferte das Modell des Stationsstandortes Tuxerjoch nicht die gewünschten Ergebnisse. Auf Basis der 15 Tage, an denen in der betreffenden Subregion Westliche Tuxer Alpen im Winter 2018/19 gm.1 ausgerufen wurde, konnte das Modell das Auftreten des Gefahrenmusters nicht prognostizieren, da der Stichprobenumfang anscheinend nicht ausreichend war, um Gemeinsamkeiten und damit Begründungen für das Auftreten in den Wetterdaten auszumachen. Eine Überprüfung der Modellgüte anhand der Testdaten aus den Jahren 2018/19 und 2019/20, in denen die Gefahrenmuster ja erstmals subregional und damit wesentlich stärker an die vorherrschenden Wetterbedingungen gekoppelt ausgerufen wurden, scheiterte daran, dass die absoluten Auftrittszahlen des Gefahrenmusters in diesen beiden Jahren mit Ausnahme der beiden Stationen in Osttirol sehr niedrig waren. Doch auch bei den akkumulierten Daten der Jahre 2010-2018, in denen die Gefahrenmuster zwar noch für ganz Tirol und damit nicht auf die regional vorherrschenden Bedingungen abgestimmt ausgerufen wurden, konnte das erstellte Modell trotz des deutlich größeren Probenumfangs der Testdaten keine akkurate Prognose durchführen.

Ein ähnliches Bild ergab sich bei der Modellerstellung der Stationsstandorte St. Veit und Mosesgipfel. Trotz hoher Auftrittszahlen in der Saison 2018/19 an den beiden Stationen in Osttirol (50 bzw. 57 Tage), konnte auch dort keine erfolgreiche Prognose durchgeführt werden, da das Modell nur 5 bzw. 6 Tage ausmachen konnte, an denen das Gefahrenmuster tatsächlich auftrat. Diese geringe Genauigkeit machte eine Überprüfung der Modelle anhand von Testdaten hinfällig, da sich die Modelle für die Prognose und Analyse als ungeeignet herausstellten.

Einen möglichen Grund für die schlechten Prognoseergebnisse von Modell 1: Tuxerjoch könnte neben den geringen Auftrittszahlen jedoch ebenso der komplexe Prozess darstellen, der zu gm.1 führt. Für das Auftreten des Gefahrenmusters ist neben dem überlagernden Triebsschnee, der seinerseits aus den kurzfristigen Wetterdaten in Form von Niederschlag oder Windeinfluss hervorgehen kann, auch die darunterliegende, dem Gefahrenmuster namengebende Schwachschicht verantwortlich, die ihrerseits jedoch nicht aus den unmittelbaren meteorologischen Messwerten abgeleitet werden kann, sondern sich über einen längeren Zeitraum einer stabilen Hochdruckwetterlage durch die aufbauende Metamorphose bildet. (vgl. Kapitel 5.2.2) Weiters ist auch hier zu erwähnen, dass die Bereiche, in denen Gefahrenmuster 1 auftritt, räumlich stark begrenzt sind und an den jeweiligen Stationsstandorten möglicherweise gar nicht die Bedingungen vorherrschen, bei denen gm.1 ein Problem darstellt, obwohl es in der Subregion und den entsprechenden Gefahrenbereichen durchaus als Gefahr angesehen werden kann. (vgl. MAIR und NAIRZ 2010: 34)

Es ist festzuhalten, dass die Prognose von gm.1 anhand der verwendeten meteorologischen Parameter nicht bewerkstelligt werden konnte.

Das deckt sich auch mit den Aussagen aus dem Interview mit Patrick Nairz, Leiter des LWD Tirol (Anhang 1.2), der darauf verweist, dass bei langfristigen Entwicklungen, wie einer bodennahen Schwachschicht vom Frühwinter, die unmittelbaren Wetterstationswerte nicht unbedingt eine Rolle in der Entscheidungsfindung für die Aufnahme im Lawinenlagebericht spielen.

8.2. Gefahrenmuster 2: Gleitschnee

„Gleitschneelawinen zählen hinsichtlich des Abgangszeitpunktes zu den am schwierigsten vorhersagbaren Lawinen, weil diese auch bei allgemein stabilen Schneeeverhältnissen zu jeder Tages- und Nachtzeit, sowohl am kältesten als auch am wärmsten Tag eines Winters abgehen können“ (MAIR und NAIRZ 2010: 45).

Aufgrund dieser Tatsache erscheint es verwunderlich, dass gm.2 Gleitschnee für die Analyse ausgewählt wurde, dabei macht es genau diese Unberechenbarkeit interessant, herauszufinden, inwiefern sich zwar nicht der Zeitpunkt des Lawinenabganges, sondern das Auftreten des Gefahrenmusters doch anhand meteorologischer Parameter erklären und prognostizieren lässt.

Die Gefahrenbereiche, an denen gm.2 am ehesten zu erwarten ist, ließen aufgrund ihrer großen Streuung über fast alle Höhenlagen und Expositionen (lediglich im hochalpinen Nordsektor über 2500m Seehöhe ist ein Auftreten von gm.2 sehr unwahrscheinlich) keine Eingrenzung der Stationsauswahl zur Modellerstellung zu. Für die Modellerstellung wurden daher zwei Stationen ausgewählt, die sich sowohl in ihrer Lage, Exposition als auch Höhenlage möglichst unähnlich sind, um festzustellen, inwiefern diese Standortfaktoren die Modellgüte beeinflussen. Infolgedessen wurden anhand der Trainingsdaten aus den Wintersaisons 2018/19 und 2019/20 von den Stationsstandorten Mosesgipfel und Salzboden Modelle erstellt, da sich diese beiden Stationen nicht nur durch den geographischen Lageunterschied zwischen den Östlichen Deferegger Alpen in Osttirol und der Westlichen Verwallgruppe im Westen Nordtirols, sondern auch in ihrer Exposition und Höhenlage signifikant voneinander unterscheiden, während an beiden Standorten hohe Auftrittszahlen von gm.2 in den Datensätzen lokalisiert werden konnten. Im Folgenden werden die Ergebnisse der Modellerstellung detailliert vorgestellt und diskutiert.

Die Modellerstellung wurde auf Basis der Trainingsdatensätze der ausgewählten Stationen mit den Messwerten der Wintersaisons 2018/19 bzw. 2019/20 zu den meteorologischen Parametern Schneehöhe, relative Luftfeuchte, Lufttemperatur, Windgeschwindigkeit, Globalstrahlung sowie eintägiger Differenz der Lufttemperatur durchgeführt.

Modell 1: Mosesgipfel

Trainingsdaten:		
Station:	Mosesgipfel Schneestation und Mosesgipfel Windstation	
Seehöhe:	2235m und 2550m	
Subregion:	Östliche Deferegger Alpen (AT-07-27)	
Exposition:	SO	

Tabelle 8: Trainingsdaten gm.2, Modell 1: Mosesgipfel

In einem ersten Schritt der Modellerstellung wurden abermals die absoluten Auftrittszahlen des zu untersuchenden Gefahrenmusters begutachtet, die bei gm.2 in der Subregion Östliche Deferegger Alpen bei 46 (2018/19) beziehungsweise 65 (2019/20) Tagen lagen. Damit konnte, anders als bei gm.1, für beide Trainingsdatensätze die Modellerstellung durchgeführt werden.

Die Ergebnisse fielen in beiden Jahren mit einer Accuracy um den Grenzwert von 70% deutlich vielversprechender aus, als es bei den Modellen zu gm.1 der Fall war. Detaillierte Ergebnisse zur Modellerstellung sind in Anhang 2.4 in tabellarischer Anordnung zu finden.

Im Trainingsdatensatz 2018/19 wurde mit einer Accuracy von 71.8% zwar der Grenzwert erreicht, die True Positive Rate fiel mit 32.6% und lediglich 15 von 46 identifizierten Auftritten jedoch gering aus. Mit den Daten aus dem Winter 2019/20 wurde eine Accuracy von 69.2% und damit knapp unterhalb des Grenzwertes erzielt, aufgrund der deutlich höheren True Positive Rate von 63% im Vergleich zum anderen Modell, wurden jedoch beide Modelle an den Daten anderer Stationen getestet.

Dabei fiel auf, dass die Modelle zu einer Prognose der Auftrittsfälle von gm.2 nur bedingt geeignet sind. In den meisten Fällen konnte mit keinem der beiden Trainingsdatensätze eine akkurate Prognose angestellt werden, einzige Ausnahme stellte dabei das Modell mit den Trainingsdaten aus dem Winter 2018/19 dar, das anhand der Testdaten aus dem Jahr 2018/19 bei fünf der sechs überprüften Stationen eine Genauigkeit von über 70% aufweisen konnte. Auffallend war dabei auch, dass bei den meisten Fällen eine True Positive Rate von über 85% erzielt werden konnte. Der einzige Stationsstandort, an dem die TPR deutlich geringer ausfiel, war mit St. Veit überraschenderweise jener, der der zur Modellerstellung verwendeten Station Mosesgipfel geographisch am nächsten liegt.

In Hinblick auf die anderen Testdaten muss jedoch als Fazit festgehalten werden, dass die beiden Modelle nicht ausreichende Zusammenhänge aufdecken konnten, um gm.2 akkurat zu prognostizieren.

Modell 2: Rendl Riffel 1 und Salzboden

Trainingsdaten:		
Station:	Rendl Riffel 1 und Salzboden	
Seehöhe:	1895m und 1985m	
Subregion:	Westliche Verwallgruppe (AT-07-10)	
Exposition:	N	

Tabelle 9: Trainingsdaten gm.2, Modell 2: Rendl Riffel 1 und Salzboden

In der Subregion Westliche Verwallgruppe wurden im Jahr 2018/19 118 Auftrittstage von gm.2 verzeichnet, während im Folgejahr mit 66 Tagen ebenfalls eine große Anzahl als Grundlage für die Datenanalyse zur Verfügung stand.

In Anhang 2.5 finden sich die Tabellen zur Modellerstellung der Trainingsdatensätzen beider Jahre, mit denen jeweils eine gute Genauigkeit von über 70% erreicht werden konnte. Mit dem Datensatz aus 2018/19 lag die Accuracy gar bei 83.7%, bedingt durch die richtige Prognose von 117 der 118 Auftritte von gm.2. Zwar unterscheiden sich die Modelle der beiden Trainingsdatensätze insofern stark, dass 2018/19 die hohe Genauigkeit auf die angesprochene hohe TPR zurückzuführen ist, während die TNR bei nur 20.7% lag und beim Modell mit den Daten von 2019/20 der Effekt mit einer niedrigen TPR von 55.1% und einer hohen TNR von 85.7% umgekehrt festgestellt werden konnte. Aufgrund der hohen Werte von Accuracy und Precision, die jeweils über dem Grenzwert von 70% lagen, erschienen allerdings beide Modelle für eine Überprüfung anhand der anderen Wetterstationsdaten als geeignet.

Leider konnten die vielversprechenden Voraussetzungen diese Überprüfung jedoch nicht bestehen, da mit beiden Modellen nur an drei der überprüften 35 Testdatensätze eine Prognosegenauigkeit von über 70% erreicht werden konnte. Alle drei Fälle sind dabei, wie bereits ähnlich bei Modell 1: Mosesgipfel festgestellt, mit dem Modell der Trainingsdaten 2018/19 und der Überprüfung anhand Testdatensätzen desselben Jahres aufgetreten. Dieses Modell fiel, wie bereits bei der Erstellung zu erahnen war, trotz sehr hoher TPR einer sehr niedrigen TNR zum Opfer, wodurch die angestrebte Genauigkeit im Großen und Ganzen nicht erreicht werden konnte. Sämtliche andere Kombinationen zwischen Modellen und Testdatensätzen führen zur Schlussfolgerung, dass eine Prognose von gm.2 anhand der verwendeten Parameter am Standort Rendl Riffel 1 und Salzboden nicht durchführbar erscheint.

Fazit

Wie aus dem Interview mit Patrick Nairz (Anhang 1.2) hervorging, spielen Wetterstationsdaten bei gm.2 eine sehr große Rolle, vor allem wenn man sich mit warmen Gleitschneelawinen beschäftigt. In Hinblick auf die fortschreitende Durchfeuchtung und damit abnehmende Stabilität der Schneedecke sind die Stationsdaten speziell bei frühem Einschneien mit massiven Schneefällen auf eine warme Bodenoberfläche ein wichtiger Faktor in der Entscheidungsfindung. Zwar wird heutzutage unterstützend mit Schneedeckensimulationsmodellen gearbeitet, um die Prozesse innerhalb der Schneedecke besser verstehen zu können und auch die Feldarbeit und der damit einhergehende Gewinn von Erkenntnissen durch Schneedeckenuntersuchungen finden in der Entscheidungsfindung zum Ausrufen von gm.2 Beachtung, trotzdem liegt der Fokus hierbei auch stark auf der Beobachtung

der meteorologischen Stationswerte. Ob die Wetterdaten alleinstehend jedoch für eine Prognose des Gefahrenmusters ausreichen, galt es herauszufinden.

An beiden Standorten liegt, anders als beim zuvor analysierten gm.1 eine große Anzahl an Auftritten des Gefahrenmusters im Untersuchungszeitraum vor, was sich auch in der Modellgüte insofern widerspiegelte, dass beide Modelle für eine Analyse anhand der Testdaten geeignet erschienen. Allerdings musste auch hier festgestellt werden, dass die Modelle eine Prognose für das Auftreten des Gefahrenmusters nicht ausreichend bewerkstelligen konnten, wie die Auswertungen in Tabelle 10 unterstreichen.

Modell	Trainingsdaten	Testdaten	>70%	<70%
Mosesgipfel	2018/19	2010-2018	0	6
		2018/19	5	1
		2019/20	0	6
	2019/20	2010-2018	1	5
		2018/19	2	5
		2019/20	0	5
Rendl Riffel 1 & Salzboden	2018/19	2010-2018	0	5
		2018/19	3	3
		2019/20	0	6
	2019/20	2010-2018	0	6
		2018/19	0	7
		2019/20	0	5

Tabelle 10: Auswertungen der Prognosegenauigkeit der Modelle zu gm.2

Die einzige Ausnahme stellen die Modelle mit den Trainingsdaten aus der Wintersaison 2018/19 dar, die bei den Testdaten aus derselben Saison bei 5 bzw. 3 von 6 Datensätzen ein Auftreten von gm.2 mit einer Genauigkeit von über 70% prognostizieren konnten. Insbesondere aufgrund der Tatsache, dass diese Modelle ansonsten jeweils keinen anderen Datensatz akkurat prognostizieren konnten, ist dies jedoch als Ausreißer zu betrachten und lässt keinen Schluss darauf zu, dass eine Prognose von gm.2 allein mit Wetterstationsdaten möglich ist. Ebenso ist zu erwähnen, dass in dieser Wintersaison besonders oft gm.2 ausgerufen wurde. So wurde beispielsweise in den Subregionen Westliche Verwallgruppe, Samnaungruppe und Karwendel an über 113 Tagen gm.2 im Lawinenlagebericht erwähnt. Demgegenüber stehen lediglich jeweils unter 35 Tage, an denen das Gefahrenmuster nicht ausgerufen wurde, was möglicherweise ansatzweise erklärt, warum die Prognosen lediglich für die Datensätze aus diesem Jahr akkurat ausfielen, da auch die Modelle eine sehr hohe True Positive Rate aufwiesen, was sich später bei der Überprüfung der Testdatensätze bestätigte.

Bei den anderen Datensätzen lag überwiegend das Problem vor, dass für zu viele Tage an denen gm.2 nicht ausgerufen wurde, von den Modellen ein Auftreten prognostiziert wurde, was sich in einer niedrigen True Negative Rate widerspiegelte und die Genauigkeit der Modelle deshalb deutlich geringer und unterhalb des Grenzwertes ausfallen ließ.

Es hat den Anschein, dass trotz hoher Auftrittszahlen an den meisten Stationen, die Prozesse, die zu gm.2 führen, nicht anhand kurzfristiger Wetterparameter erklärbar sind und die eingangs angesprochenen Prozesse innerhalb der Schneedecke für eine akkurate Prognose jedenfalls zu berücksichtigen sind.

Ein Problem, die Gleitschneeproblematik mit kurzfristigen Wetterparametern erklären zu wollen, stellt die Charakteristik des Gefahrenmusters dar. In schneereichen Wintern kann man theoretisch im ganzen Winter von einem Gleitschneeproblem sprechen, weshalb die Auftrittszahlen besonders in den Jahren vor dem Zusammenschluss der Lawinenwarndienste zum neuen Lawinenreport für Tirol, Südtirol und Trentino im Jahr 2018, besonders hoch waren. Inzwischen hat man das auch innerhalb der Lawinenwarndienste so kommuniziert, dass gm.2 nur mehr dann ausgegeben wird, wenn wirklich eine massivere Gleitschneeaktivität beobachtet wird, um den Fokus darauf zu richten und zu verhindern, dass das Gefahrenmuster durch zu lange Erwähnung im Lagebericht weniger stark wahrgenommen wird. (vgl. Anhang 1.2)

Daher ist zu dem Schluss zu kommen, dass nicht nur der Abgangszeitpunkt von Gleitschneelawinen weitgehend unvorhersehbar ist, sondern auch die Prognose eines Auftretens von gm.2 Gleitschnee lediglich mit meteorologischen Messwerten in dieser Art und Weise nicht zu bewerkstelligen ist.

8.3. Gefahrenmuster 6: Lockerer Schnee und Wind

Aufgrund der Tatsache, dass dieses Gefahrenmuster in allen Expositionen und Höhenlagen eine Gefahr darstellen kann und der Gefahrenbereich nicht wie bei anderen Gefahrenmustern auf eine bestimmte Exposition oder Höhenlage eingegrenzt werden kann, wurde versucht, durch die Auswahl der Testdatensätze ein möglichst breites Spektrum abzubilden und aufgrund verschiedener Bedingungen an den Stationsstandorten möglichst viele Situationen einfließen zu lassen, unter denen gm.6 auftritt. Für die Modellerstellung zur Prognose von gm.6 wurden in der Folge die meteorologischen Daten der Stationen Tuxerjoch, St. Veit sowie Rendl Riffel 1 & Salzboden ausgewählt, da neben der räumlichen Ausdehnung über den gesamten Untersuchungsraum Tirol - die Station Rendl Riffel 1 & Salzboden liegt im äußersten Westen des Bundeslandes, die Station Tuxerjoch ist relativ zentral in Nordtirol gelegen und der Stationsstandort St. Veit liegt in Osttirol – mit dieser Auswahl auch hinsichtlich Exposition und Höhenlage unterschiedliche Bereiche abgedeckt werden. Durch diese Auswahl wird eine repräsentative Analyse der Einflussparameter angestrebt, anhand derer eine Auftrittsprognose von gm.6 gelingen soll. Die Ergebnisse der Datenanalyse werden im folgenden Kapitel vorgestellt.

Die Modellerstellung wurde auf Basis der Trainingsdatensätze der ausgewählten Stationen mit den Messwerten der Wintersaisons 2018/19 bzw. 2019/20 zu den meteorologischen Parametern Schneehöhe, relative Luftfeuchte, Lufttemperatur, Windgeschwindigkeit sowie eintägiger Differenz der Lufttemperatur durchgeführt.

Modell 1: Tuxerjoch

Trainingsdaten:		
Station:	Tuxerjoch Schneestation und Tuxerjoch Windstation	
Seehöhe:	2380m und 2518m	
Subregion:	Westliche Tuxer Alpen (AT-07-15)	
Exposition:	NO	

Tabelle 11: Trainingsdaten gm.6, Modell 1: Tuxerjoch

Den ersten Schritt der Modellerstellung stellte, wie in den anderen Fällen, die Begutachtung der absoluten Auftrittszahlen in den Trainingsdatensätzen dar. In den, für die Modellerstellung relevanten Jahren wurde gm.6 an 100 beziehungsweise 129 Tagen im Lawinenlagebericht erwähnt. Ziel der Datenanalyse war es, abermals Zusammenhänge zwischen dem Auftreten des Gefahrenmusters und der berücksichtigten Wetterparameter aufzudecken.

Eine erste Analyse der Modellgüte fiel mit einer Genauigkeit von über 80% bei beiden Modellen vielversprechend aus. Sowohl beim Modell mit dem Trainingsdatensatz des Winters 2018/19 als jenem des Winters 2019/20 war besonders der Recall-Wert und damit die True Positive Rate mit rund 90% jene Kennzahl, die das beste Ergebnis wiedergab und so 89 von 100 beziehungsweise 108 von 116 Auftritten des Gefahrenmusters richtig prognostizieren konnte. Dass das Modell der Saison 2019/20 hier insgesamt nur 116 von 129 Auftritten von gm.6 bewerten konnte, ist auf Datenlücken zurückzuführen, die in Kapitel 7.4.2 näher beschrieben wurden. Als einflussreichste Parameter stellten sich im Zuge der Modellerstellung die Lufttemperatur, sowie deren eintägige Differenz und die Windgeschwindigkeit heraus. Mit Verweis auf die hohen Ausprägungen von Precision und F-Score mit jeweils über 84% erscheinen beide Modelle für eine Überprüfung anhand der restlichen Stationsdaten gut geeignet.

In 24 der überprüften 36 Testdatensätze (vgl. Anhang 2.6) konnten die beiden Modelle dabei ein Auftreten von gm.6 mit einer Genauigkeit von mindestens 70% anhand der meteorologischen Parameter vorhersagen. Das lässt die Annahme zu, dass die Bedeutung der Wetterdaten im Fall von Gefahrenmuster 6 als signifikant angesehen werden kann, was in der Folge anhand weiterer Modelle überprüft werden soll.

Modell 2: St. Veit

Trainingsdaten:		
Station:	St. Veit Zischke und St. Veit Speikboden	
Seehöhe:	2115m und 2630m	
Subregion:	Östliche Rieserfernergruppe (AT-07-25)	
Exposition:	S	

Tabelle 12: Trainingsdaten gm.6, Modell 2: St. Veit

Mit ähnlichen absoluten Auftrittszahlen wie an der für Modell 1 herangezogenen Station Tuxerjoch, wo 100 beziehungsweise 126 Auftrittstage von gm.6 verzeichnet wurden, sollte mit den Trainingsdaten der Station St. Veit ein vergleichbares Ergebnis erzielt werden. In der Subregion Östliche Rieserfernergruppe wurden im Untersuchungszeitraum 2018/19 an 97 Tagen, sowie 2019/20 an 123 Tagen auf die Gefahr eines Lawinenabganges in Verbindung mit gm.6 verwiesen.

Die beiden erstellten Modelle konnten davon 74 beziehungsweise 118 richtigerweise als solche prognostizieren, was sich in einer Genauigkeit von 75.8% beziehungsweise 89.8% niederschlug. Die, in Anhang 2.7 festgehaltenen Modellergebnisse zeigten, dass besonders das Modell der Trainingsdaten von 2019/20 mit Werten jenseits der 90% sowohl bei Recall, Precision als auch F-Score besonders akkurate Ergebnisse lieferte. Die Auswertungen des Trainingsdatensatzes 2018/19 fielen dagegen etwas niedriger, dabei jedoch immer noch deutlich über dem angestrebten Grenzwert von 70%, aus, was wiederum beide Modelle für weitere Analysen geeignet kennzeichnete. Lediglich die True Negative Rate wurde in beiden Fällen mit rund 63% als nicht geeignet eingeschätzt, dessen Folgen anhand der Testdaten überprüft werden sollten.

Die Ergebnisse der angesprochenen Überprüfung fielen trotz vielversprechender Ausgangslage mit nur 16 von 39 Fällen, in denen ein Auftreten von gm.6 ausreichend prognostiziert wurde, ernüchternd aus. Das Modell 2018/19 wies durchwegs eine zu hohe False Positive Rate auf, um die gewünschte Genauigkeit gewährleisten zu können, während bei Modell 2019/20 auffällig war, dass besonders bei Testdaten aus der Saison 2018/19 die Ergebnisse mit einer hohen False Negative Rate verschlechtert wurden. Abgesehen davon konnten mithilfe des Modells 2019/20 aber 9 von 13 Überprüfungen eine Accuracy von über 70% aufweisen, was wiederum dafür spricht, dass ein Zusammenhang zwischen den Wetterfaktoren und dem Gefahrenmuster zumindest in diesen Fällen statistisch nachgewiesen werden konnte.

Modell 3: Rendl Riffel 1 und Salzboden

Trainingsdaten:		
Station:	Rendl Riffel 1 und Salzboden	
Seehöhe:	1895m und 1985m	
Subregion:	Westliche Verwallgruppe (AT-07-10)	
Exposition:	N	

Tabelle 13: Trainingsdaten gm.6, Modell 3: Rendl Riffel 1 und Salzboden

Trotz der großen räumlichen Differenz zwischen dem Stationsstandort Rendl Riffel 1 und den beiden anderen zur Erstellung der Modelle herangezogenen Standorte wurden auch hier sehr ähnliche Auftrittszahlen verzeichnet, was Rückschlüsse darauf ziehen lässt, dass gm.6 in den untersuchten Wintersaisons bundeslandweit über einen großen Zeitraum eine Bedrohung für die Lawinensituation darstellte. Exakt lagen die Auftritte 2018/19 an diesem Standort bei 103 und 2019/20 bei 128.

Die Modellerstellung konnte dem, von Modell 1 und Modell 2 bekannten Muster folgen und wies bei sämtlichen entscheidenden Größen, bis auf die True Negative Rate eine ausreichende bis gute Genauigkeit auf. Abermals konnte das Modell des Trainingsdatensatzes 2019/20 im Vergleich leicht bessere Werte aufweisen und lag sowohl bei Accuracy, Recall, Precision als auch F-Score jenseits der 90%-Hürde. Beide Modelle wurden folgerichtig für eine Analyse als geeignet empfunden.

Die ausführlichen Auswertungen sind in Anhang 2.8 zu finden und bei einer Betrachtung dieser tabellarischen Ausführungen fällt auf, dass in 30 von 38 überprüften Fällen eine Prognosegenauigkeit von 70% erfüllt werden konnte. Dieses sehr gute Ergebnis wird von dem Fakt unterstrichen, dass bei einer Anpassung auf mindestens 68% Accuracy bereits 35 der 38 Fälle eine Prognose von gm.6 ermöglichen. Allerdings ist auch dieses Ergebnis mit Vorsicht zu genießen, da eine sehr niedrige True Negative Rate bei sämtlichen Untersuchungen zu beobachten ist. Nichtsdestotrotz lässt dieses Analyseergebnis Vermutungen zu, dass statistische Zusammenhänge zwischen dem Auftreten von gm.6 und den meteorologischen Einflussparametern mithilfe dieses Modells aufgedeckt werden konnten.

Fazit

Bei der Erstellung der Modelle fiel schnell auf, dass sie eine deutlich höhere Genauigkeit aufwiesen, als es bei den zuvor behandelten Gefahrenmustern gm.1 und gm.2 der Fall war. Sowohl bei den beiden Modellen mit den Wetterdaten vom Tuxerjoch (Modell 1) als auch bei jenen vom Standort Rendl Riffel 1 & Salzboden (Modell 3) lag die Genauigkeit bei jeweils über 80%, was sie für die weitere Analyse als sehr gut geeignet erscheinen ließen. Bei der Wetterstation St. Veit (Modell 2), die sich von den anderen beiden nicht nur durch ihre abgelegene Lage im Defereggental in Osttirol sondern auch durch die südliche Exposition am Stationsstandort unterscheidet, erwiesen sich die Trainingsdaten als gut geeignet für die weitere Analyse. Das Modell der Saison 2019/20 ergab ebenso wie jene vom Tuxerjoch und Salzboden eine Genauigkeit von über 80%, während sich das Modell mit den meteorologischen Daten der Saison 2018/19 mit einer Accuracy von knapp 76% und damit deutlich über dem Grenzwert von 70%, ab dem ein Modell als gut geeignet eingestuft wird, für eine Analyse geeignet herausstellte.

Einen weiteren Unterschied zu den zuvor analysierten Gefahrenmustern stellten auch die absoluten Auftrittszahlen von gm.6 im Untersuchungszeitraum dar, da diese deutlich höher vorzufinden waren. Die hohen Auftrittszahlen von gm.6 erleichtern eine Prognose, da über einen größeren Zeitraum Gemeinsamkeiten in den Daten untersucht werden können.

Dass gm.6 jedoch so oft in den Lawinenlageberichten erwähnt wurde ist aufgrund der Charakteristik des Gefahrenmusters etwas verwunderlich, da lockerer Schnee und Wind oder das Tribschneeproblem als solches ja eigentlich als kurzfristiges Problem anzusehen ist. Laut Patrick Nairz sollte gm.6 nur 2 bis 3 Tage anhalten, im Zweifel oder bei Bestehenbleiben des Gefahrenmusters in großen Höhen, wird es jedoch trotzdem im Lagebericht erwähnt. Als weiteren Grund für das häufige Auftreten nennt er den Fall von durchaus günstigen Lawinenbedingungen und Windaktivität in hochalpinen Bereichen, da das oft dazu verleitet, gm.6 auszurufen, da es das Gefahrenmuster ist, auf das am Ehesten aufzupassen ist, weshalb gm.6 durchaus überrepräsentiert sein kann. (vgl. Anhang 1.2)

Nichtsdestotrotz konnten die Modelle eine hohe Genauigkeit aufweisen, weshalb die Überprüfung anhand der Testdaten in Angriff genommen wurde. Anders als bei den zuvor durchgeführten Untersuchungen zu gm.1 und gm.2, konnten hier auch beachtliche Erfolge in der Prognose des Gefahrenmusters verzeichnet werden, wie in Tabelle 12 zu erkennen ist.

Modell	Trainingsdaten	Testdaten	>70%	<70%
Tuxerjoch	2018/19	2010-2018	2	4
		2018/19	4	2
		2019/20	6	1
	2019/20	2010-2018	5	1
		2018/19	1	6
		2019/20	6	0
St. Veit	2018/19	2010-2018	1	5
		2018/19	3	3
		2019/20	2	5
	2019/20	2010-2018	5	1
		2018/19	1	6
		2019/20	4	3
Rendl Riffel 1 & Salzboden	2018/19	2010-2018	4	2
		2018/19	6	0
		2019/20	7	0
	2019/20	2010-2018	3	3
		2018/19	5	2
		2019/20	5	1

Tabelle 14: Auswertungen der Prognosegenauigkeit der Modelle zu gm.6

Die Modelle 1 & 3 konnten, wie in Tabelle 14 ersichtlich, in 54 von 76 überprüften Datensätzen eine Genauigkeit von über 70% bei der Prognose des Auftretens von gm.6 aufweisen, während das Modell 2 in den Testdaten nur in 16 von 38 Fällen die gewünschte Genauigkeit liefern konnte. Als akkuratestes Modell stellte sich das Modell 3: Rendl Riffel 1 & Salzboden mit dem Trainingsdatensatz aus der Saison 2018/19 heraus, das von 19 überprüften Stationsdaten nur bei zwei Testdatensätzen aus den Jahren 2010-2018 eine ungenaue Prognose ausgab, wobei die Genauigkeit in diesen beiden Fällen einmal über 69% und damit sehr knapp an dem Grenzwert lag. Ähnlich war es in zwei weiteren Fällen bei der Überprüfung von Modell 3 aus der Saison 2019/20, womit von den überprüften Datensätzen bei 33 von 38 Fällen eine akkurate Prognose mit einer Genauigkeit von über 69% aufgestellt werden konnte. Ebenso wurden bei den beiden Modellen mit den Trainingsdatensätzen vom Tuxerjoch vier Fälle ausgemacht, in denen die Genauigkeit mit über 69% nur denkbar knapp unter dem Grenzwert lag, womit die Prognose hier in 28 von 38 Fällen als akkurat angesehen werden kann und die Modelle 1 & 3 zusammen in über 80% der überprüften Testdatensätze eine gute Prognose von gm.6 ermöglichten.

Als Ausnahme sind hier jedoch die beiden Modelle mit den Trainingsdaten von der Station St. Veit anzuführen, da die Ergebnisse nur in 16 von 38 Fällen positiv ausfielen. Als Grund für die vergleichsweise niedrige Erfolgsquote der Analyse können mehrere Aspekte herangezogen werden, die eine Prognose erschweren. Einerseits führt die südseitige Exposition am Stationsstandort zu anderen meteorologischen Bedingungen als es bei nordseitig ausgerichteten Standorten der Fall ist. Das Auftreten vom gm.6 ist hier somit an unterschiedliche Ausprägungen der Wetterparameter geknüpft und kann aus diesem Grund zu Komplikationen bei der Prognose an anderen Standorten führen, da die Bedingungen, die am Standort St.Veit mit dem gm.6 in Verbindung stehen andernorts nicht zu einem Auftreten von gm.6 führen müssen. Andererseits ist auch die Lage der Station in Osttirol erwähnenswert, da hier andere Großwetterlagen Einfluss haben und vor allem schneebringende Kaltluftfronten oftmals auch von Süden Einzug halten, was in Nordtirol hingegen äußerst unwahrscheinlich ist. Die Kombination aus den angeführten Gründen kann ausschlaggebend dafür sein, dass dieses Modell im Gegensatz zu den beiden Modellen von Tuxerjoch und Salzboden keine akkuraten Prognoseergebnisse liefern kann.

Zusammenfassend ist dennoch festzuhalten, dass eine Prognose der Auftrittstage von gm.6 anhand meteorologischer Messwerte durchaus im Bereich des Möglichen liegt, was auf statistische Zusammenhänge in den Datensätzen hinweist und dem Einfluss des Wetters bei der Beurteilung von gm.6 eine tragende Rolle zukommen lässt.

8.4. Gefahrenmuster 10: Frühjahrssituation

Die Brisanz von Gefahrenmuster 10 liegt vor allem darin, dass sich die Lage innerhalb kürzester Zeit und auch in einem Abstand von wenigen Stunden von einer sicheren, generell lawinengünstigen Situation zu einer akut gefährlichen Situation mit hoher Lawinenaktivität ändern kann. Der Einfluss von meteorologischen Parametern ist dabei wesentlich, da die zunehmende Lawinengefahr fast immer mit einer zunehmenden Durchnässung der Schneedecke zusammenhängt und diese direkt von Lufttemperatur, relativer Luftfeuchte und Globalstrahlung ausgelöst wird. Besonders die Globalstrahlung wird im Frühjahr immer wichtiger, da sich mit steigenden W/m^2 in Kombination mit anderen Sachen oft ein Nassschneezyklus anbahnt. (vgl. Anhang 1.2)

Daher wurde bei der Modellerstellung zur Prognose von gm.10 neben den, bei den anderen Gefahrenmustern verwendeten Parametern Lufttemperatur, relativer Luftfeuchte, Schneehöhe, Windgeschwindigkeit und eintägigen Differenz der Lufttemperatur auch der Faktor der Globalstrahlung berücksichtigt, um möglichst genaue Auswertungen zu erhalten.

Da gm.10 in zwei verschiedenen Phasen auftritt und dabei unterschiedliche Gefahrenbereiche betroffen sind (siehe Abb. 34), wurde versucht, bei der Auswahl der Standorte zur Modellerstellung diese Bandbreite abzudecken. Die erste Phase, die meist in den Monaten Februar und März auftritt, betrifft vorwiegend Bereiche im südseitig exponierten Gelände in allen Höhenstufen, weshalb der Stationsstandort St. Veit zur Modellerstellung gewählt wurde. Bei der zweiten Phase, die später im Frühjahr in den Monaten April und Mai akut wird, sind hauptsächlich Bereiche im hochalpinen und nordseitigen Expositionssektor betroffen, weshalb die Auswahl hierfür auf den Standort Rendl Riffel 1 & Salzboden fiel.

Die Modellerstellung wurde auf Basis der Trainingsdatensätze der ausgewählten Stationen mit den Messwerten der Wintersaisons 2018/19 bzw. 2019/20 zu den meteorologischen Parametern Schneehöhe, relative Luftfeuchte, Lufttemperatur, Windgeschwindigkeit, Globalstrahlung sowie eintägiger Differenz der Lufttemperatur durchgeführt.

Modell 1: Rendl Riffel 1 und Salzboden

Trainingsdaten:		
Station:	Rendl Riffel 1 und Salzboden	
Seehöhe:	1895m und 1985m	
Subregion:	Westliche Verwallgruppe (AT-07-10)	
Exposition:	N	

Tabelle 15: Trainingsdaten gm.10, Modell 1: Rendl Riffel 1 & Salzboden

Die Auftrittszahlen von gm.10 sind aufgrund der Einschränkung auf die Frühjahrsmonate deutlich geringer als es beispielsweise bei gm.6 der Fall ist, das über die gesamte Dauer einer Wintersaison auftreten kann. Mit 33 beziehungsweise 36 Tagen mit gm.10 sind die Untersuchungszeiträume dennoch für eine Analyse geeignet, da die Stichprobengröße ausreichend erscheint.

Die Modellerstellung, in Anhang 2.9 detailliert zu begutachten, wies eine hohe Genauigkeit von 90.5% mit dem Modell des Trainingsdatensatzes 2018/19 beziehungsweise 97.2% mit den Daten aus 2019/20 auf, wobei im Gegensatz zu den Modellen zu den anderen Gefahrenmustern erstmals alle Kenngrößen den Grenzwert von 70% erreichen konnten. Herausragend sind bei beiden Modellen die Werte zur True Negative Rate mit 93.9% beziehungsweise 98.3%, während auch die True Positive Rate mit 78.8% beziehungsweise 91.7% auf eine hohe Modellgüte hinweist.

Gesamt betrachtet prognostizierte das Modell mit den Daten aus dem Winter 2018/19 jeweils nur sieben Tage fälschlicherweise auf True und False, während das Modell der Daten 2019/20 an insgesamt vier Tagen jeweils nur zwei Tage in die falsche Kategorie einteilte. Bereits dieser erste Schritt der Modellerstellung lässt auf die Feststellung statistischer Zusammenhänge zwischen dem Auftreten von gm.10 und den meteorologischen Einflussparametern schließen, was in einem weiteren Schritt in der Überprüfung anhand der Testdatensätze der restlichen Stationen bestätigt werden konnte.

Die Ergebnisse weisen durchgehend eine Genauigkeit der Modelle in der Gefahrenmusterprognose von über 80% auf, wodurch die in der Modellerstellung angedeuteten Zusammenhänge nachgewiesen werden konnten. Sowohl in Hinblick auf TPR als auch TNR erweisen sich die beiden Modelle vom Standort Rendl Riffel 1 & Salzboden als äußerst akkurat, was in der Erstellung weiterer Modelle mit unterschiedlichen Trainingsdatensätzen näher überprüft werden sollte.

Modell 2: St. Veit

Trainingsdaten:		
Station:	St. Veit Zischke und St. Veit Speikboden	
Seehöhe:	2115m und 2630m	
Subregion:	Östliche Rieserfernergruppe (AT-07-25)	
Exposition:	S	

Tabelle 16: Trainingsdaten gm.10, Modell 2: St. Veit

Trotz großer räumlicher Differenz zum Standort Rendl Riffel 1 & Salzboden, dessen Daten zur Erstellung von Modell 1 herangezogen wurden, lagen die Auftrittszahlen im Untersuchungszeitraum auch in der Subregion Östliche Rieserfernergruppe mit 32 Tagen im Winter 2018/19 beziehungsweise 34 Tagen im Winter 2019/20 in einem vergleichbaren Rahmen.

Bei der Erstellung der Modelle konnten weitere Gemeinsamkeiten mit Modell 1 festgestellt werden, da abermals sämtliche Kennwerte die angestrebte Genauigkeit von 70% erfüllen konnten und wiederum die Accuracy mit 90.8% (2018/19) beziehungsweise 97.5% (2019/20) auf aufgedeckte Relationen zwischen den Einflussparametern hindeutete. Eine weitere Ähnlichkeit mit dem Modell 1 stellt die sehr hohe True Negative Rate von 94.5% beziehungsweise 98.4% dar und auch die True Positive Rate liegt mit 78.1% beziehungsweise 94.1% in einem ähnlichen Bereich wie bei Modell 1.

Bei der Überprüfung der Modellgüte an den Testdatensätzen galt es herauszufinden, ob das Modell die hohe Genauigkeit von Modell 1 ebenfalls duplizieren konnte und wiederum stellte sich heraus, dass das Modell 2 mit einer Ausnahme von lediglich zwei Testdatensätzen die Prognose der Auftritte von gm.10 mit einer Genauigkeit von über 80% bewerkstelligen konnte. Die beiden angesprochenen Ausnahmen fallen insofern nicht weiter ins Gewicht, da anhand dieser Testdatensätze die Prognosegenauigkeit mit über 70% immer noch im angestrebten Genauigkeitsbereich liegt und das Modell somit erneut eine akkurate Aussage zu den Auftritten von gm.10 liefern konnte.

Aufgrund dieser überaus hohen Genauigkeit beider Modelle, trotz großer räumlicher Differenz der Stationsstandorte wurde auf eine weitere Modellerstellung verzichtet, da anhand der durchgeführten Überprüfungen bereits ausreichende Erkenntnisgewinne gezogen werden konnten.

Fazit

An beiden Standorten wurde in den für die Modellerstellung relevanten Wintersaisons 2018/19 und 2019/20 jeweils an über 30 Tagen gm.10 ausgerufen, was sich bei den vier Modellen in Form einer Genauigkeit von über 90% auswirkte und in einem weiteren Schritt somit die Überprüfung anhand der Testdatensätze in Angriff genommen werden konnte. Besonders auffallend war die hohe Genauigkeit der Modelle mit den Trainingsdatensätzen der Saison 2019/20, die an beiden Standorten jeweils nur an vier Tagen falsche Prognosen lieferte. (vgl. Anhang 2.10)

Bei der Überprüfung der Modelle anhand der Testdatensätze der anderen Messstationen konnte dieses Bild der hohen Genauigkeit eindrucksvoll bestätigt werden, indem die Modelle bei keinem einzigen der Testdatensätze eine Prognose mit einer Genauigkeit unterhalb des Grenzwertes von 70% lieferten, wie aus Tabelle 17 herauszulesen ist.

Modell	Trainingsdaten	Tesdaten:	>70%	<70%
Rendl Riffel 1 & Salzboden	2018/19	2010-2018	6	0
		2018/19	6	0
		2019/20	6	0
	2019/20	2010-2018	6	0
		2018/19	7	0
		2019/20	6	0
St. Veit	2018/19	2010-2018	6	0
		2018/19	6	0
		2019/20	6	0
	2019/20	2010-2018	6	0
		2018/19	7	0
		2019/20	6	0

Tabelle 17: Auswertungen der Prognosegenauigkeit der Modelle zu gm.10

Die beiden Modelle des Standortes Rendl Riffel 1 & Salzboden konnten alle Testdatensätze aus der Saison 2019/20 gar mit einer Genauigkeit von über 90% prognostizieren, während die Genauigkeit auch bei den restlichen Testdatensätzen stets über 80% lag. Die Modelle der Station St. Veit konnten mit der Ausnahme von nur zwei Testdatensätzen stets eine Genauigkeit von über 80% aufweisen, was

speziell verglichen mit den Ergebnissen der anderen modellierten Gefahrenmuster ein sehr gutes Prognoseergebnis darstellt und auf deutliche Zusammenhänge zwischen den meteorologischen Messwerten und dem Auftreten von gm.10 schließen lässt.

Der kurzfristige Einfluss des Wettergeschehens kann bei gm.10 daher auf Basis dieser statistischen Untersuchungsergebnisse als sehr groß angesehen werden.

Im Interview mit Patrick Nairz (siehe Anhang 1.2) wurde die Frage gestellt, ob sich einzelne Gefahrenmuster nur mithilfe von Wetterstationsdaten bestimmen lassen und falls ja, welche das am ehesten seien. Seine Antwort, dass vor allem bei gm.10 die Wetterstationsdaten eine ganz wesentliche Rolle spielen, lässt sich mit den Ergebnissen dieser Datenanalyse gut statistisch unterlegen und bekräftigt die Annahme, dass die Analyseergebnisse als aussagekräftig anzusehen sind.

9. Schlussfolgerung und Ausblick

In diesem Kapitel werden die Analyseergebnisse der Modellberechnungen zusammengefasst und präsentiert, sowie ein Ausblick auf mögliche zukünftige Forschungsarbeiten im Themengebiet gewährt. Dabei soll die Quintessenz der Datenanalyse erneut thematisiert werden und neben den Vorteilen der statistischen Untersuchungen auch mögliche Limitationen solcher rein datenbezogenen Auswertungen beschrieben werden.

Zusammenfassend ist über die Prognose der Gefahrenmuster rein auf Basis statistischer Messwerte zu meteorologischen Einflussparametern festzuhalten, dass die Ergebnisse je nach untersuchtem Gefahrenmuster stark divergieren und somit keine einheitliche abschließende Aussage getroffen werden kann. Das ist vorrangig auf die spezifischen Charakteristika der einzelnen Gefahrenmuster zurückzuführen, da der Einfluss weiterer Parameter neben den Wetterdaten auf die unterschiedlichen Muster von vornherein differenziert betrachtet werden muss. Wie eingangs in Kapitel 6.2.4 detailliert beschrieben, sind manche Gefahrenmuster deutlich stärker als andere vom Schneedeckenaufbau und Metamorphoseprozessen innerhalb der Schneedecke beeinflusst, die anhand der meteorologischen Messwerte nicht klar ersichtlich werden.

Infolgedessen konnte eine statistische Prognose der Auftritte von gm.1: Bodennahe Schwachschicht nicht durchgeführt werden, da bereits die Erstellung der Modelle anhand der Trainingsdatensätze keine akkuraten Ergebnisse liefern konnte und das Auffinden von Relationen basierend auf den Wetterdaten nicht gewährleistet werden konnte. Das bestätigte die Untersuchung von Modell 1 anhand der Testdatensätze, da zwar die angestrebte Genauigkeit von 70% erreicht werden konnte, dies jedoch vorrangig auf die geringen Auftrittszahlen von gm.1 im Untersuchungszeitraum und eine hohe True Negative Rate zurückzuführen ist, während die True Positive Rate nicht ansatzweise die erhofften Ergebnisse liefern konnte. Es ist folglich zu dem Schluss zu kommen, dass die Prozesse, die ein Auftreten von gm.1 bekräftigen, nicht alleine mit meteorologischen Messwerten beschrieben werden können und zu einer akkuraten Auftrittsprognose die Berücksichtigung weiterer Einflussparameter vonnöten ist.

Ein ähnliches Problem wurde bei der Modellerstellung zur Prognose von gm.2 ausgemacht, insofern ebenfalls eine hohe TNR die Genauigkeiten verzerrte, während die TPR nicht die angestrebte Güte aufwies. Die Überprüfung der Modelle hatte somit zur Folge, dass zwar an vereinzelten Testdatensätzen eine Prognosegenauigkeit von 70% erreicht werden konnte, dies jedoch nie in Verbindung mit akkuraten Werten bei sowohl TNR als auch TPR. Abermals ist das Fazit zu ziehen, dass zur Prognose von Auftrittstagen von gm.2 weitere Parameter in die Untersuchung miteinbezogen werden müssen, um akkurate Ergebnisse zu erhalten, lediglich anhand der meteorologischen Parameter muss die Prognose als unzureichend abgeschlossen werden.

Bei den Datenanalysen zu gm.6 konnten bereits im Schritt der Modellerstellung erste Unstimmigkeiten festgestellt werden, indem zwar ein hoher Recall und damit TPR-Wert erreicht werden konnte, dies jedoch stets mit einer niedrigen TNR einherging. Aufgrund der hohen Auftrittszahlen vom gm.6 im Untersuchungszeitraum fiel dies jedoch bei der Analyse nicht stärker ins Gewicht, wodurch auch die Überprüfungen an den Testdatensätzen deutlich bessere Ergebnisse liefern sollten als bei den zuvor untersuchten Gefahrenmustern. Bei Betrachtung der Analyseauswertung ist somit zum Schluss zu kommen, dass die Modelle zwar Zusammenhänge zwischen den Stationsdaten und den Auftrittstagen von gm.6 feststellen konnten, dies jedoch nicht lückenlos vonstatten ging. Die angestrebte Genauigkeit von 70% konnte in vielen Fällen erreicht werden, ist aber aufgrund der durchwegs niedrigen TNR mit Vorsicht zu behandeln. Festzuhalten ist, dass durch die Analyse zwar Zusammenhänge aufgedeckt

werden konnten und die Prognose auf Basis der Messwerte durchaus im Bereich des Möglichen liegt, in der ausgeführten Form jedoch nicht fehlerfrei gewährleistet werden kann.

Ein anderes Bild zeigte sich bei der Untersuchung des vierten und letzten untersuchten Gefahrenmusters, da die Modellprognosen zu den Auftritten von gm.10 ausnahmslos die angestrebte Genauigkeit erreichen konnten und in vielen Fällen sogar deutlich übertrafen. Beide hierzu erstellten Modelle lassen die Annahme zu, dass der Einfluss der meteorologischen Parameter bei gm.10 unter den untersuchten Gefahrenmuster als deutlich am größten einzustufen ist und das Phänomen der Frühjahrssituation gut anhand der statistischen Wetterdaten zu prognostizieren ist.

In Abbildung 67 und in Tabelle 18 wurden die Ergebnisse sämtlicher Untersuchungen erneut gegenübergestellt, um die Unterschiede der Modellgüte zu den einzelnen Gefahrenmuster zu verdeutlichen. Abermals ist der beschriebene Trend klar erkennbar, wodurch eine Auftretisprognose von gm.1 und gm.2 anhand der verwendeten Methode nicht bewerkstelligt werden konnte, während die Ergebnisse der Datenanalyse zu gm.6 auf Zusammenhänge mit den meteorologischen Einflussparametern zumindest schließen lassen und bei gm.10 eindeutige statistische Relationen mit den Wetterstationsdaten nachgewiesen werden konnten.




Abb. 67: Darstellung der Untersuchungsergebnisse (Quelle: eigene Darstellung)

Untersuchtes Gefahrenmuster	Modell	Genauigkeit >70%	Genauigkeit <70%
gm.1	1: Tuxerjoch	10*	7
	2: St. Veit**	0	0
	3: Mosesgipfel**	0	0
gm.2	1: Mosesgipfel	8	28
	2: Rendl Riffel 1 & Salzboden	3	32
gm.6	1: Tuxerjoch	24	14
	2: St. Veit	16	23
	3: Rendl Riffel 1 & Salzboden	30	8
gm.10	1: Rendl Riffel 1 & Salzboden	37	0
	2: St. Veit	37	0

Tabelle 18: Gegenüberstellung der Untersuchungsergebnisse

*Sämtliche Fälle, in denen die Genauigkeit von 70% erreicht wurde, sind mit einer überproportionalen TNR zu begründen, während die Auftrittstage nicht lokalisiert werden konnten und das Modell somit als, zur Prognose von gm.1 unbrauchbar, handzuhaben ist.

**Die Modelle 2 und 3 zur Prognose von gm.1 erfüllten nicht die benötigten Qualitätskriterien, die zur Überprüfung anhand der Testdatensätze als notwendig erachtet werden, weshalb hierzu keine Ergebnisse vorliegen.

An dieser Stelle sollen nun einige Limitationen der vorliegenden Forschung thematisiert werden.

Durch die spezifischen Bedingungen, die zur Ausprägung der spezifischen Gefahrenmuster führen und vor allem bedingt durch den relativ kurzen Untersuchungsraum von 10 Jahren, ist nach momentanem Datenstand leider keine vollständige Analyse zu jedem der 10 Gefahrenmuster durchzuführen. Eine Analyse zum Zusammenhang der meteorologischen Messwerte und dem Auftritt bestimmter Gefahrenmuster konnte somit nur bei den häufigsten im Lawinenlagebericht erwähnten Mustern mit sehr unterschiedlichen Ergebnissen durchgeführt werden.

Im Vergleich der vier Analysen zu den Gefahrenmustern gm.1: Bodennahe Schwachschicht, gm.2: Gleitschnee, gm.6: Lockerer Schnee und Wind sowie gm.10: Frühjahrssituation zeigt sich deutlich, dass eine Verallgemeinerung in Hinblick auf direkte Zusammenhänge mit den Wetterstationsdaten nicht getroffen werden kann. Dass jedes der Gefahrenmuster durch vorhergehende Wetterphänomene hervorgerufen beziehungsweise gefördert wird liegt zwar in der Natur der Sache, die Komplexität der Einflussfaktoren führt jedoch dazu, dass jedes Gefahrenmuster einzeln betrachtet und statistisch ausgewertet werden muss. Die Auswahl der Methode hat dabei sicherlich ebenso einen Einfluss auf etwaige Analyseergebnisse wie die Auswahl der verwendeten Wetterstationen. Somit ist zu dem Schluss zu kommen, dass die Ergebnisse zwar als statistisch wertvoll betrachtet und die Zusammenhänge als solche identifiziert und gewertet werden können, jedoch ähnliche Forschungen unter Berücksichtigung anderer Einflussfaktoren unterschiedliche Ergebnisse aufweisen können, weshalb die Rahmenbedingungen bei der Interpretation der Ergebnisse immer miteinbezogen werden müssen. Dies wurde unter anderem in der Anfangsphase dieser Arbeit sichtbar, als die Auswahl der zu verwendenden Analyseparameter erst durch verschiedene Testläufe herausgefunden werden musste und diese ersten Testläufe deutlich andere Ergebnisse lieferten, als schlussendlich in dieser Arbeit präsentiert werden. Ebenso muss weiterhin die Tatsache berücksichtigt werden, dass die subjektive Einschätzung und Erfahrung der Lawinenprognostiker*innen bei der Ausgabe der Gefahrenmuster eine sehr große Rolle spielen (vgl. Anhang 1.2, Frage 4), womit ein gewisser Unsicherheitsfaktor für

statistische Untersuchungen einhergeht, da die Entscheidung meist keiner zahlengestützten Methode unterliegt. Nichtsdestotrotz stellen die Analyseergebnisse einen relevanten Beitrag zur Informationserweiterung im sich ständig wandelnden Themenkomplex der Lawinenwarnung dar und sollen für künftige Entscheidungsfindungen eine zusätzliche Grundlage liefern.

Ein Ausblick auf mögliche Folgeanalysen muss in erster Linie dahingehend ausfallen, dass eine größere Anzahl an Wetterstationen und ein damit einhergehender, vergrößerter Stichprobenumfang an Wetterstationsdaten detailliertere Ergebnisse und zusätzliche Erkenntnisgewinne liefern könnte. Aufgrund des beschränkten Zeit- und Ressourcenaufwandes im Zuge dieser Masterarbeit war das nicht umzusetzen, sollte aber Anreiz für zukünftige Projekte im Themengebiet darstellen. Im Zuge dessen wäre es auch spannend herauszufinden, inwiefern weitere relevante Einflussfaktoren wie der Schneedeckenaufbau, möglicherweise in Form von Daten aus diversen Schneedeckensimulationsmodellen oder Schneeprofilen, in die Analyse miteinbezogen werden können, um akkuratere Prognoseergebnisse liefern zu können. Wenn additiv noch weitere Faktoren, wie vorherrschende Lawinenwarnstufen oder Lawinenprobleme zur besseren Beschreibung der vorherrschenden Bedingungen eingebaut werden, kann die Genauigkeit der Modellvorhersage sicherlich weiter optimiert werden.

Ebenso ist mit zeitlicher Fortdauer der Datenaufzeichnung eine Erweiterung der Möglichkeiten verbunden, da in einem größeren Untersuchungszeitraum eventuell Modelle zu jenen Gefahrenmustern erstellt werden können, die im Zuge dieser Arbeit aufgrund der geringen Auftretiszahlen noch keine Bedeutung finden konnten.

Erweitert man das Themengebiet auf die verschiedenen Informationsmittel, die im Zuge der Lawinenwarnung Beachtung finden, so sind die Forschungsmöglichkeiten schier unbegrenzt. Zwar wurden zu Lawinengefahrenstufen erste Untersuchungen angestellt, jedoch erweitern zusätzliche Forschungen auf diesem Gebiet schlichtweg die Informationsfülle der Lawinenwarndienste und sind allein daher erstrebenswert. Grundsätzlich sollte die Lawinenkunde darauf bedacht sein, auch mithilfe solcher statistischen Auswertungen im Rahmen von Forschungsarbeiten mögliche Wissenslücken zu schließen oder unbekannte Zusammenhänge aufzudecken, um der Komplexität der Thematik weiter auf den Grund gehen zu können.

10. Literaturverzeichnis

AMMANN W., BUSER O. und VOLLENWYDER U. (1997): Lawinen. – Basel.

BRODERSEN L. (2005): Geo-communication the modern way: Lars Brodersen explains why the communication of geoinformation involves more than a map alone. – In: GEO:connexion, vol. 4, no. 5, 28-31.

BRODERSEN L. (2007): Paradigm shift from cartography to geo-communication. – In: XXIII International Cartographic Conference: Cartography for everyone and for you. ICA.

BRODERSEN L. (2008) Geo-communication and information design – A viewpoint regarding the content architecture agreement on case and location as the basis of decisions based on a phenomenological, communicative, semiotic and rhetorical foundation. – In: Journal for Theoretical Cartography, vol. 1, 1-13.

data.gv.at – Open Data Österreich (2021): basemap.at Verwaltungsgrundkarte Raster Österreich. - online unter: <https://www.data.gv.at/katalog/dataset/2c54f4d6-5712-4e5a-a025-b7f7a396c39b> [17.11.2021]

data.gv.at – Open Data Österreich (2021): Digitales Geländemodell Tirol. – online unter: <https://www.data.gv.at/katalog/dataset/0454f5f3-1d8c-464e-847d-541901eb021a> [24.11.2021]

EAWS – European Avalanche Warning Services (2021): Inhalt und Aufbau des Lawinenlageberichts (Lawinenbulletin). – online unter: https://www.avalanches.org/wp-content/uploads/2019/05/Inhalt_Aufbau_Lawinenlagebericht-EAWS.pdf [02.06.2021]

EAWS – European Avalanche Warning Services (2022): Glossar. – online unter: <https://www.avalanches.org/glossary/?lang=de> [17.01.2022]

ERNEST A. (1981): Wetter, Schnee und Lawinen. Lawinengefahr, Einflüsse, Beurteilung, Verhalten. – Graz, Stuttgart.

HAKE G., GRÜNREICH D. und MENG L. (2002): Kartographie. Visualisierung raum-zeitlicher Informationen. 8. Auflage – Berlin.

KELLERMANN W. (1989): Lawinen. – In: DAV (Hrsg.): Wetter, Lawinen. (Alpin-Lehrplan; 9) – 2. Auflage – München, Wien, Zürich; 119-187.

KRIZ K. und GALANDA M. (1998): Thematische Aspekte der Hochgebirgskartographie. – In: KRIZ K. (Hrsg.): Hochgebirgskartographie – Silvretta '98. High Mountain Cartography (= Wiener Schriften zur Geographie und Kartographie, 11) – Wien, 117-129.

KRIZ K. (2001): Kartographische Ansichten im neuen Millennium. – In: BUZIN R. und WINTGES T. (Hrsg.): Kartographie 2001 – multidisziplinär und multimedial. Beiträge zum 50. Deutschen Kartographentag. – Heidelberg, 228-238.

KRIZ K. (2013): Maps and Design-Influence of Deception, Space and Aesthetics on Geocommunication. – In: KRIZ K., CARTWRIGHT B., KINBERGER M. (Hrsg.): Understanding Different Geographies. – Berlin, Heidelberg, 9-23.

LAWIS (2021)¹: Lawineninformationssystem. – online unter: <https://www.lawis.at> [04.12.2021]

LAWIS (2021)²: Stationen. – online unter: <https://lawis.at/station/> [04.12.2021]

LWD Tirol – Lawinenwarndienst Tirol – Lawinen.report (2021)¹: Gefahrenmuster. – online unter: <https://lawinen.report/education/danger-patterns> [07.06.2021]

LWD Tirol – Lawinenwarndienst Tirol – Lawinen.report (2021)²: Lawinengefahrenstufen. – online unter: <https://lawinen.report/education/danger-scale> [04.06.2021]

LWD Tirol – Lawinenwarndienst Tirol – Lawinen.report (2021)³: Lawinenlagebericht vom 06.12.2020. – online unter: https://static.avalanche.report/bulletins/2020-12-06/2020-12-06_de.pdf [08.11.2021]

LWD Tirol – Lawinenwarndienst Tirol – Lawinen.report (2021)⁴: Lawinenlagebericht vom 18.12.2020. – online unter: https://static.avalanche.report/bulletins/2020-12-18/2020-12-18_de.pdf [08.11.2021]

LWD Tirol – Lawinenwarndienst Tirol – Lawinen.report (2021)⁵: Lawinenprobleme. – online unter: <https://lawinen.report/education/avalanche-problems> [04.06.2021]

LWD Tirol – Lawinenwarndienst Tirol – Lawinen.report (2021)⁶: Mehr. Über uns. – online unter: <https://lawinen.report/more/about> [02.06.2021]

MAIR R. und NAIRZ P. (2010): Lawine. - Die 10 entscheidenden Gefahrenmuster erkennen. – Innsbruck.

NAIRZ P., SAUERMOSER S., KLEEMAYER K., GABL K., STOFFEL M., MARGRETH S. und RUDOLF-MIKLAU F. (2011): Lawinen: Entstehung und Wirkung. – In: RUDOLF-MIKLAU F. und SAUERMOSER S. (Hrsg.): Handbuch Technischer Lawinenschutz. – Berlin, 21-62.

NEUGEBAUER L. (2021): Lawinenrisikomanagement durch Geokommunikation in entlegenen Gebirgsregionen. – Wien.

R-bloggers (2021): Binary Logistic Regression With R. – online unter: <https://www.r-bloggers.com/2020/05/binary-logistic-regression-with-r/> [25.11.2021]

SCHWEIZER J., JAMIESON J. B. und SCHNEEBELI M. (2003): Snow avalanche formation. – In: Reviews of geophysics, vol. 41 (4), 1016, 1-25.

SCHWEIZER J. und LÜTSCHG M. (2001): Characteristics of human-triggered avalanches. – In: Cold Regions Science and Technology, vol. 33 (2), 147-162.

WOLLSCHLÄGER D. (2014): Grundlagen der Datenanalyse mit R. Eine anwendungsorientierte Einführung. – 3. Auflage – Berlin.

ZOTTLER M., SCHWARZ M. und KUNDIGRABER B. (2014): Der Zusammenhang zwischen Lawinengefahrenstufen und Wetterlagen in den Gebirgsregionen der Steiermark. – Graz.

Anhang

Anhangsverzeichnis

Anhang 1: Interview	90
Anhang 1.1: Interviewleitfaden.....	90
Anhang 1.2: Interview mit Patrick Nairz (LWD Tirol) vom 23.08.2021	92
Anhang 2: Ergebnisse der Modellerstellung	106
Anhang 2.1: Modellerstellung zu gm.1, Modell 1: Tuxerjoch	106
Anhang 2.2: Modellerstellung zu gm.1, Modell 2: St. Veit.....	110
Anhang 2.3: Modellerstellung zu gm.1, Modell 3: Mosesgipfel.....	111
Anhang 2.4: Modellerstellung zu gm.2, Modell 1: Mosesgipfel.....	112
Anhang 2.5: Modellerstellung zu gm.2, Modell 2: Rendl Riffel 1 und Salzboden	116
Anhang 2.6: Modellerstellung zu gm.6, Modell 1: Tuxerjoch	120
Anhang 2.7: Modellerstellung zu gm.6, Modell 2: St. Veit.....	124
Anhang 2.8: Modellerstellung zu gm.6, Modell 3: Rendl Riffel 1 und Salzboden	128
Anhang 2.9: Modellerstellung zu gm.10, Modell 1: Rendl Riffel 1 und Salzboden	132
Anhang 2.10: Modellerstellung zu gm.10, Modell 2: St. Veit.....	136

Anhang 1: Interview

Anhang 1.1: Interviewleitfaden

Die 10 entscheidenden Gefahrenmuster sind seit 2010 ein Teil des Lawinenlageberichtes, um die Lawinensituation detaillierter und mithilfe der wiederkehrenden Muster auch leichter verständlich zu übermitteln.

In meiner Masterarbeit widme ich mich der Kommunikation dieser Lawinengefahrenmuster und will im Zuge dessen den Zusammenhang mit den meteorologischen Messdaten aufzeigen.

Daher anfangs einige Fragen zum Ablauf eurer Entscheidungsfindung in der täglichen Arbeit.

Frage 1:

Gibt es vorgefertigte Abläufe, die bei der Erstellung des Lageberichtes jeden Tag bearbeitet werden?

Frage 2:

Wie wird, um das Thema etwas zu konkretisieren, bei der Ausgabe der Gefahrenmuster üblicherweise vorgegangen?

Frage 3:

Spielen die Stationsmesswerte in eurer Einschätzung zu den Gefahrenmustern eine Rolle?

Frage 4:

Welche Rolle spielt die subjektive Gefahreneinschätzung durch Beobachtungen im Gelände und Erfahrung?

Frage 5:

In eurem Buch „Lawine. Die 10 entscheidenden Gefahrenmuster erkennen“ haben Rudi Mair und du 2010 erstmals die Gefahrenmuster als solche beschrieben.

Wurde bei der Erstellung/Ausarbeitung der Gefahrenmuster mit Wetterdaten gearbeitet?

Frage 6:

Der Schneedeckenaufbau ist ein zentrales Kriterium bei den meisten Gefahrenmustern.

Lassen sich einzelne Gefahrenmuster jedoch nur mithilfe von Wetterstationsdaten bestimmen?

- Falls ja, welche am ehesten?

Die Kommunikation der Lawinengefahr ist ein zentraler Bestandteil eurer Arbeit beim Lawinenwarndienst und gleichzeitig ein Thema, das auch immer wieder Veränderungen unterliegt.

Beispielsweise wurden mit dem interregionalen Projekt ALBINA die Lawinenwarndienste Tirols, Südtirols und Trentinos zu einem Lawinenreport zusammengefügt. Im Zuge dessen wurden u.a. die dynamischen Regionen eingeführt, um die Lawinensituation noch besser und spezifischer beschreiben zu können, während von 2010 bis 2018 die Gefahrenmuster noch für ganz Tirol ausgegeben wurden und keine regionalen Unterschiede beschrieben wurden.

Frage 7:

Ist eine Beurteilung der Gefahrenmuster für ganz Tirol aussagekräftig?

- Falls nein, warum wurde es lange so gehandhabt?
- Und auf welche Größenbereiche lassen sich vernünftige Aussagen bezüglich der Gefahrenmuster treffen?

Frage 8:

Werden Wetterdaten herangezogen, um beispielsweise die Gebietsabgrenzung der Gefahrenmuster im Lagebericht zu bestimmen?

Frage 9:

Birgt ein solches Mustersystem hinsichtlich der Kommunikation Gefahren oder Risiken?

Frage 10:

Es kommt ja durchaus vor, dass manche Gefahrenmuster über Wochen hinweg im Lagebericht erwähnt werden. Wird die Gefahr tendenziell weniger stark wahrgenommen, wenn ein Gefahrenmuster sehr lange präsent ist?

Anhang 1.2: Interview mit Patrick Nairz (LWD Tirol) vom 23.08.2021

I: Hallo Patrick und danke, dass du dir die Zeit für das Interview genommen hast. Lass uns gleich beginnen.

Die 10 entscheidenden Gefahrenmuster sind seit 2010 ein Teil des Lawinenlageberichtes, um die Lawinensituation detaillierter und mithilfe der wiederkehrenden Muster auch leichter verständlich zu übermitteln.

In meiner Masterarbeit widme ich mich der Kommunikation dieser Lawinengefahrenmuster und will im Zuge dessen den Zusammenhang mit den meteorologischen Messdaten aufzeigen.

Daher anfangs einige Fragen zum Ablauf eurer Entscheidungsfindung in der täglichen Arbeit.

Frage 1: Gibt es vorgefertigte Abläufe, die bei der Erstellung des Lageberichtes jeden Tag bearbeitet werden?

P: Prinzipiell geht es bei uns immer darum, dass wir, wenn wir den Lagebericht erstellen, sämtliche Daten, die uns zur Verfügung stehen, genau analysieren. Ein wesentlicher Teil sind auf der einen Seite die Messdaten der Wetterstationen, ein weiterer wesentlicher Teil sind sämtliche Beobachterdaten. Einerseits sind das Daten von Frühbeobachtern, die noch direkt vor Ort ihre Wetterhütten haben und dort meteorologische Daten aufzeichnen und uns zusätzlich dann auch noch weitere Informationen über die Schneedecke und mögliche Lawinenereignisse übermitteln. Weitere Informationen sind dann beispielsweise von den Wintersportlern, von denen wir immer mehr Rückmeldungen bekommen. Selbstständige Geländearbeit ist auch ein wesentlicher Teil und zusätzlich dann auch der Kontakt mit der Wetterdienststelle. Im Grunde schauen wir alles was wir kriegen und relevant ist für das jetzige Wetter-, Schneedecken- und Lawinengeschehen - dass wir uns sämtliche Informationen möglichst gut anschauen und uns vor allem sehr gezielt gewisse Daten anschauen.

I: Frage 2: Wie wird, um das Thema etwas zu konkretisieren, bei der Ausgabe der Gefahrenmuster üblicherweise vorgegangen? Wie legt ihr euch da fest?

P: Prinzipiell ist es bei uns so, dass wir, wenn wir den Lawinenreport erstellen, eigentlich eine ganz klare Maske haben, wo wir dann den Lagebericht entsprechend ausfüllen und uns überlegen, welche Lawinenprobleme gerade relevant sind und damit zusammenhängend dann auch welche Gefahrenmuster relevant sind.

Richtig diesbezüglich so ein grobes Schema, nach dem wir vorgehen und sagen „Ist es gm.1? Nein ist es nicht. Ist es gm.2? Nein ist es nicht.“ haben wir nicht. Das geht eigentlich alles gedanklich im Kopf. Dass wir dann natürlich die einzelnen Auswahlfenster haben, wenn wir den Lawinenreport schreiben - einerseits für die Probleme, andererseits für die Gefahrenmuster und uns dann halt immer Gedanken machen müssen, was sind derzeit gerade die relevantesten Gefahrenmuster für die jeweiligen Regionen - also wir machen ja für jede dieser aggregierten Regionen, die wir haben für den Lawinenreport - machen wir uns Gedanken über die jeweiligen Gefahrenmuster. Inzwischen ist es so, dass wir die Möglichkeit haben uns auf 3 Lawinenprobleme entsprechend zu konzentrieren, bzw. 2 Gefahrenmuster. Das ergibt sich dann einfach aus der Situation heraus, dass wir uns natürlich im Hochwinter nicht wirklich über gm.10 Frühjahrssituation Gedanken machen müssen im Normalfall. Wie gesagt, das geht einfach im Zuge der täglichen Arbeit, da weiß man: Zurzeit ist einfach z.B. ein Gleitschneeproblem das Hauptthema in bestimmten Höhenlagen und Expositionen. Und zusätzlich woanders oder weiter oben ein Altschneeproblem bzw. entsprechend die Gefahrenmuster dazu. Hängt ganz wesentlich mit dem Wissen der Schneedecke zusammen und natürlich auch mit der Analyse der Wetterstationsdaten.

Also einen Algorithmus, der uns z.B. automatisch ausspuckt, dass heute dieses Gefahrenmuster auftritt, gibt es in diesem Fall nicht.

I: Frage 3: Spielen die Stationsmesswerte in eurer Einschätzung zu den Gefahrenmustern eine Rolle? Dass beispielsweise ab einem gewissen Wert eines Parameters ein Gefahrenmuster nicht mehr ausgegeben wird?

P: Auf der einen Seite spielen Messwerte natürlich eine Rolle, auf der anderen Seite ganz wesentlich auch die ganzen Schneeprofile und Schneedeckenuntersuchungen. Weil gerade bei z.B. gm4 kalt auf warm - um ein Beispiel zu bringen - da sind einerseits natürlich die Messwerte mal primär ausschlaggebend bzw. das ganze Wettergeschehen.

Dass man sagt, man hat eine Situation gehabt, da ist die Schneedecke feucht geworden, was man anhand der Wetterstationsdaten und speziell anhand der Schneeoberflächentemperatur, der Lufttemperatur und des Taupunktes recht gut feststellen kann. Man hat also gewisse Bereiche, an denen die Schneedecke feucht geworden ist und dann kommt eine Kaltfront mit entsprechenden Schneefällen - dann weiß man, dass das prinzipiell ein Zeitpunkt ist, ab dem wir uns vermehrt Gedanken machen müssen über z.B. gm.4. Und dann ist eigentlich anschließend das Wesentliche, dass man sich ins Gelände begibt bzw. sämtliche Beobachter und Wintersportler aktiviert über soziale Medien und auffordert in die Schneedecke zu schauen. Können die schon etwas beobachten? Man fordert sie auf, Schneedeckenstabilitätsuntersuchungen zu machen, um dann anhand dieser Daten dann feststellen zu können, ob sich etwas ausgebildet hat. Und wenn, ob das relevant ist. Sprich, ob sich da eine Schwachschicht gebildet hat, die bruchfortpflanzungsfähig ist. D.h. es ist eine Kombination aus diesen Sachen eigentlich. Das wäre exemplarisch für gm.4.

Bei gm.2 Gleitschnee z.B. - sehr wohl spielen Wetterstationsdaten eine sehr große Rolle, speziell wenn man sich mit warmen Gleitschneelawinen beschäftigt. Einerseits frühes Einschneien - massive Schneefälle auf einen warmen Boden - haben wir immer ganz sicher Gleitschneeaktivität bzw. fortschreitende Durchfeuchtung der Schneedecke. Auch das wird anhand von Wetterstationsdaten soweit ganz gut feststellbar. Inzwischen auch in Kombination mit Schneedeckensimulationsmodellen und den Schneedeckenuntersuchungen draußen im Gelände - dass man feststellen kann, wie tiefgreifend ist sie durchnässt. Geht sie bis zum Boden und wenn sie bis zum Boden geht, kann man sagen, das wird der Zeitpunkt sein, wo sich vermehrt diese Gleitschneelawinen aktivieren werden.

So kann man eigentlich bei jedem Gefahrenmuster in ähnlicher Weise dann sehen können.

I: Frage 4: Welche Rolle spielt die subjektive Gefahreinschätzung durch Beobachtungen im Gelände und Erfahrung?

P: Eine sehr große Rolle. Subjektive Einschätzung und Erfahrung, im Grunde gehts ja genau bei diesen [Gefahren]Mustern um diese wiederkehrenden Situationen und je mehr man selbst gespeichert hat von früher, je besser und je größer die Erfahrung ist, desto leichter tut man sich auch diese Gefahrenmuster entsprechend zuzuordnen und die Situationen mit historischen Situationen zu vergleichen. Also ja, ein sehr wesentlicher Aspekt auf jeden Fall.

Auf der anderen Seite wie gesagt, grad mit gm.4 ist es nach wie vor so, dass wir noch nicht immer ganz genau wissen, wenn die Voraussetzungen gegeben sind, ob das jetzt tatsächlich eine Situation ist, die sich zur gefährlichen Situation ausbildet. Da sind wir fest dabei, anhand von Schneedeckensimulationsmodellen - Snowpack - das kommt von den Schweizern - da Unterstützung zu haben, aber da tapfen wir teilweise noch ein bisschen im Dunklen. Und da ist das Um und Auf ins Gelände zu gehen - rauszuschauen, zu untersuchen und auch natürlich zu sehen, ob eventuell

Lawinen ausgelöst werden und vor allem wo. Ob die Bereiche zusammenpassen mit jenen Bereichen wo eben die Voraussetzungen für gm.4 gegeben waren und so macht man sich dann das Bild.

I: Jetzt könnt ihr aber nicht jeden Tag überall in Tirol sein. Wie macht ihr das? Fahrt ihr da speziell in die Gebiete, in denen ihr euch vorher schon denkt, dass es da interessant ist oder aussagekräftig für größere Regionen?

P: Da spielen wie gesagt die Informationen der Wetterdienststelle eine sehr große Rolle, die uns dann einfach immer sagen, wo wie das Wetter entsprechend ist. Die ganzen Wetterstationsdaten und natürlich gerade bei solchen Situationen, wo gewisse Entwicklungen gerade im Gang sind, sind natürlich auch die Beobachter gefordert. Dieses Beobachternetz, das wir haben, das haben wir in den letzten Jahren eigentlich ständig ausgebaut und schauen, dass wir da wirklich sehr gut ausgebildete geländegängige Leute haben. Also es handelt sich nicht selten um Bergführer, die uns dann ganz gezielt auch in die Schneedecke schauen. Sind halt die verschiedensten Entwicklungen, wenn man einfach sagt - Oberflächenreifbildung oder solche Sachen oder Nigg Effekt - also sehr spezielle Sachen. Gerade Nigg Effekt ist etwas, da sind wir sehr auf diese Daten oder Informationen von den Leuten vor Ort oder von Wintersportlern angewiesen und da helfen uns schon sehr die sozialen Medien, dass wir ganz aktiv auch teilweise bei gewissen Situationen, in denen wir uns nicht so sicher sind in einen Blog z.B. hineinschreiben, dass sich die Leute bitte rückmelden sollen, wenn sie so etwas beobachten.

Und inzwischen muss man auch sagen, dass wir intern einen Mitarbeiter haben, der uns die ganze Oberfläche programmiert und da sind wir jetzt ganz fest dabei, dass wir sämtliche Informationskanäle, die wir haben, gebündelt - oder versuchen, diese Informationen sehr gebündelt für uns zur Verfügung zu haben. Weil zurzeit ist es ein bisschen ein Kribus Krabus mit WhatsApp und Emails und keine Ahnung was alles daherkommt und dass man da einfach schaut - wirklich problembezogen, dass es schon nach Möglichkeit selektiert wird oder eben gefahrenmusterbezogen, dass man dann diese Informationen hat.

Es ist eher das Problem, dass wir teilweise zu viele Daten haben und wir müssen schauen, dass wir aus der Hülle und Fülle von Daten wirklich das selektieren, was für uns gerade wesentlich ist aber auch da hilft die Erfahrung.

I: Nutzt ihr lawis.at auch oder nur das was euch direkt geschickt wird?

P: Natürlich nutzen wir auch lawis.at. Lawis ist für uns eigentlich gerade in Hinblick auf die Schneeprofile das Tool schlechthin, wo wir auf Schneeprofilinformationen zurückgreifen können. Und seit es lawis gibt, muss man sagen, dass wir deutlich mehr Informationen über die Schneedecke haben als wir früher gehabt haben. Früher hatte man einfach noch andere Programme. Da hat man teilweise dieses Schneedecken- oder Schneeprofilprogramm lokal installiert, d.h. das haben halt Beobachter oder Lawinenkommissionsmitglieder bei sich daheim installiert und für sich gehabt und haben es irgendwo archiviert und einige wenige haben es zu uns geschickt und sonst sind uns eigentlich diese Informationen verborgen geblieben. Seit es lawis gibt, haben wir, ich möchte nicht sagen exponentiell mehr – aber die Informationen über das Schneeprofil sind deutlich angestiegen. Und es wird auch so kommuniziert, grade auch bei den Kursen, dass man den Leuten sagt, gebt bitte die Schneeprofile ins lawis rein und auch da gibt es Entwicklungen, dass man anhand dieser Schneeprofile, die man hat, dass man da versucht, zukünftig gewisse Muster automatisiert herauszufiltern. Also da geht's auch in die Richtung, dass man dann Gefahrenmuster dann schlussendlich eventuell dadurch schneller eigentlich erkennen kann.

I: Quasi durch die Abfolge der Schneesichten eine automatische Auswahl?

P: Ja genau, dass man da abtastet - und in gewissen Bereichen sind wir jetzt gerade dabei, da wird sich in näherer Zukunft einiges entwickeln, aber es geht dann darum, wo sind die Problembereiche, haben wir eventuell deziidiert in Textteilen gewisse Informationen, die da weiterhelfen bzw. wie du sagst aufgrund der Abfolge von Schichten mit gewissen Härten und anderen Eigenschaften wie Kornformen usw. Dass man da sagen kann, das ist mit hoher Wahrscheinlichkeit, weil das auch in diesem Höhenbereich gerade vorhanden ist, wird das zu dem und dem Problem und Muster passen.

I: Sehr interessant auf jeden Fall.

P: Es gibt inzwischen sogar dann auch mal grad innerhalb der europäischen Lawinenwarndienste sagt man, dass die Entwicklung in die Richtung gehen wird, dass Lawinenprognostiker in Zukunft vermehrt Vorschläge vom System bekommen werden. Also aufgrund der ganzen Simulationen, die man hat, aufgrund der Daten, die man hat, dass das System dann, oder Systeme entwickelt werden, die dem Prognostiker eigentlich gut unter die Arme greifen und dann sagen, ich schlag zB gewisse Regionen vor mit gewissen Problemen und gewissen Gefahrenmustern. Und der Experte und Prognostiker wird das dann entsprechend anpassen müssen. Aber es wird noch dauern – sicher Jahre dauern, aber es ist nicht abwegig, dass das bald einmal so sein wird und dass dann eigentlich der Experte wie beim Wetter/Wetterdienst das eigentlich eh schon ist. Die ganzen Modelle, die geben ja eigentlich sehr gut vor schon, was wann wo wie zu erwarten ist und der Experte muss dann einfach noch mithilfe seiner Erfahrung eingreifen und das System dann – oder dem System seinen Stempel aufdrücken. Und das kann und wird bei den Lawinenwarndiensten auch so sein und da wird die Aufgabe des Prognostikers einerseits darin liegen in dieser Anpassung, auf der anderen Seite halt vermehrt in dieser Kommunikationsschiene. Dass man dann versucht, dass man das was man da weiß, möglichst gut zu transportieren und so zu transportieren, dass die Leute das draußen im Gelände auch können/ checken können und sich entsprechend verhalten können.

Mit lawis ist natürlich das Andere - ich habe mich jetzt nur auf die Schneeprofile konzentriert - natürlich sind die Wetterstationsdaten auch relevant, die haben wir zwar über andere Systeme bei uns verfügbar, aber im Grunde ist das eins zu eins das Gleiche. Und natürlich die Unfälle auch. Unfälle sind immer ein Indiz für gewisses Gefahrenpotenzial in bestimmten Bereichen und es ist die Summe aus allen Informationen.

I: Frage 5: In eurem Buch „Lawine. Die 10 entscheidenden Gefahrenmuster erkennen“ haben Rudi Mair und du 2010 erstmals die Gefahrenmuster als solche beschrieben.

Wurde bei der Erstellung/Ausarbeitung der Gefahrenmuster mit Wetterdaten gearbeitet?

P: Damals war die Basis von dem ganzen Konzept nicht die, dass wir uns Wetterstationsdaten angeschaut haben und aufgrund dieser dann schlussendlich diese Muster rausgefiltert haben, sondern es war eigentlich ein intuitiver und erfahrungsbasierter Ansatz.

Wir haben dann einfach überlegt, welche Situationen hat es so gegeben. Natürlich ist z.B. beim gm.5 Schnee nach langer Kälteperiode das Um und Auf es hat diese lange Kälteperiode gegeben. Die muss es gegeben haben, dass die Entwicklungen passieren, inkl. aufbauender Umwandlung - also so gesehen ist das - wie soll man sagen - die Grundlage des Gefahrenmusters, aber es war nicht so, dass wir dann zu den Wetterstationen gegangen sind und uns Wetterstationsdaten angeschaut haben und analysiert haben, was wir als lange Kälteperiode definieren oder sowas. Also erfahrungsbasiert einfach.

I: Frage 6:

Jetzt hast du schon öfter gesagt, dass der Schneedeckenaufbau ein zentrales Kriterium bei den Gefahrenmustern ist.

Lassen sich einzelne Gefahrenmuster jedoch nur mithilfe von Wetterstationsdaten bestimmen?

- Falls ja, welche am ehesten?

Dass man quasi nur aufgrund vom Wettergeschehen sagen kann, dass dieses Gefahrenmuster jetzt auftritt.

P: Jo mei, wenn wir jetzt z.B. gm.10 anschauen, die Frühjahrssituation, dann spielen Wetterstationsdaten schon eine ganz ganz wesentliche Rolle, weil man da einfach schauen muss, wie schaut es mit der Durchnässung der Schneedecke aus. Wenn ich jetzt gar nicht im Gelände bin, bin ich 100% abhängig von diesen Stationsdaten. Wie ich es schon vorher erwähnt habe, ist da der Fokus ganz wesentlich auf der Schneeoberflächentemperatur. Primär auf dem, dann auf dem Taupunkt, abhängig von der Luftfeuchte und auch Lufttemperatur. In Bezug auf den gesamten Schneedeckenaufbau dann, wo habe ich Schwachschichten und wo kann mir die Nässe irgendwie was antun bei den Schwachschichten.

Rein nur Wetterstationsdaten – mal angenommen bei gm.3 Regen. Regen ist halt so ein Thema, da verlassen wir uns halt sehr auf die Wetterdienststelle, die uns sagt es kommt eine Warmfront und es wird so und soweit rauf regnen. Unsere Erfahrung zeigt, dass bei ein und dem gleichen Wetterereignis, das über Tirol zieht, die Regengrenze teilweise um 1000 Höhenmeter differieren kann, weil noch irgendwo Kaltluftzellen drinnen sind, die irgendwo anders ausgerechnet werden. Und da versuchen wir auch auf der einen Seite mit irgendwelchen Wettermodellen die es gibt, das möglichst gut herauszufiltern, auch anhand der Wetterstationsdaten. Dass man sieht, wie sich die Lufttemperatur entwickelt - wie nah an Null Grad ist sie schon und natürlich dann auch anhand der ganzen Beobachtungen.

Rein nur Wetterstationsdaten gibt es nie bei uns muss ich sagen, nein.

Graupel wäre z.B. wieder was wo man sich 100% auf die Wetterdienststelle verlassen muss bzw. die Erfahrung. Dass man einfach sagt, konvektive Niederschläge wird es halt hauptsächlich und vermehrt im Frühjahr geben, auf der anderen Seite gibt es diese Phänomene auch eingelagert in größeren Fronten im Hochwinter, sodass auch da Graupel auftreten kann.

Was schon wichtig ist – wir haben einen unterschiedlichen Fokus auf Wetterstationsdaten in Abhängigkeit der Jahreszeit. Für mich spielt eine Oberflächentemperatur auf der einen Seite im Hochwinter eine Rolle gemeinsam mit dem Taupunkt z.B. für die Oberflächenreifbildung. Und dann im Frühjahr für die Durchnässung. Strahlungseinfluss also die Globalstrahlung hat im Hochwinter meistens ganz wenig Einfluss auf meine Entscheidung. Hingegen wird die dann im Frühjahr immer wichtiger, wenn man sieht, dass die W/m^2 steigen und steigen und in Kombination mit den anderen Sachen wird sich halt irgendwann mal ein Nassschneezyklus anbahnen.

Ja das ist schon ein Thema natürlich - also unterschiedlicher Fokus auf die Wetterstationsdaten in Abhängigkeit der Jahreszeiten.

I: Ok das ist auf jeden Fall sehr gut für meine Arbeit, das lässt sich da sicher einbauen.

Jetzt hast du auch schon davon gesprochen, dass die Kommunikation der Lawinengefahr ein zentraler Bestandteil eurer Arbeit ist.

Die Kommunikation der Lawinengefahr ist ein zentraler Bestandteil eurer Arbeit beim Lawinenwarndienst und gleichzeitig ein Thema, das auch immer wieder Veränderungen unterliegt.

Beispielsweise wurden mit dem interregionalen Projekt ALBINA die Lawinenwarndienste Tirols, Südtirols und Trentinos zu einem Lawinenreport zusammengefügt. Im Zuge dessen wurden u.a. die dynamischen Regionen eingeführt, um die Lawinensituation noch besser und spezifischer

beschreiben zu können, während von 2010 bis 2018 die Gefahrenmuster noch für ganz Tirol ausgegeben wurden und keine regionalen Unterschiede beschrieben wurden.

Frage 7: Ist eine Beurteilung der Gefahrenmuster für ganz Tirol aussagekräftig?

- Falls nein, warum wurde es lange so gehandhabt?

P: Damals war das einfach der erste Schritt, wie man an die Sache herangegangen ist. Das Gleiche ist dann auch mit den Lawinenproblemen bzw. anfangs waren die Probleme noch nicht dabei aber z.B. mit der Expositionsdarstellung, dass wir die besonders gefährdeten Bereiche mit Exposition und Höhenangabe angeführt haben und das war dann teilweise oder anfangs, wie du das auch gesagt hast mit den Gefahrenmustern, für ganz Tirol gedacht und vorgesehen.

Und da ist natürlich eine Durchmischung und natürlich muss man dann wieder sagen, was sind Tirol bezogen, da ist einfach die Region deutlich größer - also Region unter Anführungszeichen - aber nein ist so. Da hat man halt eine Riesenregion, auf die man das dann bezieht und einfach einen Fokus, in dem man ganz Tirol anschaut - was sind da meine Hauptgefahrenmuster z.B. Oder was sind meine hauptsächlich gefährdeten Bereiche. Und da kann es z.B. gerade bei den Gefahrenmustern wie gesagt - da ist der Fokus, dass man sagt, wenn ich irgendwo in Südtirol ein massives Gleitschneeproblem habe und die sind relativ groß und in Nordtirol habe ich halt irgendwo ein bisschen ein Altschneeproblem, dann werde ich halt das Gleitschneeproblem vorne dransetzen und dann halt Altschneeproblem je nachdem - lassen wir das eine bodennahe Schwachschicht vom Frühwinter sein - als Gefahrenmuster und nachher kommt das als zweites. Und wenn ich dann noch Triebschnee irgendwo hab, dann sagt man das ist halt nicht so wichtig, weil es auch über die Fläche bezogen nicht so relevant ist und nicht so vorherrschend. Also es ist immer dieser Flächenbezug auf der einen Seite, wie verbreitet sind die Gefahrenmuster in der Region und welche Auswirkungen, welche Lawinen habe ich zu erwarten. Und das ist dieser Fokus und das ist eine sehr gute Entwicklung gewesen, dass man dann gesagt hat, ok - aber eigentlich ist es eine Durchmischung, die nicht immer ganz für den Kunden ist. Man versucht dann natürlich - oder hat versucht, im Text das möglichst zu differenzieren und zu sagen man hat diese Gefahrenmuster X und Y vor allem in jenem und jenen Bereichen, also da war der Kunde quasi mehr gefordert, dass er auf diese Bereiche dann selbst draufkommt. Einerseits über den Text des Lawinenlageberichts, wie er damals geheißen hat oder jetzt Lawinenreport bzw. auch unser sehr sehr hilfreiches Mittel, das wir haben - unser Blog. Dass wir da wirklich dann detailliert auf solche Sachen eingehen können und Sachen die wir primär nicht kommunizieren konnten, detaillierter und was wir uns da alles gedacht haben, dass wir da versucht haben das über andere Medien zu kompensieren. Inzwischen eben - wie du angesprochen hast mit dieser Aggregation von Regionen und mit der spezifischen Angabe der Probleme und Gefahrenmuster pro Region, sind wir natürlich viel viel flexibler und haben da natürlich dann auch - oder der Lawinenreport hat an Aussagekraft sehr gewonnen.

I: D.h. war ein Grund dafür, dass ihr einfach nicht genug Daten gehabt habt, dass ihr nicht von Beginn an kleinere Regionen gemacht habt?

P: Nein. Das war einfach die Entwicklung damals, die ist halt einfach in gewissen Schritten erfolgt und damals haben wir halt noch nicht die. Da haben wir halt gesagt ok was ist einmal ein guter Ansatz oder wir wollen es natürlich auf jeden Fall kommunizieren, dass wir diese Muster haben. Dann fängt man halt an - was sind die Möglichkeiten? Wie schaut es aus? Das ist ja teilweise doch einiges an Programmieraufwand im Hintergrund, wenn man bestehende Systeme hat und man muss auch ganz ehrlich sagen, der Lagebericht oder Lawinenreport ist ein sehr lebendiges Produkt. Dass man dann einfach auch durch den Input von den Nutzern und durch selbstständige Arbeit mit dem Report jeden Tag - dass man da halt einfach draufkommt, was kann man noch anders oder besser machen. Und da

war z.B. das ALBINA Projekt eine ganz herausragende Sache, dass wir da von Grund auf sagen konnten, was sind Sachen, die uns prinzipiell schon gestört haben. Es war uns eigentlich gleich bewusst, dass das jetzt noch nicht das Beste ist, was wir machen konnten, aber es war nicht viel anderes möglich, sagen wir so. Und auch mit dieser tageszeitlichen Abhängigkeit, was wir dann gemacht haben - Vormittag/Nachmittag - wo wir auch entsprechend die Muster adaptiert haben für Vormittag und Nachmittag oder auch die Probleme. Das sind alles diese schrittweisen Entwicklungen, die teilweise einfach Zeit brauchen. Teilweise hat man die Ressourcen nicht gehabt und teilweise hat man halt gewisse Probleme in der Kommunikation, die dann aufgetreten sind, anfangs auch noch gar nicht so wahrgenommen. Also die selbstständige Arbeit von uns mit diesen Gefahrenmuster, die hat dann schon ergeben, dass gewisse Situationen - in Summe nur einige sehr wenige Situationen, die ich mit den Gefahrenmuster gar nicht so ganz gut beschreiben kann. Das ist z.B. Problem mit massiver Lockerschneelawinenaktivität. So gesehen gibt es das nicht bei den Mustern und das ist auch im Laufe der Zeit erst aufgetaucht.

I: Ok auch sehr interessant. Und auf welche Größenbereiche lassen sich vernünftige Aussagen bezüglich der Gefahrenmuster treffen? Weil du eben angesprochen hast, ihr habt es anfangs für ganz Tirol probiert. Grundsätzlich ist ja doch jeder Berg anders als der Nachbarberg.

P: Ja grundsätzlich können wir sowieso nicht nach Tälern oder so unterscheiden. Wie gesagt - das wie wir es jetzt haben mit unseren Regionen, das ist eine sehr sehr vernünftige Größe. Normalerweise sagt man, dass Lawinenwarndienste Gefahrenstufen normalerweise ab einer Regionsgröße von 100 km² ausgeben und jetzt bei uns mit dem Report mit unseren Regionen, die wir haben, die werden teilweise noch - das ist auch eine Hintergrundinformation - die werden wir teilweise auch noch kleiner machen. Also gerade z.B. die nördlichen Ötztaler und Stubai Alpen sind wir jetzt draufgekommen im Zuge von unserer Arbeit, dass es vernünftig wäre, die noch zu teilen. Da z.B. hat es - weil du das davor mal angesprochen hast, ob wir Wetterstationsdaten hergenommen haben, um irgendwas festzulegen - da hat es sehr detaillierte Analysen gegeben, einerseits aufgrund unserer Erfahrung aber auch mit Wetterstationsdaten, wo man sich dann festgelegt hat, mit diesen Regionen. Nachher also zusätzlich zu unserer Expertise sind dann noch Analysen von Wetterstationsdaten über langen Zeitraum gelaufen - dass wir Cluster gebildet haben und gesagt haben ok, das passt zusammen mit dem was wir uns gedacht haben. Und gerade bei der einen Region sind wir jetzt draufgekommen - hoppala es wäre doch gut, wenn man das wieder teilt und kleiner macht.

Sonst von der Größe ca. 100 km² und natürlich ist es schon so, dass dieses Wettergeschehen ein wesentlicher Aspekt ist. Dass das dann auch vorgibt - gewisse Wetterentwicklungen waren in gewissen Bereichen Tirols, welche Regionen waren da betroffen und entsprechend macht man dann die Auswahl der Regionen. Mit denen können wir sehr gut arbeiten mit dieser Größe. Und die Tendenz geht jetzt noch dahin, dass wir einige Regionen, die bisschen zu groß waren noch halbieren oder dritteln werden und dann haben wir aber genug Klein- oder Kleinstregionen mit denen wir wirklich sehr sehr gut arbeiten können. Und noch weiter hinunter zu differenzieren - so viele Informationen hätten wir gar nicht in diesen Kleinregionen, dass das Sinn machen würde. Und die Hauptentwicklungen kann man so sehr gut darstellen, wie wir das haben.

I: Ok gut, du hast mir da schon wieder ein bisschen vorweggegriffen, weil meine Frage 8 wäre gewesen: Werden Wetterdaten herangezogen, um beispielsweise die Gebietsabgrenzung der Gefahrenmuster im Lawinenreport zu bestimmen?

P: Natürlich ja. Eben wieder in Abhängigkeit der jeweiligen Situation und in Abhängigkeit des jeweiligen Gefahrenmusters. Natürlich ist Regen z.B. höchstwahrscheinlich - Wetterstationsdaten werden da überall herangezogen eigentlich. Bei diesen langfristigen Entwicklungen, bodennahe

Schwachschicht vom Frühwinter z.B. oder sowas da geht es halt einfach um die langfristige Entwicklung - da sind es jetzt nicht die unmittelbaren Wetterstationswerte.

I: Ok aber d.h. ihr vergleicht die Daten der verschiedenen Regionen und schließt die so dann zusammen?

P: Ja auf jeden Fall - ja genau. Und wir vergleichen dann die ganzen Schneeprofile z.B. und Rückmeldungen, die wir bekommen. Es ist ja eigentlich unser Bild, das wir haben - da versuchen wir halt jeden Tag, dass wir ein möglichst realitätsnahes Bild der Situation haben und meinen jeden Tag, wenn wir den Report herausgeben, dass das was wir jetzt gerade ausgeben, der Realität möglichst nahekommt. Und das ist ein ständiger Iterationsprozess - von Tag zu Tag gibt es neue Entwicklungen, neue Wettereinflüsse usw. und ja. So muss man das eigentlich sehen, das ist jetzt nicht... Das Wesentliche bei uns ist halt eigentlich, dass man von Beginn des Winters aktiv voll dabei ist bei der Sache und sich Gedanken macht, was halt gerade im Herbst z.B. im Hochgebirge schon passiert schattseitig, wo der Schnee liegen bleibt. Und das ist halt einfach dieser Dauerprozess, dass man sagt - aha da war halt einfach, wie letzten Winter z.B. alles eher unbeständig und dann haben sich halt plötzlich Schwachschichten gebildet, die kurzfristig schon im Frühwinter zu Unfällen geführt haben. Bzw. Schwachschichten, die dann im Juni auch wieder aktiv geworden sind, weil Wasser reingekommen ist. Also da ist bei uns immer diese ganzheitliche Sicht ein ganz wesentlicher Aspekt wo Wetterstationsdaten also Wetter mit den Daten in Beziehung mit dem ganzen Wissen über die Schneedecke alles einfließt und dann dieses Gesamtbild ergibt.

I: Ok sehr gut. Jetzt hätte ich noch zwei Fragen zum Abschluss hinsichtlich der Kommunikation. Die Gefahrenmuster sind ja in einem Mustersystem, das ja immer dieselben Sachen beschreibt.

Birgt ein solches Mustersystem hinsichtlich der Kommunikation Gefahren oder Risiken? Dass z.B. etwas untergeht und dass die Informationen nicht so beim Nutzer ankommen, wie ihr das wollt?

P: Da versuchen wir schon, ... Das ist einfach das Prinzip der Kommunikation oder eines der Prinzipie der Kommunikation, dass wir unseren Report so aufgebaut haben - oder Lageberichte innerhalb der europäischen Lawinenwarndienste immer so aufgebaut werden, dass wesentliche leicht erfassbare Informationen vorne drangestellt werden und Details dann weiter unten kommuniziert werden. Das ist das Prinzip der Informationspyramide, wo nach wie vor die Gefahrenstufe an oberster Stelle ist, dann die Probleme mit den Gefahrenmustern kommen und dann kommen halt entsprechend die Textteile zur Gefahr, Schneedeckenaufbau und dem Wetter.

Da ist es so, dass man jetzt sehr große Bemühungen hat, dass man versucht, vermehrt diesen problemorientierten Ansatz, wo dann schlussendlich als Beiwerk möchte ich sagen die Gefahrenmuster auch noch dranhängen, dass man den eigentlich verstärkt und auch versucht, dass die Leute das möglichst als erstes dann auffassen.

Man sagt, was ist derzeit das Hauptproblem - lassen wir es ein Altschneeproblem sein. Wo habe ich das? Dann kommt irgendeine Expositionsdarstellung mit entsprechenden Expositionsbereich und Höhenbereich, wo ich das zu erwarten habe. Und dann kommt da dazu noch das Gefahrenmuster – Altschneeproblem aufgrund von – lass es sein – gm.4 so in die Richtung.

Und wenn man ein Grundverständnis hat, dann kann man sich eigentlich diese Gefahrenbereiche relativ gut schon herausarbeiten und das ist eben die Stärke von den Problemen und von den Mustern, dass sich die Leute da unseres Erachtens schon relativ gut vorstellen können, worum es da geht. Wir wissen vom kommunikationstechnischen her, dass es ein Problem ist, dass sich Leute zehn Sachen merken. 5 ist so eine Grundgröße - es gibt mal nicht nur deshalb, aber auch deshalb 5 Gefahrenstufen, es gibt 5 Lawinenprobleme, es gibt 5 Lawinengrößen. Also es sind alles so Sachen,

was man sich relativ leicht merken kann und wir wissen sehr wohl, dass Gefahrenmuster in der Kommunikation schon eher etwas für Interessiertere Wintersportler, Experten und Profis sind.

Dass die sich dann über die Entwicklungen, die zu einem bestimmten Problem führen, einfach nochmal mehr Gedanken machen können und wissen, welcher Prozess dahintersteht. Also wir sind uns bewusst, dass wir mit diesen Gefahrenmustern sicher nicht so einen Wintersportler erreichen werden, der eine Woche lang auf Urlaub zu uns kommt und da ein bisschen im Variantenbereich herumfährt. Für das sind sie aber auch nicht gedacht. Das ist einfach in der Ebene der Kommunikation zumindest unter den Lawinenproblemen, aber doch so, dass wir sie eher weiter oben haben, weil dieses wiederkehrende und offensichtliche doch etwas ist, was sich die Leute unseres Erachtens leicht merken können.

Wenn man sagt, Schnee nach langer Kälteperiode - das ist für uns schon irgend so was Aussagekräftiges. Also man sagt, ok wenn es lange kalt ist und dann schneit, bitte passt wirklich extrem auf, die Gefahrenstufe geht sehr rasch hinauf, die Gefahr geht sehr rasch hinauf und wir haben während dieser Phasen immer sehr viele Unfälle gehabt und das wird immer so sein. Und ja da denkt man schon, dass das für Leute, die sich interessieren, dass es schon so gemacht ist, dass man damit arbeiten kann und das ist auch die Rückmeldung, die wir bekommen. Es ist natürlich so, dass vom Grundprinzip bei den Gefahrenmustern, wenn man sagt mit den Gefahrenmustern beschreibt man primär die Prozesse, die zu einem Problem führen, dass es nicht immer ganz konsistent ist. Weil schneearm neben schneereich ist nicht unbedingt ein Prozess. Das sagt aber, dass wenn man ein Altschneeproblem hat, dass man am ehesten in schneearmen Bereichen, je nachdem, aber sagen wir bei bodennahen Schwachschichten, das in schneearmen Bereichen auch auslösen kann. Das war auch mit diesen... Das hat sich auch nicht unmittelbar, als wir uns die Gefahrenmuster überlegt haben, war das nicht damals unser Gedanke, dass wir gesagt haben, was ist das Problem und was ist der Prozess, weil das mit diesen Problemen - die sind damals auch erst so langsam aufgekommen und die waren noch nicht konsistent und so definiert - so fix definiert als Standard bei den Lawinenwarndiensten, wie es jetzt der Fall ist. Aber es hat sich schlussendlich sehr gut eingefügt muss man sagen.

I: Ok. Frage 10:

Es kommt ja durchaus vor, dass manche Gefahrenmuster über Wochen hinweg im Lagebericht erwähnt werden. Wird die Gefahr tendenziell weniger stark wahrgenommen, wenn ein Gefahrenmuster sehr lange präsent ist?

P: Ja da sprichst du etwas an, das nicht nur für die Gefahrenmuster zutrifft - natürlich auch für die Gefahrenstufe und für das Lawinenproblem. Es gibt einfach solche Situationen - und da brauchen wir nicht lange zurückschauen, da müssen wir uns nur den letzten Winter anschauen - Situationen, wo über sehr lange Zeit, ein ausgeprägtes Altschneeproblem herrscht als Beispiel, weil das ist sehr typisch für lange Probleme. Und da beobachtet man sehr häufig, dass unmittelbar - nehmen wir jetzt Schnee nach langer Kälteperiode - dass es da unmittelbar danach wirklich eine extrem störanfällige Schneedecke gibt mit zahlreichen Auslösungen und dann beobachtet man, wie sich einfach im Laufe der Zeit die Schneedecke schon etwas stabilisiert bzw. die Auslösung nicht mehr so leicht erfolgt aber immer noch leicht genug und immer noch Gefahrenbereiche großflächig genug, dass man von diesen Problemen und Gefahrenstufen, die man da ausgibt nicht weggehen kann.

Und was wir schon beobachten, wenn das über zu lange Zeit ist, dass die Leute es dann das nicht mehr ganz so ernst nehmen. Was immer hilft - unter Anführungszeichen hilft - für die Wahrnehmung sind dann wieder Lawinenereignisse bzw. natürlich dann auch wieder der Blog, wo wir in den Analysen schreiben, dass wir in den Schneedeckenuntersuchungen sehen, dass es immer noch nicht

sehr gut ist. Dass die Leute wirklich noch sehr aufpassen müssen, weil wir haben noch immer vermehrte Auslösungen usw. - also das ist ein allgemeines Problem einfach, dass...

Sehr gut wahrgenommen werden so Sachen, wenn es akut ist, wenn vermehrt Lawinenunfälle passieren bzw. wenn wir auch massiv in die Medien gehen und sagen, jetzt großflächig einen Appell: passt bitte auf, wir haben ein massives Problem hier und dort. Aber das liegt an der Natur der Sache. Bei uns dann auch, wann wir mit der Gefahrenstufe runtergehen. Mit der Gefahrenstufe runtergehen ist immer viel viel schwieriger als mit der Gefahrenstufe hinauf gehen und da muss man wirklich sehr gute fundierte Informationen haben, dass man sagt es hat sich wirklich definitiv gebessert und man kann guten Gewissens runter gehen.

Was du noch angesprochen hast mit dem Zeitraum wie lang man Gefahrenmuster gibt. Gleitschnee z.B. ist so etwas, wo man auch innerhalb der Lawinenwarndienste gelernt hat, man kann in schneereichen Wintern theoretisch im ganzen Winter von einem Gleitschneeproblem sprechen. Aber das ist genau so etwas, was dann halt irgendwann einmal nicht mehr ernst genommen wird von den Leuten und die Leute gehen halt kreuz und quer unter den Gleitschneemäulern durch und machen sich keine Gedanken mehr. Gerade beim Gleitschnee ist es so eine Sache, dass man inzwischen und das auch innerhalb der Lawinenwarndienste so kommuniziert hat, dass wir das nur mehr dann ausgeben, wenn wirklich eine massivere Gleitschneeaktivität beobachtet wird gerade. Das ist dann, wie ich anfangs schon erwähnt habe, im Frühwinter, wenn es massiv schneit auf einen noch ungefrorenen Boden, wenn in den Grashängen wirklich sehr sehr viele Gleitschneelawinen abgehen und die auch Straßen gefährden können und sehr sehr unberechenbar sind. Und dann im Frühjahr hinaus, wenn die Wärmephase ist - dann gibt es halt diese kalten Gleitschneelawinen, die halt irgendwann am kältesten Tag mitten in der Nacht abgehen - die hat man nicht im Griff. Da gibt es Situationen, wo wir die vermehrt beobachtet haben - dann wird man das so kommunizieren, aber sonst geben wir Gleitschneeproblem dann gar nicht mehr in den Lawinenreport hinein.

Das ist schon eine Entwicklung auch, wo man gesagt hat - wir konzentrieren uns auf die Bereiche wo wir das vermehrt rückgemeldet bekommen und selbst beobachten, dass es weiter wahrgenommen und ernst genommen wird.

I: Um eben zu vermeiden, dass die Leute das dann nicht so ernst nehmen?

P: Genau. Das ist überhaupt - muss man auch sagen - schon auch ein Grundprinzip von uns. Wir wollen nicht immer nur mit dem erhobenen Zeigefinger den Leuten sagen, da ist es gefährlich, dort ist es gefährlich und das dürft ihr nicht machen, sondern dann schon auch kommunizieren: jetzt ist es richtig gut und trauts euch und hauts euch raus und genießt den Pulverschnee oder so. Also nicht im Zweifel noch die Gefahrenstufe höher halten oder im Zweifel ein Problem oder Gefahrenmuster länger anführen - das tun wir eigentlich nicht, ganz bewusst nicht. Und ernten manchmal auch Kritik, dass es bei kritischen Situationen, wenn wir davor noch Stufe 4 gegeben haben und dann sagt, es hat sich gebessert, jetzt gehen wir auf einen 3er – aber es ist halt doch noch ein kritischer 3er und dann passieren Unfälle und dann heißt es warum habt ihr nicht den 4er gelassen, weil dann wären die Leute ein bisschen zurückhaltender gewesen. Aber da versuchen wir halt wirklich das zu leben, von dem wir überzeugt sind, dass es sich wirklich so entwickelt hat. Und die Basis sind halt unsere umfassenden Daten, die wir haben.

I: Jetzt ist mir noch aufgefallen, gm.6 ist in den letzten Jahren in den Daten, die ich bearbeitet habe, extrem oft über einen langen Zeitraum im Report drinnen gewesen. Warum habt ihr es da dann anders gehandhabt?

P: Ja (überlegt) ... Im Grunde wäre es da interessant bei deinen Auswertungen zu sehen, gibt es einen Zusammenhang mit dem Wettergeschehen, dass man einfach sagt es war halt doch immer wieder windig und kalt und dass es sich immer neu entwickelt hat. Weil lockerer Schnee und Wind als solches, oder das Tribschneeproblem als solches ist ja eigentlich als kurzfristiges Problem anzusehen. Dass man sagt, ok es ist unmittelbar kalt und es weht der Wind und dann hast du die Schwachschicht - am Ende eben diesen lockeren Pulverschnee oder den Wildschnee oder so etwas, wo du halt mitunter kurzfristig dann auch von einer langen Kältephase die aufbauend umgewandelten Kristalle hast. Aber normalerweise geht das ja dann in ein Altschneeproblem über, wenn es persistente Schwachschichten sind, also aufbauend umgewandelte Kristalle. Oder man sagt nach 2 bis 3 Tagen ist das wieder vorbei. Oder wenn es dieses klassische Tribschneeproblem ist, mit der Schwachschicht aus Pulverschnee - Wildschnee dauert ein bisschen länger - aber aus lockerem kaltem Pulverschnee, dann sollte ein Tribschneeproblem oder gm.6 eigentlich nur 2 bis 3 Tage anhalten und dann eigentlich vorbei sein. Kann natürlich sein – dass in tieferen Lagen und mittleren Lagen das vorbei ist, aber in höheren Lagen haben wir es doch noch, also geben wir es halt noch hinein.

I: Das hat mich nur gewundert. Es ist auch das Gefahrenmuster gewesen, das sich am besten mit den Wetterdaten irgendwie prognostizieren ließ.

P: Ja das glaube ich auch. Du sagst ist es kalt, ist es das. Aber hätte das dann auch halbwegs zusammen gepasst von deiner Auswertung her, weil es kann natürlich ja... wie gesagt man ist dann mitunter verleitet, wenn sonst alles passt und dann geht halt ein bisschen der Wind hochalpin, dass man dann sagt ok geben wir das halt an, weil das ist halt das auf das am Ehesten aufzupassen ist zurzeit. Darum kann das auch überrepräsentiert sein.

I: Ok wie gesagt, das war das, das man am besten prognostizieren konnte. Ich wäre mit meinen Fragen durch, aber wenn du noch irgendwas anmerken willst? Es war eh sehr ausführlich also bin auf jeden Fall sehr dankbar, dass das funktioniert hat.

P: Bitte gerne, du kannst dich jederzeit melden, wenn du noch irgendwo eine Frage hast oder dir etwas nicht ganz klar ist.

Was vielleicht noch ist, was ich nicht erwähnt hatte - das hast du jetzt selbst festgestellt - wir haben ganz am Anfang die Gefahrenmuster bisschen angepasst. Gerade von der Namensgebung her. Eben der zweite Schneefall, das war am Anfang einfach noch ein bisschen ein anderer Gedankengang, wo wir dann gesagt haben, ok eigentlich gehts ja darum, dass sich da eine bodennahe Schwachschicht gebildet hat, die dann persistent ist und noch länger Probleme bereiten kann. Und dann ein Gefahrenmuster der zweite Schneefall irgendwann Anfang Jänner nach dem zehnten Schneefall anzugeben, das war dann, wo wir auch draufgekommen sind, dass es kommunikationstechnisch nicht das richtige ist und dann haben wir es umbenannt. [in bodennahe Schwachschicht]

Oder früher dann auch kalter lockerer Neuschnee und Wind, was wir umbenannt haben auf Lockerer Schnee und Wind. Dass wir gesagt haben, es könnte theoretisch auch eine aufbauend umgewandelte Schneeoberfläche sein, die vom Wind beeinflusst sein kann - das wird vertragen und entsprechend zerkleinert und das wird dann windabgewandt abgelagert, d.h. das wäre dann das Korrektere und deswegen hat es eben diese kleinen Anpassungen noch gegeben.

Aber vom Grundprinzip muss man ganz ehrlich sagen, sind wir eigentlich schon auch überrascht und bisschen stolz, dass man so gut damit arbeiten kann. Also wir sind im Verhältnis auf wenig Probleme gestoßen, damit zu arbeiten. Wie gesagt das mit den Lockerschneelawinen kann noch ein Thema sein, aber es gibt wenige wenige Tage, an denen man sagt, jetzt tu ich mir ein bisschen schwer. Das

kann mit den Prozessen, die zu einem Altschneeproblem führen manchmal ein bisschen diffiziler sein oder wie lange habe ich das Problem Schnee nach langer Kälteperiode noch, dass man das dann anführt. Ja aber wie gesagt für das gibt es Blog und solche Sachen, dass man das, wenn es uns irgendwo zwickt und wenn wir meinen, dass wir es nicht richtig weitergeben können, dass wir das dann doch einer breiten Masse entsprechend weitergeben können über die anderen Medien.

I: Ok, d.h. die Gefahrenmuster sind so gesehen nicht in Stein gemeißelt?

P: Ja wir sind eigentlich immer und bei allem was wir machen für neue Entwicklungen offen und das ist eigentlich unser Grundprinzip. Und wenn wir Input kriegen von den Leuten oder selbst darauf kommen, dass irgendwas besser gemacht werden kann - dann sind wir die Ersten, die versuchen das möglichst rasch umzusetzen.

I: Ist ja eigentlich auch der richtige Ansatz, wie man so etwas Kommunikatives machen sollte eigentlich.

P: Unbedingt. Unbedingt ja - und in der heutigen Zeit muss man ganz ehrlich sagen, ist ja das Tolle, man kann ja extrem rasch handeln. Also bei uns z.B. der Programmierer und Mitarbeiter und Prognostiker von uns auch, der diese Lawinenreportseite dann auch im Wesentlichen programmiert bzw. dann auch koordiniert hat - der ist halt, wenn es irgendetwas gibt, performancemäßig - dann wird das gleich nochmal verbessert, neue Server angeschafft oder alles auf einen Server gelegt und Sachen im Hintergrund vereinheitlicht, verbessert. Und wenn sonst irgendetwas auftaucht kann der unmittelbar etwas umprogrammieren und dass wir während des Winters immer wieder auch Neuerungen umsetzen, wo man normalerweise sagt, never touch a running system.

Aber inzwischen sind wir so weit, dass das im Hintergrund gut getestet werden kann alles und ok zack - release mitten im Winter und wir fahren mit der neuen Version weiter und das ist inzwischen kein Problem. Früher war es so in meinen Anfangszeiten - da hat man halt mit den Partnern, die die Internetseite programmiert haben, irgendwann mal im Frühjahr zusammengesetzt und die ganzen Wünsche und sowas bekanntgegeben und dann gehofft, dass das zu Winterbeginn gut programmiert ist, weil die nächste Möglichkeit irgendetwas anzupassen erst wieder Monate später war z.B.

Das ist dieses rasche Handeln - das ist ganz eine tolle Sache, die inzwischen sehr gut funktioniert.

I: Ok, das heißt ihr habt da mittlerweile selbst einen übernommen? Weil am Anfang habe ich schon mitbekommen, dass bei uns in der Uni auf unserem Institut auch relativ viel gemacht wurde.

P: Ja genau. Da sind die ganzen Sachen auch mit den ganzen Wetterstationsdaten hin und hergeschoben worden, das ist inzwischen schlussendlich vereinheitlicht und zentralisiert worden.

Da geht es auch unter anderem darum, nicht nur aber auch, dass man gesagt hat, wie kann man das System möglichst wenig fehleranfällig machen und drum jetzt das z.B. mit was ich weiß einem Server, möglicherweise Wetterstationsserver noch einen eigenen. Früher sind wirklich gewisse Sachen weil zB Zugriff auf unsere Landesserver nicht mehr möglich waren, hat eben der Kriz Charly oder haben wir das gemeinsam bzw. Kriz Charly hat das dann initiiert, dass wir gesagt haben, wir machen bei uns jetzt einfach Server und wir hauen unsere ganzen Daten hin und machen ein Abbild von den ganzen Sachen und produzieren unsere eigenen Sachen. Eigentlich ist es die einzige Möglichkeit gewesen, sagen wir so. Das hat man dann umgesetzt und das hat sehr gut funktioniert, muss man auch ganz ehrlich sagen. So richtig massive Ausfälle haben wir eigentlich nie gehabt und wenn es irgendwo gestockt hat, dann war eigentlich extrem schnell, dass alles wieder normal gelaufen ist.

I: Ja das wäre mir auch noch nie aufgefallen.

P: Große Leistung gewesen, muss man schon sagen.

I: Sehr gut gelungen auch die neue Seite, das war schon ein großer Fortschritt.

P: Ja muss ich auch sagen, da sind wir sehr zufrieden. Auch im Hintergrund wie wir arbeiten war natürlich eine riesige Umstellung bei uns mit diesem Satzkatalog zu arbeiten z.B., aber schlussendlich ist es eine sehr sehr gute Sache. Und auch da vom kommunikativen - ganz kurz noch zu dem - von dem ist es auch so, dass es gar nicht schlecht ist. Also am Anfang war ich skeptisch wegen dem Satzkatalog, weil ich mir gedacht habe, wir können nicht alles sagen was man sagen will. Inzwischen ist es so dass der Satzkatalog auch wieder erweitert worden ist und auch für nächstes Jahr wieder erweitert wird mit z.B. Schneedeckensätzen, dass wir da mehr Möglichkeiten haben. Auch das ist ein iterativer Prozess. Schlussendlich bin ich aber überzeugt, dass gerade mit dem Satzkatalog eine bessere Kommunikation möglich ist, weil wir uns noch einmal klarer sein müssen, was wir sagen wollen und die Sätze sind sehr klar und einheitlich. Und die Leute glaube ich können das besser auffassen als wie ich es früher gemacht habe, dass ich halt noch ein Detail reinzupressen und noch ein Detail und noch eins und dann halt verschachtelte Sätze gehabt habe und was auch immer alles. Also da bin ich überzeugt, dass vielleicht der Experte früher mehr damit anfangen konnte, aber die breite Masse jetzt viel einen größeren Nutzen hat.

I: Ok auch interessant. Das habe ich so gar nicht gewusst, dass ihr da nur mehr mit dem arbeitet.

P: Ja das ist, seit wir das System haben - das ist eigentlich von den Schweizern übernommen worden, die haben das schon gehabt, aber schlussendlich von uns dann noch verbessert - mehr Sprachen sind dazugekommen und wir sind da im engsten Austausch mit den Schweizern, dass wir das gemeinsam weiterentwickeln und da jeder was davon hat. Und eben diese Übersetzung, die wir früher gehabt haben, wo ein Übersetzer das im Hintergrund alles auf Englisch übersetzt hat und das halt zeitverzögert war und das ist jetzt alles nicht mehr so. Sobald wir auf einen Knopf drücken und sagen, jetzt ist es fertig, ist es sofort in allen Sprachen verfügbar und da haben wir inzwischen sieben Sprachen.

I: Und ich schätze die Umstellung, dass ihr den Report am Tag davor macht, hat auch positive Auswirkungen gehabt auf die Arbeit. Auch weil du nicht mehr so früh aufstehen musst und den Stress in der Früh einfach nicht hast.

P: Ja - jein, also nicht mehr regelmäßig ganz so früh aber doch noch meistens früh genug. Je nach Situation ist man natürlich auch wieder früher auf den Füßen und überprüft, ob das alles passt. Aber ja auch das ist für uns ein Vorteil und es ist schlussendlich muss man wirklich feststellen auch für den Kunden ein großer Vorteil. Ist tatsächlich so, dass das sehr wertgeschätzt worden ist, dass die Leute schon am Vortag die Information haben. Mit diesen Unabwägbarkeiten, was man hat wettertechnisch teilweise hat aber da können wir reagieren und da reagieren wir dann entsprechend. Dann sagt man ok, ist so, es hat sich uns anders gezeigt das Bild und drum müssen wir handeln und dann passen wir das einfach an und fertig.

I: Eine letzte Frage noch, die mir jetzt noch eingefallen ist zu den Gefahrenmustern. Als ihr die damals veröffentlicht habt, wie wurde das von den anderen Lawinenwarndiensten aufgenommen worden, weil du jetzt z.B. die Schweizer angesprochen hast?

P: Wir haben das damals dann vorgestellt bei den europäischen Lawinenwarndiensten und damals war gerade die Diskussion auch mit den Lawinenproblemen - Vereinheitlichen der Lawinenprobleme oder dieser typischen Gefahrensituationen wie sie teilweise geheißen haben - da hat es ja nicht nur innerhalb von Europa sondern eigentlich weltweit sehr ähnliche Entwicklungen gegeben. Da waren

z.B. auch die Amerikaner, die da sehr gute Ansätze gehabt haben. Die haben es mehr so lawinentypusspezifisch gehabt u.a. und da hat es die Entwicklung gegeben, dass man gesagt hat, ok was wird jetzt der Standard. Da hat sich halt schlussendlich herauskristallisiert, dass es am vernünftigsten ist, sich auf das leicht kommunizierbare zu einigen. Auf diese 5 Lawinenprobleme, was schlussendlich meines Erachtens ein sehr guter Wurf geworden ist. Und wo es geheißen hat, jeder der will, der kann Gefahrenmuster verwenden, muss es aber nicht. Also nicht, dass wir denen das aufgezwungen hat. Einige Lawinenwarndienste europaweit sind da aufgesprungen und andere nicht. Wir sind sehr zufrieden, wie es sich entwickelt hat. Und es wäre nicht gut gewesen, wenn wir gesagt hätten, die 10 Gefahrenmuster sind der europaweite Standard. Es ist besser, dass die Probleme der Standard sind, weil leichter erfassbar und besser kommunizierbar für die Masse.

Und weil es sich einfach sehr sehr stimmig ergibt, auf der einen Seite die Probleme und auf der anderen Seite die Gefahrenmuster mit den Prozessen, die dahinter stecken usw. noch - passt es sehr sehr gut ins Gesamtbild hinein.

I: Gut, ich habe jetzt keine Fragen mehr. Das ist eh länger geworden, als ich gedacht habe, aber ich bin natürlich sehr froh und danke auch nochmal, dass du dir die Zeit genommen hast.

P: Ja bitte gern. Ich wünsch dir alles Gute für die Arbeit und wenn du noch was brauchst, melde dich jederzeit.

Anhang 2: Ergebnisse der Modellerstellung

Anhang 2.1: Modellerstellung zu gm.1, Modell 1: Tuxerjoch

2018/19	2019/20
<pre>> summary(train_1819\$muster) Mode FALSE TRUE NA's logical 131 15 36</pre>	<pre>> summary(train_1920\$muster) Mode FALSE TRUE NA's logical 160 2 20</pre>
<pre>> summary(logistic_model1819) Call: glm(formula = muster ~ HS + LF + LT + WG + Differenz, family = binomial(), data = train_1819) Deviance Residuals: Min 1Q Median 3Q Max -1.5243 -0.2470 -0.1555 -0.1039 2.7256 Coefficients: (Intercept) Estimate Std. Error z value Pr(> z) HS -0.038210 0.008109 -4.712 2.45e-06 *** LF 0.007274 0.019726 0.369 0.712 LT -0.108580 0.086265 -1.259 0.208 WG -0.397711 0.280063 -1.420 0.156 Differenz 0.191876 0.125183 1.533 0.125 --- Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1 (Dispersion parameter for binomial family taken to be 1) Null deviance: 96.452 on 144 degrees of freedom Residual deviance: 54.473 on 139 degrees of freedom (37 observations deleted due to missingness) AIC: 66.473 Number of Fisher Scoring iterations: 7</pre>	<pre>> summary(logistic_model1920) Call: glm(formula = muster ~ HS + LF + LT + WG + Differenz, family = binomial(), data = train_1920) Deviance Residuals: Min 1Q Median 3Q Max -0.46718 -0.17957 -0.11058 -0.08032 2.85984 Coefficients: (Intercept) Estimate Std. Error z value Pr(> z) HS -8.07067 4.27560 -1.888 0.0591 . LF 0.02219 0.03368 0.659 0.5100 LF 0.03640 0.04234 0.860 0.3899 LT -0.06173 0.09387 -0.658 0.5108 WG -0.15493 0.43178 -0.359 0.7197 Differenz -0.05710 0.20086 -0.284 0.7762 --- Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1 (Dispersion parameter for binomial family taken to be 1) Null deviance: 21.189 on 147 degrees of freedom Residual deviance: 18.938 on 142 degrees of freedom (34 observations deleted due to missingness) AIC: 30.938 Number of Fisher Scoring iterations: 8</pre>
<pre>> train_1819\$pred_class <- ifelse(logistic_model1819\$fitted.values >= 0.5, TRUE, FALSE) > ctab_train <- table(train_1819\$muster, train_1819\$pred_class) > ctab_train FALSE TRUE FALSE 128 2 TRUE 7 8 > > accuracy_train <- sum(diag(ctab_train))/sum(ctab_train)*100 > accuracy_train [1] 93.7931</pre>	<pre>> train_1920\$pred_class <- ifelse(logistic_model1920\$fitted.values >= 0.5, TRUE, FALSE) > ctab_train <- table(train_1920\$muster, train_1920\$pred_class) > ctab_train FALSE FALSE 146 TRUE 2 > > accuracy_train <- sum(diag(ctab_train))/sum(ctab_train)*100 > accuracy_train [1] 98.64865</pre>
<pre>> accuracy_train <- sum(diag(ctab_train))/sum(ctab_train)*100 > accuracy_train [1] 93.7931 > Recall <- (ctab_train[2, 2]/sum(ctab_train[2,]))*100 > Recall [1] 53.33333 > TNR <- (ctab_train[1, 1]/sum(ctab_train[1,]))*100 > TNR [1] 98.46154 > Precision <- (ctab_train[2, 2]/sum(ctab_train[, 2]))*100 > Precision [1] 80 > F_Score <- (2 * Precision * Recall / (Precision + Recall))/100 > F_Score [1] 0.64</pre>	
<pre>> auc(roc) Area under the curve: 0.919</pre>	

Testdaten	Modell 18/19	Modell 19/20
2012-2018 <pre>> summary(test_1018\$muster) Mode FALSE TRUE logical 515 307</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5) FALSE TRUE FALSE 398 95 TRUE 184 102 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 64.18485</pre>	
2018/19 <pre>> summary(test_1819\$muster) Mode FALSE TRUE logical 131 15</pre>		
2019/20 <pre>> summary(test_1920\$muster) Mode FALSE TRUE logical 160 2</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5) FALSE TRUE FALSE 85 61 TRUE 1 1 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 58.10811</pre>	

Testdaten:		
Station:	Magdeburger Hütte und Hechenberg	
Seehöhe:	1646m und 1922m	
Subregion:	Karwendel (AT-07-4)	
Exposition:	NW	
Testdaten		Modell 18/19
2014-2018 <pre>> summary(test_1018\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 285 244</pre>		<pre>> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 204 81</pre> <pre>TRUE 193 51</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 48.20416</pre>
2018/19 <pre>> summary(test_1819\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 145 1</pre>		<pre>> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 133 12</pre> <pre>TRUE 1 0</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 91.09589</pre>
2019/20 <pre>> summary(test_1920\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 159 2</pre>		<pre>> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 131 28</pre> <pre>TRUE 1 1</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 81.98758</pre>

Testdaten:		
Station:	Mosesgipfel Schneestation und Mosesgipfel Windstation	
Seehöhe:	2235m und 2550m	
Subregion:	Östliche Deferegger Alpen (AT-07-27)	
Exposition:	SO	
Testdaten		Modell 18/19
2018/19 <pre>> summary(test_1819\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 99 50</pre>		<pre>> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 84 15</pre> <pre>TRUE 46 4</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 59.0604</pre>
2019/20 <pre>> summary(test_1920\$muster)</pre> <pre>Mode FALSE NA's</pre> <pre>logical 156 26</pre>		

Testdaten:		
Station:	Nachtweide und Palinkopf	
Seehöhe:	2030m und 2864m	
Subregion:	Samnaungruppe (AT-07-13)	
Exposition:	W	
Testdaten		Modell 18/19
2010-2018 <pre>> summary(test_1018\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 782 321</pre>		<pre>> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 757 21</pre> <pre>TRUE 306 15</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 70.24568</pre>
2018/19 <pre>> summary(test_1819\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 142 6</pre>		<pre>> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 142 0</pre> <pre>TRUE 4 2</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 97.2973</pre>
2019/20 <pre>> summary(test_1920\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 160 2</pre>		<pre>> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5)</pre> <pre>FALSE</pre> <pre>FALSE 150</pre> <pre>TRUE 2</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 98.68421</pre>

Testdaten:		
Station:	Rendl Riffel 1 und Salzboden	
Seehöhe:	1895m und 1985m	
Subregion:	Westliche Verwallgruppe (AT-07-10)	
Exposition:	N	
Testdaten		Modell 18/19
2015-2018 <pre>> summary(test_1018\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 227 166</pre>		<pre>> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 203 23</pre> <pre>TRUE 142 24</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 57.90816</pre>
2018/19 <pre>> summary(test_1819\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 146 1</pre>		<pre>> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 135 11</pre> <pre>TRUE 1 0</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 91.83673</pre>
2019/20 <pre>> summary(test_1920\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 160 2</pre>		<pre>> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 121 21</pre> <pre>TRUE 0 0</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 85.21127</pre>

Testdaten:		
Station:	St. Veit Zischke und St. Veit Speikboden	
Seehöhe:	2115m und 2630m	
Subregion:	Östliche Rieserfernergruppe (AT-07-25)	
Exposition:	S	
Testdaten		Modell 18/19
2014-2018 <pre>> summary(test_1018\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 285 244</pre>		<pre>> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 221 54</pre> <pre>TRUE 176 66</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 55.51257</pre>
2018/19 <pre>> summary(test_1819\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 92 57</pre>		<pre>> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 75 10</pre> <pre>TRUE 48 8</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 58.86525</pre>
2019/20 <pre>> summary(test_1920\$muster)</pre> <pre>Mode FALSE NA's</pre> <pre>logical 159 23</pre>		

Testdaten:		
Station:	Valdafur und Tscheyegg	
Seehöhe:	2500m und 2668m	
Subregion:	Glockturmgruppe (AT-07-19)	
Exposition:	SW	
Testdaten		Modell 18/19
2010-2018 <pre>> summary(test_1018\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 782 321</pre>		<pre>> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 719 36</pre> <pre>TRUE 275 30</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 70.66038</pre>
2018/19 <pre>> summary(test_1819\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 126 22</pre>		<pre>> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 126 0</pre> <pre>TRUE 22 0</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 85.13514</pre>
2019/20 <pre>> summary(test_1920\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 160 2</pre>		<pre>> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5)</pre> <pre>FALSE</pre> <pre>FALSE 147</pre> <pre>TRUE 2</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 98.65772</pre>

Anhang 2.2: Modellerstellung zu gm.1, Modell 2: St. Veit

Modell 18/19	Modell 19/20																																															
<pre>> summary(train_1819\$muster)</pre> <table><tr><th>Mode</th><th>FALSE</th><th>TRUE</th><th>NA's</th></tr><tr><td>logical</td><td>92</td><td>57</td><td>35</td></tr></table>	Mode	FALSE	TRUE	NA's	logical	92	57	35	<pre>> summary(train_1920\$muster)</pre> <table><tr><th>Mode</th><th>FALSE</th><th>NA's</th></tr><tr><td>logical</td><td>159</td><td>23</td></tr></table>	Mode	FALSE	NA's	logical	159	23																																	
Mode	FALSE	TRUE	NA's																																													
logical	92	57	35																																													
Mode	FALSE	NA's																																														
logical	159	23																																														
<pre>> summary(logistic_model1819)</pre> call: glm(formula = muster ~ HS + LF + LT + WG + Differenz, family = binomial(), data = train_1819) Deviance Residuals: <table><tr><th></th><th>Min</th><th>1Q</th><th>Median</th><th>3Q</th><th>Max</th></tr><tr><td></td><td>-1.2418</td><td>-1.0365</td><td>-0.8622</td><td>1.2899</td><td>1.7254</td></tr></table> Coefficients: <table><tr><th></th><th>Estimate</th><th>Std. Error</th><th>z value</th><th>Pr(> z)</th></tr><tr><td>(Intercept)</td><td>0.669562</td><td>0.833502</td><td>0.803</td><td>0.422</td></tr><tr><td>HS</td><td>-0.001211</td><td>0.007023</td><td>-0.172</td><td>0.863</td></tr><tr><td>LF</td><td>-0.011254</td><td>0.009872</td><td>-1.140</td><td>0.254</td></tr><tr><td>LT</td><td>-0.002732</td><td>0.040216</td><td>-0.068</td><td>0.946</td></tr><tr><td>WG</td><td>-0.075519</td><td>0.071114</td><td>-1.062</td><td>0.288</td></tr><tr><td>Differenz</td><td>-0.019528</td><td>0.060226</td><td>-0.324</td><td>0.746</td></tr></table> (Dispersion parameter for binomial family taken to be 1) Null deviance: 189.46 on 140 degrees of freedom Residual deviance: 186.15 on 135 degrees of freedom (43 observations deleted due to missingness) AIC: 198.15 Number of Fisher Scoring iterations: 4			Min	1Q	Median	3Q	Max		-1.2418	-1.0365	-0.8622	1.2899	1.7254		Estimate	Std. Error	z value	Pr(> z)	(Intercept)	0.669562	0.833502	0.803	0.422	HS	-0.001211	0.007023	-0.172	0.863	LF	-0.011254	0.009872	-1.140	0.254	LT	-0.002732	0.040216	-0.068	0.946	WG	-0.075519	0.071114	-1.062	0.288	Differenz	-0.019528	0.060226	-0.324	0.746
	Min	1Q	Median	3Q	Max																																											
	-1.2418	-1.0365	-0.8622	1.2899	1.7254																																											
	Estimate	Std. Error	z value	Pr(> z)																																												
(Intercept)	0.669562	0.833502	0.803	0.422																																												
HS	-0.001211	0.007023	-0.172	0.863																																												
LF	-0.011254	0.009872	-1.140	0.254																																												
LT	-0.002732	0.040216	-0.068	0.946																																												
WG	-0.075519	0.071114	-1.062	0.288																																												
Differenz	-0.019528	0.060226	-0.324	0.746																																												
<pre>> train_1819\$pred_class <- ifelse(logistic_model1819\$fitted.values >= 0.5, "TRUE", "FALSE") > ctab_train <- table(train_1819\$muster, train_1819\$pred_class) > ctab_train</pre> <table><tr><th></th><th>FALSE</th><th>TRUE</th></tr><tr><th>FALSE</th><td>80</td><td>5</td></tr><tr><th>TRUE</th><td>51</td><td>5</td></tr></table> <pre>> > accuracy_train <- sum(diag(ctab_train))/sum(ctab_train)*100 > accuracy_train [1] 60.28369</pre>			FALSE	TRUE	FALSE	80	5	TRUE	51	5																																						
	FALSE	TRUE																																														
FALSE	80	5																																														
TRUE	51	5																																														
<pre>> Recall <- (ctab_train[2, 2]/sum(ctab_train[2,]))*100 > Recall [1] 8.928571 > TNR <- (ctab_train[1, 1]/sum(ctab_train[1,]))*100 > TNR [1] 94.11765 > Precision <- (ctab_train[2, 2]/sum(ctab_train[, 2]))*100 > Precision [1] 50 > F_Score <- (2 * Precision * Recall / (Precision + Recall))/100 > F_Score [1] 0.1515152</pre>																																																
<pre>> auc(roc)</pre> Area under the curve: 0.5935																																																

Testdaten	Modell 18/19	Modell 19/20															
2014-2018 <pre>> summary(test_1018\$muster)</pre> <table> <tr> <th>Mode</th><th>FALSE</th><th>TRUE</th></tr> <tr> <td>logical</td><td>285</td><td>244</td></tr> </table>	Mode	FALSE	TRUE	logical	285	244	<pre>> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5)</pre> <table> <tr> <th></th><th>FALSE</th><th>TRUE</th></tr> <tr> <th>FALSE</th><td>266</td><td>9</td></tr> <tr> <th>TRUE</th><td>208</td><td>34</td></tr> </table> <pre>> > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 58.02708</pre>		FALSE	TRUE	FALSE	266	9	TRUE	208	34	
Mode	FALSE	TRUE															
logical	285	244															
	FALSE	TRUE															
FALSE	266	9															
TRUE	208	34															
2018/19																	
2019/20																	

Anhang 2.3: Modellerstellung zu gm.1, Modell 3: Mosesgipfel

Modell 18/19	Modell 19/20																																													
<pre>> summary(train_1819\$muster)</pre> <table><tr><th>Mode</th><th>FALSE</th><th>TRUE</th><th>NA's</th></tr><tr><td>logical</td><td>99</td><td>50</td><td>35</td></tr></table>	Mode	FALSE	TRUE	NA's	logical	99	50	35	<pre>> summary(train_1920\$muster)</pre> <table><tr><th>Mode</th><th>FALSE</th><th>NA's</th></tr><tr><td>logical</td><td>156</td><td>26</td></tr></table>	Mode	FALSE	NA's	logical	156	26																															
Mode	FALSE	TRUE	NA's																																											
logical	99	50	35																																											
Mode	FALSE	NA's																																												
logical	156	26																																												
<pre>> summary(logistic_model1819)</pre> Call: glm(formula = muster ~ HS + LF + LT + WG + Differenz, family = binomial(), data = train_1819) Deviance Residuals: <table><tr><th>Min</th><th>1Q</th><th>Median</th><th>3Q</th><th>Max</th></tr><tr><td>-1.3201</td><td>-0.9253</td><td>-0.7318</td><td>1.2203</td><td>1.7873</td></tr></table> Coefficients: <table><tr><th></th><th>Estimate</th><th>Std. Error</th><th>z value</th><th>Pr(> z)</th></tr><tr><td>(Intercept)</td><td>-0.282282</td><td>0.841998</td><td>-0.335</td><td>0.737</td></tr><tr><td>HS</td><td>0.006820</td><td>0.006296</td><td>1.083</td><td>0.279</td></tr><tr><td>LF</td><td>-0.007545</td><td>0.008433</td><td>-0.895</td><td>0.371</td></tr><tr><td>LT</td><td>0.047220</td><td>0.043687</td><td>1.081</td><td>0.280</td></tr><tr><td>WG</td><td>-0.055578</td><td>0.068461</td><td>-0.812</td><td>0.417</td></tr><tr><td>Differenz</td><td>-0.025667</td><td>0.062239</td><td>-0.412</td><td>0.680</td></tr></table> (Dispersion parameter for binomial family taken to be 1) Null deviance: 190.14 on 148 degrees of freedom Residual deviance: 182.57 on 143 degrees of freedom (35 observations deleted due to missingness) AIC: 194.57 Number of Fisher Scoring iterations: 4		Min	1Q	Median	3Q	Max	-1.3201	-0.9253	-0.7318	1.2203	1.7873		Estimate	Std. Error	z value	Pr(> z)	(Intercept)	-0.282282	0.841998	-0.335	0.737	HS	0.006820	0.006296	1.083	0.279	LF	-0.007545	0.008433	-0.895	0.371	LT	0.047220	0.043687	1.081	0.280	WG	-0.055578	0.068461	-0.812	0.417	Differenz	-0.025667	0.062239	-0.412	0.680
Min	1Q	Median	3Q	Max																																										
-1.3201	-0.9253	-0.7318	1.2203	1.7873																																										
	Estimate	Std. Error	z value	Pr(> z)																																										
(Intercept)	-0.282282	0.841998	-0.335	0.737																																										
HS	0.006820	0.006296	1.083	0.279																																										
LF	-0.007545	0.008433	-0.895	0.371																																										
LT	0.047220	0.043687	1.081	0.280																																										
WG	-0.055578	0.068461	-0.812	0.417																																										
Differenz	-0.025667	0.062239	-0.412	0.680																																										
<pre>> train_1819\$pred_class <- ifelse(logistic_model1819\$fitted.values >= 0.5, "TRUE", "FALSE") > ctab_train <- table(train_1819\$muster, train_1819\$pred_class) > ctab_train</pre> <table><tr><th></th><th>FALSE</th><th>TRUE</th></tr><tr><th>FALSE</th><td>94</td><td>5</td></tr><tr><th>TRUE</th><td>44</td><td>6</td></tr></table> <pre>> > accuracy_train <- sum(diag(ctab_train))/sum(ctab_train)*100 > accuracy_train [1] 67.11409</pre>			FALSE	TRUE	FALSE	94	5	TRUE	44	6																																				
	FALSE	TRUE																																												
FALSE	94	5																																												
TRUE	44	6																																												
<pre>> Recall <- (ctab_train[2, 2])/sum(ctab_train[2,])*100 > Recall [1] 12 > TNR <- (ctab_train[1, 1])/sum(ctab_train[1,])*100 > TNR [1] 94.94949 > Precision <- (ctab_train[2, 2])/sum(ctab_train[, 2])*100 > Precision [1] 54.54545 > F_Score <- (2 * Precision * Recall / (Precision + Recall))/100 > F_Score [1] 0.1967213</pre>																																														
<pre>> auc(roc)</pre> Area under the curve: 0.6315																																														

Anhang 2.4: Modellerstellung zu gm.2, Modell 1: Mosesgipfel

Modell 18/19	Modell 19/20																																																																																																				
<pre>> summary(train_1819\$muster)</pre> <table><tr><th>Mode</th><th>FALSE</th><th>TRUE</th><th>NA's</th></tr><tr><td>logical</td><td>103</td><td>46</td><td>35</td></tr></table>	Mode	FALSE	TRUE	NA's	logical	103	46	35	<pre>> summary(train_1920\$muster)</pre> <table><tr><th>Mode</th><th>FALSE</th><th>TRUE</th><th>NA's</th></tr><tr><td>logical</td><td>91</td><td>65</td><td>26</td></tr></table>	Mode	FALSE	TRUE	NA's	logical	91	65	26																																																																																				
Mode	FALSE	TRUE	NA's																																																																																																		
logical	103	46	35																																																																																																		
Mode	FALSE	TRUE	NA's																																																																																																		
logical	91	65	26																																																																																																		
<pre>> summary(logistic_model1819)</pre> Call: glm(formula = muster ~ HS + LF + LT + WG + GS + Differenz, family = binomial(), data = train_1819) Deviance Residuals: <table><tr><th>Min</th><th>1Q</th><th>Median</th><th>3Q</th><th>Max</th></tr><tr><td>-1.9841</td><td>-0.8847</td><td>-0.4067</td><td>0.8380</td><td>2.0400</td></tr></table> Coefficients: <table><tr><th></th><th>Estimate</th><th>Std. Error</th><th>z value</th><th>Pr(> z)</th></tr><tr><td>(Intercept)</td><td>-2.875575</td><td>1.219304</td><td>-2.358</td><td>0.0184 *</td></tr><tr><td>HS</td><td>0.049483</td><td>0.010487</td><td>4.719</td><td>2.37e-06 ***</td></tr><tr><td>LF</td><td>-0.011351</td><td>0.009679</td><td>-1.173</td><td>0.2409</td></tr><tr><td>LT</td><td>-0.019213</td><td>0.054149</td><td>-0.355</td><td>0.7227</td></tr><tr><td>WG</td><td>0.017640</td><td>0.080328</td><td>0.220</td><td>0.8262</td></tr><tr><td>GS</td><td>-0.007684</td><td>0.003753</td><td>-2.047</td><td>0.0407 *</td></tr><tr><td>Differenz</td><td>-0.113925</td><td>0.071422</td><td>-1.595</td><td>0.1107</td></tr></table> --- Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1 (Dispersion parameter for binomial family taken to be 1) Null deviance: 184.19 on 148 degrees of freedom Residual deviance: 148.31 on 142 degrees of freedom (35 observations deleted due to missingness) AIC: 162.31 Number of Fisher Scoring iterations: 5	Min	1Q	Median	3Q	Max	-1.9841	-0.8847	-0.4067	0.8380	2.0400		Estimate	Std. Error	z value	Pr(> z)	(Intercept)	-2.875575	1.219304	-2.358	0.0184 *	HS	0.049483	0.010487	4.719	2.37e-06 ***	LF	-0.011351	0.009679	-1.173	0.2409	LT	-0.019213	0.054149	-0.355	0.7227	WG	0.017640	0.080328	0.220	0.8262	GS	-0.007684	0.003753	-2.047	0.0407 *	Differenz	-0.113925	0.071422	-1.595	0.1107	<pre>> summary(logistic_model1920)</pre> Call: glm(formula = muster ~ HS + LF + LT + WG + GS + Differenz, family = binomial(), data = train_1920) Deviance Residuals: <table><tr><th>Min</th><th>1Q</th><th>Median</th><th>3Q</th><th>Max</th></tr><tr><td>-1.7143</td><td>-0.9443</td><td>-0.5299</td><td>0.9693</td><td>2.0801</td></tr></table> Coefficients: <table><tr><th></th><th>Estimate</th><th>Std. Error</th><th>z value</th><th>Pr(> z)</th></tr><tr><td>(Intercept)</td><td>-0.963312</td><td>1.187393</td><td>-0.811</td><td>0.41720</td></tr><tr><td>HS</td><td>0.023575</td><td>0.008517</td><td>2.768</td><td>0.00564 **</td></tr><tr><td>LF</td><td>-0.004058</td><td>0.008196</td><td>-0.495</td><td>0.62050</td></tr><tr><td>LT</td><td>0.244398</td><td>0.060252</td><td>4.056</td><td>4.99e-05 ***</td></tr><tr><td>WG</td><td>-0.109664</td><td>0.086079</td><td>-1.274</td><td>0.20267</td></tr><tr><td>GS</td><td>-0.002390</td><td>0.002359</td><td>-1.013</td><td>0.31084</td></tr><tr><td>Differenz</td><td>-0.145325</td><td>0.066720</td><td>-2.178</td><td>0.02940 *</td></tr></table> --- Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1 (Dispersion parameter for binomial family taken to be 1) Null deviance: 211.91 on 155 degrees of freedom Residual deviance: 182.50 on 149 degrees of freedom (26 observations deleted due to missingness) AIC: 196.5 Number of Fisher Scoring iterations: 4	Min	1Q	Median	3Q	Max	-1.7143	-0.9443	-0.5299	0.9693	2.0801		Estimate	Std. Error	z value	Pr(> z)	(Intercept)	-0.963312	1.187393	-0.811	0.41720	HS	0.023575	0.008517	2.768	0.00564 **	LF	-0.004058	0.008196	-0.495	0.62050	LT	0.244398	0.060252	4.056	4.99e-05 ***	WG	-0.109664	0.086079	-1.274	0.20267	GS	-0.002390	0.002359	-1.013	0.31084	Differenz	-0.145325	0.066720	-2.178	0.02940 *
Min	1Q	Median	3Q	Max																																																																																																	
-1.9841	-0.8847	-0.4067	0.8380	2.0400																																																																																																	
	Estimate	Std. Error	z value	Pr(> z)																																																																																																	
(Intercept)	-2.875575	1.219304	-2.358	0.0184 *																																																																																																	
HS	0.049483	0.010487	4.719	2.37e-06 ***																																																																																																	
LF	-0.011351	0.009679	-1.173	0.2409																																																																																																	
LT	-0.019213	0.054149	-0.355	0.7227																																																																																																	
WG	0.017640	0.080328	0.220	0.8262																																																																																																	
GS	-0.007684	0.003753	-2.047	0.0407 *																																																																																																	
Differenz	-0.113925	0.071422	-1.595	0.1107																																																																																																	
Min	1Q	Median	3Q	Max																																																																																																	
-1.7143	-0.9443	-0.5299	0.9693	2.0801																																																																																																	
	Estimate	Std. Error	z value	Pr(> z)																																																																																																	
(Intercept)	-0.963312	1.187393	-0.811	0.41720																																																																																																	
HS	0.023575	0.008517	2.768	0.00564 **																																																																																																	
LF	-0.004058	0.008196	-0.495	0.62050																																																																																																	
LT	0.244398	0.060252	4.056	4.99e-05 ***																																																																																																	
WG	-0.109664	0.086079	-1.274	0.20267																																																																																																	
GS	-0.002390	0.002359	-1.013	0.31084																																																																																																	
Differenz	-0.145325	0.066720	-2.178	0.02940 *																																																																																																	
<pre>> train_1819\$pred_class <- ifelse(logistic_model1819\$fitted.values >= 0.5, "TRUE", "FALSE") > ctab_train <- table(train_1819\$muster, train_1819\$pred_class) > ctab_train</pre> <table><tr><th></th><th>FALSE</th><th>TRUE</th></tr><tr><th>FALSE</th><td>92</td><td>11</td></tr><tr><th>TRUE</th><td>31</td><td>15</td></tr></table> <pre>> > accuracy_train <- sum(diag(ctab_train))/sum(ctab_train)*100 > accuracy_train [1] 71.81208</pre>		FALSE	TRUE	FALSE	92	11	TRUE	31	15	<pre>> train_1920\$pred_class <- ifelse(logistic_model1920\$fitted.values >= 0.5, "TRUE", "FALSE") > ctab_train <- table(train_1920\$muster, train_1920\$pred_class) > ctab_train</pre> <table><tr><th></th><th>FALSE</th><th>TRUE</th></tr><tr><th>FALSE</th><td>67</td><td>24</td></tr><tr><th>TRUE</th><td>24</td><td>41</td></tr></table> <pre>> > accuracy_train <- sum(diag(ctab_train))/sum(ctab_train)*100 > accuracy_train [1] 69.23077</pre>		FALSE	TRUE	FALSE	67	24	TRUE	24	41																																																																																		
	FALSE	TRUE																																																																																																			
FALSE	92	11																																																																																																			
TRUE	31	15																																																																																																			
	FALSE	TRUE																																																																																																			
FALSE	67	24																																																																																																			
TRUE	24	41																																																																																																			
<pre>> Recall <- (ctab_train[2, 2]/sum(ctab_train[2,]))*100 > Recall [1] 32.6087 > TNR <- (ctab_train[1, 1]/sum(ctab_train[1,]))*100 > TNR [1] 89.32039 > Precision <- (ctab_train[2, 2]/sum(ctab_train[, 2]))*100 > Precision [1] 57.69231 > F_Score <- (2 * Precision * Recall / (Precision + Recall))/100 > F_Score [1] 0.4166667</pre>	<pre>> Recall <- (ctab_train[2, 2]/sum(ctab_train[2,]))*100 > Recall [1] 63.07692 > TNR <- (ctab_train[1, 1]/sum(ctab_train[1,]))*100 > TNR [1] 73.62637 > Precision <- (ctab_train[2, 2]/sum(ctab_train[, 2]))*100 > Precision [1] 63.07692 > F_Score <- (2 * Precision * Recall / (Precision + Recall))/100 > F_Score [1] 0.6307692</pre>																																																																																																				
<pre>> auc(roc)</pre> Area under the curve: 0.7799	<pre>> auc(roc)</pre> Area under the curve: 0.7461																																																																																																				

Testdaten	Modell 18/19	Modell 19/20															
2018/19 <pre>> summary(test_1819\$muster)</pre> <table> <tr> <th>Mode</th><th>FALSE</th><th>TRUE</th></tr> <tr> <td>logical</td><td>103</td><td>46</td></tr> </table>	Mode	FALSE	TRUE	logical	103	46		<pre>> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5)</pre> <table> <tr> <th></th><th>FALSE</th><th>TRUE</th></tr> <tr> <th>FALSE</th><td>78</td><td>25</td></tr> <tr> <th>TRUE</th><td>33</td><td>13</td></tr> </table> <pre>> > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 61.07383</pre>		FALSE	TRUE	FALSE	78	25	TRUE	33	13
Mode	FALSE	TRUE															
logical	103	46															
	FALSE	TRUE															
FALSE	78	25															
TRUE	33	13															
2019/20 <pre>> summary(test_1920\$muster)</pre> <table> <tr> <th>Mode</th><th>FALSE</th><th>TRUE</th></tr> <tr> <td>logical</td><td>91</td><td>65</td></tr> </table>	Mode	FALSE	TRUE	logical	91	65	<pre>> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5)</pre> <table> <tr> <th></th><th>FALSE</th><th>TRUE</th></tr> <tr> <th>FALSE</th><td>49</td><td>42</td></tr> <tr> <th>TRUE</th><td>28</td><td>37</td></tr> </table> <pre>> > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 55.12821</pre>		FALSE	TRUE	FALSE	49	42	TRUE	28	37	
Mode	FALSE	TRUE															
logical	91	65															
	FALSE	TRUE															
FALSE	49	42															
TRUE	28	37															

Testdaten:		
Station:	Magdeburger Hütte und Hechenberg	
Seehöhe:	1646m und 1922m	
Subregion:	Karwendel (AT-07-4)	
Exposition:	NW	
Testdaten	Modell 18/19	Modell 19/20
2014-2018 > summary(test_1018\$muster) Mode FALSE TRUE logical 358 171	> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5) FALSE TRUE FALSE 313 45 TRUE 141 29 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 64.77273	> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5) FALSE TRUE FALSE 300 58 TRUE 127 43 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 64.96212
2018/19 > summary(test_1819\$muster) Mode FALSE TRUE logical 28 118	> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5) FALSE TRUE FALSE 10 18 TRUE 37 81 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 62.32877	> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5) FALSE TRUE FALSE 14 14 TRUE 29 89 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 70.54795
2019/20 > summary(test_1920\$muster) Mode FALSE TRUE logical 94 67	> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5) FALSE TRUE FALSE 90 4 TRUE 67 0 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 55.90062	> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5) FALSE TRUE FALSE 71 23 TRUE 44 23 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 58.38509

Testdaten:		
Station:	Nachtweide und Palinkopf	
Seehöhe:	2030m und 2864m	
Subregion:	Samnaungruppe (AT-07-13)	
Exposition:	W	
Testdaten	Modell 18/19	Modell 19/20
2010-2018 > summary(test_1018\$muster) Mode FALSE TRUE logical 696 407	> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5) FALSE TRUE FALSE 428 266 TRUE 216 186 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 56.0219	> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5) FALSE TRUE FALSE 550 144 TRUE 284 118 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 60.94891
2018/19 > summary(test_1819\$muster) Mode FALSE TRUE logical 35 113	> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5) FALSE TRUE FALSE 7 28 TRUE 7 106 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 76.35135	> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5) FALSE TRUE FALSE 24 11 TRUE 44 69 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 62.83784
2019/20 > summary(test_1920\$muster) Mode FALSE TRUE logical 96 66	> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5) FALSE TRUE FALSE 46 50 TRUE 35 21 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 44.07895	> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5) FALSE TRUE FALSE 72 24 TRUE 27 29 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 66.44737

Testdaten:		
Station:	Tuxerjoch Schneestation und Tuxerjoch Windstation	
Seehöhe:	2380m und 2518m	
Subregion:	Westliche Tuxer Alpen (AT-07-15)	
Exposition:	NO	
Testdaten	Modell 18/19	Modell 19/20
2012-2018 <pre>> summary(test_1018\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 520 302</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 419 83</pre> <pre>TRUE 230 47</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 59.82028</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 472 30</pre> <pre>TRUE 248 29</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 64.31322</pre>
2018/19 <pre>> summary(test_1819\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 46 100</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 25 21</pre> <pre>TRUE 2 97</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 84.13793</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 40 6</pre> <pre>TRUE 44 55</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 65.51724</pre>
2019/20 <pre>> summary(test_1920\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 96 66</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 91 1</pre> <pre>TRUE 55 1</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 62.16216</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 91 1</pre> <pre>TRUE 52 4</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 64.18919</pre>

Testdaten:		
Station:	Rendl Riffel 1 und Salzboden	
Seehöhe:	1895m und 1985m	
Subregion:	Westliche Verwallgruppe (AT-07-10)	
Exposition:	N	
Testdaten	Modell 18/19	Modell 19/20
2015-2018 <pre>> summary(test_1018\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 256 137</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 148 107</pre> <pre>TRUE 61 76</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 57.14286</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 147 108</pre> <pre>TRUE 56 81</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 58.16327</pre>
2018/19 <pre>> summary(test_1819\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 29 118</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 11 18</pre> <pre>TRUE 16 102</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 76.87075</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 13 16</pre> <pre>TRUE 32 86</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 67.34694</pre>
2019/20 <pre>> summary(test_1920\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 96 66</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 52 32</pre> <pre>TRUE 43 15</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 47.1831</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 48 36</pre> <pre>TRUE 33 25</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 51.40845</pre>

Testdaten:		
Station:	St. Veit Zischke und St. Veit Speikboden	
Seehöhe:	2115m und 2630m	
Subregion:	Östliche Rieserfernergruppe (AT-07-25)	
Exposition:	S	
Testdaten	Modell 18/19	Modell 19/20
2014-2018 <pre>> summary(test_1018\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 358 171</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 290 58</pre> <pre>TRUE 120 49</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 65.5706</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 319 29</pre> <pre>TRUE 124 45</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 70.40619</pre>
2018/19 <pre>> summary(test_1819\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 96 53</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 83 5</pre> <pre>TRUE 35 18</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 71.63121</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 74 14</pre> <pre>TRUE 38 15</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 63.12057</pre>
2019/20 <pre>> summary(test_1920\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 91 68</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 31 58</pre> <pre>TRUE 19 49</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 50.95541</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 54 35</pre> <pre>TRUE 17 51</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 66.87898</pre>

Testdaten:		
Station:	Valdafur und Tscheyegg	
Seehöhe:	2500m und 2668m	
Subregion:	Glockturmgruppe (AT-07-19)	
Exposition:	SW	
Testdaten	Modell 18/19	Modell 19/20
2010-2018 <pre>> summary(test_1018\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 696 407</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 511 157</pre> <pre>TRUE 255 136</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 61.09537</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 601 67</pre> <pre>TRUE 319 72</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 63.55052</pre>
2018/19 <pre>> summary(test_1819\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 55 93</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 14 41</pre> <pre>TRUE 0 93</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 72.2973</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 39 16</pre> <pre>TRUE 24 69</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 72.97297</pre>
2019/20 <pre>> summary(test_1920\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 97 65</pre>	Keine Daten zu Globalstrahlung	Keine Daten zu Globalstrahlung

Anhang 2.5: Modellerstellung zu gm.2, Modell 2: Rendl Riffel 1 und Salzboden

Modell 18/19	Modell 19/20																																																																																																				
<pre>> summary(train_1819\$muster)</pre> <table><thead><tr><th>Mode</th><th>FALSE</th><th>TRUE</th><th>NA's</th></tr></thead><tbody><tr><td>logical</td><td>29</td><td>118</td><td>35</td></tr></tbody></table>	Mode	FALSE	TRUE	NA's	logical	29	118	35	<pre>> summary(train_1920\$muster)</pre> <table><thead><tr><th>Mode</th><th>FALSE</th><th>TRUE</th><th>NA's</th></tr></thead><tbody><tr><td>logical</td><td>96</td><td>66</td><td>20</td></tr></tbody></table>	Mode	FALSE	TRUE	NA's	logical	96	66	20																																																																																				
Mode	FALSE	TRUE	NA's																																																																																																		
logical	29	118	35																																																																																																		
Mode	FALSE	TRUE	NA's																																																																																																		
logical	96	66	20																																																																																																		
<pre>> summary(logistic_model1819)</pre> call: glm(formula = muster ~ HS + LF + LT + WG + GS + Differenz, family = binomial(), data = train_1819) Deviance Residuals: <table><thead><tr><th>Min</th><th>1Q</th><th>Median</th><th>3Q</th><th>Max</th></tr></thead><tbody><tr><td>-2.1578</td><td>0.3573</td><td>0.5090</td><td>0.6580</td><td>1.2202</td></tr></tbody></table> Coefficients: <table><thead><tr><th></th><th>Estimate</th><th>Std. Error</th><th>z value</th><th>Pr(> z)</th></tr></thead><tbody><tr><td>(Intercept)</td><td>0.824141</td><td>1.187999</td><td>0.694</td><td>0.48786</td></tr><tr><td>HS</td><td>0.015234</td><td>0.005381</td><td>2.831</td><td>0.00464 **</td></tr><tr><td>LF</td><td>-0.012082</td><td>0.013861</td><td>-0.872</td><td>0.38338</td></tr><tr><td>LT</td><td>0.049986</td><td>0.057578</td><td>0.868</td><td>0.38532</td></tr><tr><td>WG</td><td>-0.087650</td><td>0.178626</td><td>-0.491</td><td>0.62364</td></tr><tr><td>GS</td><td>-0.002577</td><td>0.004147</td><td>-0.621</td><td>0.53428</td></tr><tr><td>Differenz</td><td>-0.116803</td><td>0.080342</td><td>-1.454</td><td>0.14599</td></tr></tbody></table> --- Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1 (Dispersion parameter for binomial family taken to be 1) Null deviance: 146.00 on 146 degrees of freedom Residual deviance: 132.12 on 140 degrees of freedom (35 observations deleted due to missingness) AIC: 146.12 Number of Fisher Scoring iterations: 4	Min	1Q	Median	3Q	Max	-2.1578	0.3573	0.5090	0.6580	1.2202		Estimate	Std. Error	z value	Pr(> z)	(Intercept)	0.824141	1.187999	0.694	0.48786	HS	0.015234	0.005381	2.831	0.00464 **	LF	-0.012082	0.013861	-0.872	0.38338	LT	0.049986	0.057578	0.868	0.38532	WG	-0.087650	0.178626	-0.491	0.62364	GS	-0.002577	0.004147	-0.621	0.53428	Differenz	-0.116803	0.080342	-1.454	0.14599	<pre>> summary(logistic_model1920)</pre> call: glm(formula = muster ~ HS + LF + LT + WG + GS + Differenz, family = binomial(), data = train_1920) Deviance Residuals: <table><thead><tr><th>Min</th><th>1Q</th><th>Median</th><th>3Q</th><th>Max</th></tr></thead><tbody><tr><td>-2.1836</td><td>-0.8756</td><td>-0.5466</td><td>1.0105</td><td>2.0620</td></tr></tbody></table> Coefficients: <table><thead><tr><th></th><th>Estimate</th><th>Std. Error</th><th>z value</th><th>Pr(> z)</th></tr></thead><tbody><tr><td>(Intercept)</td><td>3.1842561</td><td>1.2348730</td><td>2.579</td><td>0.009920 **</td></tr><tr><td>HS</td><td>-0.0396461</td><td>0.0108051</td><td>-3.669</td><td>0.000243 ***</td></tr><tr><td>LF</td><td>-0.0057670</td><td>0.0132766</td><td>-0.434</td><td>0.664016</td></tr><tr><td>LT</td><td>0.0946963</td><td>0.0686766</td><td>1.379</td><td>0.167934</td></tr><tr><td>WG</td><td>-0.1091767</td><td>0.1845555</td><td>-0.592</td><td>0.554141</td></tr><tr><td>GS</td><td>-0.0002142</td><td>0.0030938</td><td>-0.069</td><td>0.944811</td></tr><tr><td>Differenz</td><td>-0.1003418</td><td>0.0748918</td><td>-1.340</td><td>0.180303</td></tr></tbody></table> --- Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1 (Dispersion parameter for binomial family taken to be 1) Null deviance: 192.07 on 141 degrees of freedom Residual deviance: 159.87 on 135 degrees of freedom (40 observations deleted due to missingness) AIC: 173.87 Number of Fisher Scoring iterations: 4	Min	1Q	Median	3Q	Max	-2.1836	-0.8756	-0.5466	1.0105	2.0620		Estimate	Std. Error	z value	Pr(> z)	(Intercept)	3.1842561	1.2348730	2.579	0.009920 **	HS	-0.0396461	0.0108051	-3.669	0.000243 ***	LF	-0.0057670	0.0132766	-0.434	0.664016	LT	0.0946963	0.0686766	1.379	0.167934	WG	-0.1091767	0.1845555	-0.592	0.554141	GS	-0.0002142	0.0030938	-0.069	0.944811	Differenz	-0.1003418	0.0748918	-1.340	0.180303
Min	1Q	Median	3Q	Max																																																																																																	
-2.1578	0.3573	0.5090	0.6580	1.2202																																																																																																	
	Estimate	Std. Error	z value	Pr(> z)																																																																																																	
(Intercept)	0.824141	1.187999	0.694	0.48786																																																																																																	
HS	0.015234	0.005381	2.831	0.00464 **																																																																																																	
LF	-0.012082	0.013861	-0.872	0.38338																																																																																																	
LT	0.049986	0.057578	0.868	0.38532																																																																																																	
WG	-0.087650	0.178626	-0.491	0.62364																																																																																																	
GS	-0.002577	0.004147	-0.621	0.53428																																																																																																	
Differenz	-0.116803	0.080342	-1.454	0.14599																																																																																																	
Min	1Q	Median	3Q	Max																																																																																																	
-2.1836	-0.8756	-0.5466	1.0105	2.0620																																																																																																	
	Estimate	Std. Error	z value	Pr(> z)																																																																																																	
(Intercept)	3.1842561	1.2348730	2.579	0.009920 **																																																																																																	
HS	-0.0396461	0.0108051	-3.669	0.000243 ***																																																																																																	
LF	-0.0057670	0.0132766	-0.434	0.664016																																																																																																	
LT	0.0946963	0.0686766	1.379	0.167934																																																																																																	
WG	-0.1091767	0.1845555	-0.592	0.554141																																																																																																	
GS	-0.0002142	0.0030938	-0.069	0.944811																																																																																																	
Differenz	-0.1003418	0.0748918	-1.340	0.180303																																																																																																	
<pre>> train_1819\$pred_class <- ifelse(logistic_model1819\$fitted.values >= 0.5, "TRUE", "FALSE") > ctab_train <- table(train_1819\$muster, train_1819\$pred_class) > ctab_train</pre> <table><thead><tr><th></th><th>FALSE</th><th>TRUE</th></tr></thead><tbody><tr><td>FALSE</td><td>6</td><td>23</td></tr><tr><td>TRUE</td><td>1</td><td>117</td></tr></tbody></table> <pre>> > accuracy_train <- sum(diag(ctab_train))/sum(ctab_train)*100 > accuracy_train [1] 83.67347</pre>		FALSE	TRUE	FALSE	6	23	TRUE	1	117	<pre>> train_1920\$pred_class <- ifelse(logistic_model1920\$fitted.values >= 0.5, "TRUE", "FALSE") > ctab_train <- table(train_1920\$muster, train_1920\$pred_class) > ctab_train</pre> <table><thead><tr><th></th><th>FALSE</th><th>TRUE</th></tr></thead><tbody><tr><td>FALSE</td><td>72</td><td>12</td></tr><tr><td>TRUE</td><td>26</td><td>32</td></tr></tbody></table> <pre>> > accuracy_train <- sum(diag(ctab_train))/sum(ctab_train)*100 > accuracy_train [1] 73.23944</pre>		FALSE	TRUE	FALSE	72	12	TRUE	26	32																																																																																		
	FALSE	TRUE																																																																																																			
FALSE	6	23																																																																																																			
TRUE	1	117																																																																																																			
	FALSE	TRUE																																																																																																			
FALSE	72	12																																																																																																			
TRUE	26	32																																																																																																			
<pre>> Recall <- (ctab_train[2, 2]/sum(ctab_train[2,]))*100 > Recall [1] 99.15254 > TNR <- (ctab_train[1, 1]/sum(ctab_train[1,]))*100 > TNR [1] 20.68966 > Precision <- (ctab_train[2, 2]/sum(ctab_train[, 2]))*100 > Precision [1] 83.57143 > F_Score <- (2 * Precision * Recall / (Precision + Recall))/100 > F_Score [1] 0.9069767</pre>	<pre>> Recall <- (ctab_train[2, 2]/sum(ctab_train[2,]))*100 > Recall [1] 55.17241 > TNR <- (ctab_train[1, 1]/sum(ctab_train[1,]))*100 > TNR [1] 85.71429 > Precision <- (ctab_train[2, 2]/sum(ctab_train[, 2]))*100 > Precision [1] 72.72727 > F_Score <- (2 * Precision * Recall / (Precision + Recall))/100 > F_Score [1] 0.627451</pre>																																																																																																				
<pre>> auc(roc) Area under the curve: 0.6823</pre>	<pre>> auc(roc) Area under the curve: 0.7761</pre>																																																																																																				

Testdaten	Modell 18/19	Modell 19/20																								
2015-2018 <pre>> summary(test_1018\$muster)</pre> <table> <tr> <th>Mode</th><th>FALSE</th><th>TRUE</th></tr> <tr> <td>logical</td><td>256</td><td>137</td></tr> </table>	Mode	FALSE	TRUE	logical	256	137	<pre>> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5)</pre> <table> <tr> <th></th><th>FALSE</th><th>TRUE</th></tr> <tr> <th>FALSE</th><td>19</td><td>236</td></tr> <tr> <th>TRUE</th><td>8</td><td>129</td></tr> </table> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 37.7551</pre>		FALSE	TRUE	FALSE	19	236	TRUE	8	129	<pre>> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5)</pre> <table> <tr> <th></th><th>FALSE</th><th>TRUE</th></tr> <tr> <th>FALSE</th><td>187</td><td>68</td></tr> <tr> <th>TRUE</th><td>115</td><td>22</td></tr> </table> <pre>> > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 53.31633</pre>		FALSE	TRUE	FALSE	187	68	TRUE	115	22
Mode	FALSE	TRUE																								
logical	256	137																								
	FALSE	TRUE																								
FALSE	19	236																								
TRUE	8	129																								
	FALSE	TRUE																								
FALSE	187	68																								
TRUE	115	22																								
2018/19 <pre>> summary(test_1819\$muster)</pre> <table> <tr> <th>Mode</th><th>FALSE</th><th>TRUE</th></tr> <tr> <td>logical</td><td>29</td><td>118</td></tr> </table>	Mode	FALSE	TRUE	logical	29	118		<pre>> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5)</pre> <table> <tr> <th></th><th>FALSE</th><th>TRUE</th></tr> <tr> <th>FALSE</th><td>21</td><td>8</td></tr> <tr> <th>TRUE</th><td>113</td><td>5</td></tr> </table> <pre>> > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 17.68707</pre>		FALSE	TRUE	FALSE	21	8	TRUE	113	5									
Mode	FALSE	TRUE																								
logical	29	118																								
	FALSE	TRUE																								
FALSE	21	8																								
TRUE	113	5																								
2019/20 <pre>> summary(test_1920\$muster)</pre> <table> <tr> <th>Mode</th><th>FALSE</th><th>TRUE</th></tr> <tr> <td>logical</td><td>96</td><td>66</td></tr> </table>	Mode	FALSE	TRUE	logical	96	66	<pre>> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5)</pre> <table> <tr> <th></th><th>FALSE</th><th>TRUE</th></tr> <tr> <th>FALSE</th><td>1</td><td>83</td></tr> <tr> <th>TRUE</th><td>5</td><td>53</td></tr> </table> <pre>> > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 38.02817</pre>		FALSE	TRUE	FALSE	1	83	TRUE	5	53										
Mode	FALSE	TRUE																								
logical	96	66																								
	FALSE	TRUE																								
FALSE	1	83																								
TRUE	5	53																								

Testdaten:		
Station:	Magdeburger Hütte und Hechenberg	
Seehöhe:	1646m und 1922m	
Subregion:	Karwendel (AT-07-4)	
Exposition:	NW	
Testdaten	Modell 18/19	Modell 19/20
2014-2018 > summary(test_1018\$muster) Mode FALSE TRUE logical 358 171	> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5) FALSE TRUE FALSE 174 184 TRUE 59 111 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 53.97727	> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5) FALSE TRUE FALSE 139 219 TRUE 76 94 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 44.12879
2018/19 > summary(test_1819\$muster) Mode FALSE TRUE logical 28 118	> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5) FALSE TRUE FALSE 4 24 TRUE 15 103 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 73.28767	> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5) FALSE TRUE FALSE 21 7 TRUE 89 29 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 34.24658
2019/20 > summary(test_1920\$muster) Mode FALSE TRUE logical 94 67	> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5) FALSE TRUE FALSE 26 68 TRUE 28 39 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 40.37267	> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5) FALSE TRUE FALSE 33 61 TRUE 8 59 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 57.14286

Testdaten:		
Station:	Mosesgipfel Schneestation und Mosesgipfel Windstation	
Seehöhe:	2235m und 2550m	
Subregion:	Östliche Deferegger Alpen (AT-07-27)	
Exposition:	SO	
Testdaten	Modell 18/19	Modell 19/20
2018/19 > summary(test_1819\$muster) Mode FALSE TRUE logical 103 46	> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5) FALSE TRUE FALSE 54 49 TRUE 12 34 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 59.0604	> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5) FALSE TRUE FALSE 71 32 TRUE 45 1 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 48.32215
2019/20 > summary(test_1920\$muster) Mode FALSE TRUE logical 91 65	> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5) FALSE TRUE FALSE 23 68 TRUE 4 61 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 53.84615	> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5) FALSE TRUE FALSE 83 8 TRUE 53 12 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 60.89744

Testdaten:		
Station:	Nachtweide und Palinkopf	
Seehöhe:	2030m und 2864m	
Subregion:	Samnaungruppe (AT-07-13)	
Exposition:	W	
Testdaten	Modell 18/19	Modell 19/20
2010-2018 > summary(test_1018\$muster) Mode FALSE TRUE logical 696 407	> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5) FALSE TRUE FALSE 215 479 TRUE 91 311 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 47.9927	> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5) FALSE TRUE FALSE 529 165 TRUE 357 45 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 52.37226
2018/19 > summary(test_1819\$muster) Mode FALSE TRUE logical 35 113	> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5) FALSE TRUE FALSE 8 27 TRUE 5 108 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 78.37838	> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5) FALSE TRUE FALSE 32 3 TRUE 113 0 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 21.62162
2019/20 > summary(test_1920\$muster) Mode FALSE TRUE logical 96 66	> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5) FALSE TRUE FALSE 23 73 TRUE 7 49 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 47.36842	> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5) FALSE TRUE FALSE 82 14 TRUE 44 12 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 61.84211

Testdaten:		
Station:	Tuxerjoch Schneestation und Tuxerjoch Windstation	
Seehöhe:	2380m und 2518m	
Subregion:	Westliche Tuxer Alpen (AT-07-15)	
Exposition:	NO	
Testdaten	Modell 18/19	Modell 19/20
2012-2018 > summary(test_1018\$muster) Mode FALSE TRUE logical 520 302	> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5) FALSE TRUE FALSE 293 209 TRUE 152 125 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 53.65854	> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5) FALSE TRUE FALSE 295 207 TRUE 160 117 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 52.88832
2018/19 > summary(test_1819\$muster) Mode FALSE TRUE logical 46 100	> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5) FALSE TRUE FALSE 16 30 TRUE 2 97 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 77.93103	> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5) FALSE TRUE FALSE 31 15 TRUE 99 0 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 21.37931
2019/20 > summary(test_1920\$muster) Mode FALSE TRUE logical 96 66	> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5) FALSE TRUE FALSE 66 26 TRUE 34 22 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 59.45946	> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5) FALSE TRUE FALSE 59 33 TRUE 36 20 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 53.37838

Testdaten:		
Station:	St. Veit Zischke und St. Veit Speikboden	
Seehöhe:	2115m und 2630m	
Subregion:	Östliche Rieserfernergruppe (AT-07-25)	
Exposition:	S	
Testdaten	Modell 18/19	Modell 19/20
2014-2018 <pre>> summary(test_1018\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 358 171</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 216 132</pre> <pre>TRUE 65 104</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 61.89555</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 136 212</pre> <pre>TRUE 90 79</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 41.58607</pre>
2018/19 <pre>> summary(test_1819\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 96 53</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 42 46</pre> <pre>TRUE 7 46</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 62.41135</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 50 38</pre> <pre>TRUE 49 4</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 38.29787</pre>
2019/20 <pre>> summary(test_1920\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 91 68</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 10 79</pre> <pre>TRUE 3 65</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 47.7707</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 81 8</pre> <pre>TRUE 55 13</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 59.87261</pre>

Testdaten:		
Station:	Valdafur und Tscheyegg	
Seehöhe:	2500m und 2668m	
Subregion:	Glockturmgruppe (AT-07-19)	
Exposition:	SW	
Testdaten	Modell 18/19	Modell 19/20
2010-2018 <pre>> summary(test_1018\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 696 407</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 400 268</pre> <pre>TRUE 174 217</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 58.26251</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 598 70</pre> <pre>TRUE 379 12</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 57.60151</pre>
2018/19 <pre>> summary(test_1819\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 55 93</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 10 45</pre> <pre>TRUE 0 93</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 69.59459</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 52 3</pre> <pre>TRUE 93 0</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 35.13514</pre>
2019/20 <pre>> summary(test_1920\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 97 65</pre>	Keine Daten zu Globalstrahlung	Keine Daten zu Globalstrahlung

Anhang 2.6: Modellerstellung zu gm.6, Modell 1: Tuxerjoch

Modell 18/19	Modell 19/20
<pre>> summary(train_1819\$muster) Mode FALSE TRUE NA's logical 46 100 36</pre>	<pre>> summary(train_1920\$muster) Mode FALSE TRUE NA's logical 33 129 20</pre>
<pre>> summary(logistic_model1819) Call: glm(formula = muster ~ HS + LF + LT + WG + Differenz, family = binomial(), data = train_1819) Deviance Residuals: Min 1Q Median 3Q Max -2.5134 -0.6377 0.2816 0.6931 1.8022 Coefficients: Estimate Std. Error z value Pr(> z) (Intercept) 2.236885 1.350076 1.657 0.09755 . HS -0.025091 0.008438 -2.974 0.00294 ** LF 0.002548 0.011132 0.229 0.81893 LT -0.333206 0.067748 -4.918 8.73e-07 *** WG 0.074749 0.117250 0.638 0.52379 Differenz 0.260884 0.082191 3.174 0.00150 ** --- Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1 (Dispersion parameter for binomial family taken to be 1) Null deviance: 179.62 on 144 degrees of freedom Residual deviance: 120.08 on 139 degrees of freedom (37 observations deleted due to missingness) AIC: 132.08 Number of Fisher Scoring iterations: 6</pre>	<pre>> summary(logistic_model1920) Call: glm(formula = muster ~ HS + LF + LT + WG + Differenz, family = binomial(), data = train_1920) Deviance Residuals: Min 1Q Median 3Q Max -3.1134 0.1179 0.3730 0.5950 1.5752 Coefficients: Estimate Std. Error z value Pr(> z) (Intercept) -3.45929 1.13268 -3.054 0.00226 ** HS 0.03299 0.01361 2.424 0.01535 * LF 0.02463 0.01072 2.299 0.02153 * LT -0.14842 0.03232 -4.593 4.38e-06 *** WG 0.22079 0.14800 1.492 0.13575 Differenz 0.12213 0.07379 1.655 0.09790 . --- Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1 (Dispersion parameter for binomial family taken to be 1) Null deviance: 157.07 on 147 degrees of freedom Residual deviance: 116.66 on 142 degrees of freedom (34 observations deleted due to missingness) AIC: 128.66 Number of Fisher Scoring iterations: 5</pre>
<pre>> train_1819\$pred_class <- ifelse(logistic_model1819\$fitted.values >= 0.5, 'TRUE', 'FALSE') > ctab_train <- table(train_1819\$muster, train_1819\$pred_class) > ctab_train FALSE TRUE FALSE 29 16 TRUE 11 89 > accuracy_train <- sum(diag(ctab_train))/sum(ctab_train)*100 > accuracy_train [1] 81.37931</pre>	<pre>> train_1920\$pred_class <- ifelse(logistic_model1920\$fitted.values >= 0.5, 'TRUE', 'FALSE') > ctab_train <- table(train_1920\$muster, train_1920\$pred_class) > ctab_train FALSE TRUE FALSE 13 20 TRUE 7 108 > accuracy_train <- sum(diag(ctab_train))/sum(ctab_train)*100 > accuracy_train [1] 81.75676</pre>
<pre>> Recall <- (ctab_train[2, 2]/sum(ctab_train[2,]))*100 > Recall [1] 89 > TNR <- (ctab_train[1, 1]/sum(ctab_train[1,]))*100 > TNR [1] 64.44444 > Precision <- (ctab_train[2, 2]/sum(ctab_train[, 2]))*100 > Precision [1] 84.7619 > F_Score <- (2 * Precision * Recall / (Precision + Recall))/100 > F_Score [1] 0.8682927</pre>	<pre>> Recall <- (ctab_train[2, 2]/sum(ctab_train[2,]))*100 > Recall [1] 93.91304 > TNR <- (ctab_train[1, 1]/sum(ctab_train[1,]))*100 > TNR [1] 39.39394 > Precision <- (ctab_train[2, 2]/sum(ctab_train[, 2]))*100 > Precision [1] 84.375 > F_Score <- (2 * Precision * Recall / (Precision + Recall))/100 > F_Score [1] 0.8888889</pre>
<pre>> auc(roc) Area under the curve: 0.8642</pre>	<pre>> auc(roc) Area under the curve: 0.8403</pre>

Testdaten	Modell 18/19	Modell 19/20
2010-2018 <pre>> summary(test_1018\$muster) Mode FALSE TRUE logical 395 708</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5) FALSE TRUE FALSE 32 230 TRUE 9 508 > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 69.31964</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5) FALSE TRUE FALSE 62 200 TRUE 26 491 > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 70.98845</pre>
2018/19 <pre>> summary(test_1819\$muster) Mode FALSE TRUE logical 46 100</pre>		<pre>> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5) FALSE TRUE FALSE 0 45 TRUE 1 99 > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 68.27586</pre>
2019/20 <pre>> summary(test_1920\$muster) Mode FALSE TRUE logical 33 129</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5) FALSE TRUE FALSE 3 30 TRUE 0 115 > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 79.72973</pre>	

Testdaten:		
Station:	Magdeburger Hütte und Hechenberg	
Seehöhe:	1646m und 1922m	
Subregion:	Karwendel (AT-07-4)	
Exposition:	NW	
Testdaten	Modell 18/19	Modell 19/20
2014-2018 > summary(test_1018\$muster) Mode FALSE TRUE Logical 164 365	> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5) FALSE TRUE FALSE 46 118 TRUE 28 337 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 72.40076	> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5) FALSE TRUE FALSE 101 63 TRUE 76 289 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 73.72401
2018/19 > summary(test_1819\$muster) Mode FALSE TRUE Logical 49 97	> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5) FALSE TRUE FALSE 38 11 TRUE 36 61 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 67.80822	> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5) FALSE TRUE FALSE 6 43 TRUE 8 89 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 65.06849
2019/20 > summary(test_1920\$muster) Mode FALSE TRUE Logical 32 129	> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5) FALSE TRUE FALSE 19 13 TRUE 15 114 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 82.6087	> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5) FALSE TRUE FALSE 29 3 TRUE 44 85 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 70.80745

Testdaten:		
Station:	Mosesgipfel Schneestation und Mosesgipfel Windstation	
Seehöhe:	2235m und 2550m	
Subregion:	Östliche Deferegger Alpen (AT-07-27)	
Exposition:	SO	
Testdaten	Modell 18/19	Modell 19/20
2018/19 > summary(test_1819\$muster) Mode FALSE TRUE Logical 52 97	> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5) FALSE TRUE FALSE 20 32 TRUE 3 94 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 76.51007	> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5) FALSE TRUE FALSE 1 51 TRUE 6 91 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 61.74497
2019/20 > summary(test_1920\$muster) Mode FALSE TRUE Logical 35 121	> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5) FALSE TRUE FALSE 14 21 TRUE 20 101 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 73.71795	> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5) FALSE TRUE FALSE 13 22 TRUE 2 119 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 84.61538

Testdaten:		
Station:	Nachtweide und Palinkopf	
Seehöhe:	2030m und 2864m	
Subregion:	Samnaungruppe (AT-07-13)	
Exposition:	W	
Testdaten	Modell 18/19	Modell 19/20
2010-2018 > summary(test_1018\$muster) Mode FALSE TRUE logical 395 708	> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5) FALSE TRUE FALSE 120 274 TRUE 54 651 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 70.15469	> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5) FALSE TRUE FALSE 78 316 TRUE 6 699 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 70.70064
2018/19 > summary(test_1819\$muster) Mode FALSE TRUE logical 44 104	> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5) FALSE TRUE FALSE 32 12 TRUE 23 81 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 76.35135	> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5) FALSE TRUE FALSE 0 44 TRUE 1 103 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 69.59459
2019/20 > summary(test_1920\$muster) Mode FALSE TRUE logical 34 128	> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5) FALSE TRUE FALSE 18 16 TRUE 18 100 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 77.63158	> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5) FALSE TRUE FALSE 13 21 TRUE 5 113 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 82.89474

Testdaten:		
Station:	Rendl Riffel 1 und Salzboden	
Seehöhe:	1895m und 1985m	
Subregion:	Westliche Verwallgruppe (AT-07-10)	
Exposition:	N	
Testdaten	Modell 18/19	Modell 19/20
2015-2018 > summary(test_1018\$muster) Mode FALSE TRUE logical 104 289	> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5) FALSE TRUE FALSE 61 43 TRUE 76 212 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 69.64286	> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5) FALSE TRUE FALSE 36 68 TRUE 8 280 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 80.61224
2018/19 > summary(test_1819\$muster) Mode FALSE TRUE logical 44 103	> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5) FALSE TRUE FALSE 37 7 TRUE 46 57 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 63.94558	> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5) FALSE TRUE FALSE 1 43 TRUE 5 98 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 67.34694
2019/20 > summary(test_1920\$muster) Mode FALSE TRUE logical 34 128	> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5) FALSE TRUE FALSE 13 7 TRUE 17 105 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 83.09859	> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5) FALSE TRUE FALSE 10 10 TRUE 15 107 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 82.39437

Testdaten:		
Station:	St. Veit Zischke und St. Veit Speikboden	
Seehöhe:	2115m und 2630m	
Subregion:	Östliche Rieserfernergruppe (AT-07-25)	
Exposition:	S	
Testdaten	Modell 18/19	Modell 19/20
2014-2018 <pre>> summary(test_1018\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 164 365</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 27 137</pre> <pre>TRUE 19 334</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 69.82592</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 101 63</pre> <pre>TRUE 48 305</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 78.52998</pre>
2018/19 <pre>> summary(test_1819\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 52 97</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 18 34</pre> <pre>TRUE 4 85</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 73.04965</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 15 37</pre> <pre>TRUE 10 79</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 66.66667</pre>
2019/20 <pre>> summary(test_1920\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 36 123</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 21 15</pre> <pre>TRUE 34 87</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 68.78981</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 17 19</pre> <pre>TRUE 2 119</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 66.6242</pre>

Testdaten:		
Station:	Valdafur und Tscheyegg	
Seehöhe:	2500m und 2668m	
Subregion:	Glockturmgruppe (AT-07-19)	
Exposition:	SW	
Testdaten	Modell 18/19	Modell 19/20
2010-2018 <pre>> summary(test_1018\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 395 708</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 65 325</pre> <pre>TRUE 45 625</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 65.09434</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 22 368</pre> <pre>TRUE 2 668</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 65.09434</pre>
2018/19 <pre>> summary(test_1819\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 44 104</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 33 11</pre> <pre>TRUE 23 81</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 77.02703</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 0 44</pre> <pre>TRUE 0 104</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 70.27027</pre>
2019/20 <pre>> summary(test_1920\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 34 128</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 22 12</pre> <pre>TRUE 16 99</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 81.20805</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 0 34</pre> <pre>TRUE 1 114</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 76.51007</pre>

Anhang 2.7: Modellerstellung zu gm.6, Modell 2: St. Veit

18/19	19/20
<pre>> summary(train_1819\$muster) Mode FALSE TRUE NA's logical 52 97 35</pre>	<pre>> summary(train_1920\$muster) Mode FALSE TRUE NA's logical 36 123 23</pre>
<pre>> summary(logistic_model1819) Call: glm(formula = muster ~ HS + LF + LT + WG + Differenz, family = binomial(), data = train_1819) Deviance Residuals: Min 1Q Median 3Q Max -2.1242 -0.8490 0.4023 0.7988 1.8230 Coefficients: Estimate Std. Error z value Pr(> z) (Intercept) -0.262552 1.013590 -0.259 0.795611 HS -0.018582 0.008421 -2.207 0.027332 * LF -0.002896 0.011349 0.255 0.798609 LT -0.190331 0.052851 -3.601 0.000317 *** WG -0.348821 0.098820 -3.530 0.000416 *** Differenz -0.184865 0.075866 -2.437 0.014821 * --- Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1 (Dispersion parameter for binomial family taken to be 1) Null deviance: 185.64 on 140 degrees of freedom Residual deviance: 141.95 on 135 degrees of freedom (43 observations deleted due to missingness) AIC: 153.95 Number of Fisher Scoring iterations: 5</pre>	<pre>> summary(logistic_model1920) Call: glm(formula = muster ~ HS + LF + LT + WG + Differenz, family = binomial(), data = train_1920) Deviance Residuals: Min 1Q Median 3Q Max -3.15189 0.03943 0.19364 0.51261 1.96648 Coefficients: Estimate Std. Error z value Pr(> z) (Intercept) -6.21369 2.00559 -3.098 0.001947 ** HS -0.05136 0.01541 -3.333 0.000859 *** LF -0.03041 0.01700 -1.789 0.073602 . LT -0.20520 0.09848 -2.084 0.037188 * WG -0.43929 0.20082 -2.188 0.028706 * Differenz -0.18079 0.09594 -1.884 0.059513 . --- Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1 (Dispersion parameter for binomial family taken to be 1) Null deviance: 169.067 on 156 degrees of freedom Residual deviance: 95.264 on 151 degrees of freedom (25 observations deleted due to missingness) AIC: 107.26 Number of Fisher Scoring iterations: 6</pre>
<pre>> train_1819pred_class <- ifelse(logistic_model1819\$fitted.values >= 0.5, "TRUE", "FALSE") > ctab_train <- table(train_1819\$muster, train_1819pred_class) > ctab_train FALSE TRUE FALSE 33 19 TRUE 15 74 > > accuracy_train <- sum(diag(ctab_train))/sum(ctab_train)*100 > accuracy_train [1] 75.88652</pre>	<pre>> train_1920pred_class <- ifelse(logistic_model1920\$fitted.values >= 0.5, "TRUE", "FALSE") > ctab_train <- table(train_1920\$muster, train_1920pred_class) > ctab_train FALSE TRUE FALSE 23 13 TRUE 3 118 > > accuracy_train <- sum(diag(ctab_train))/sum(ctab_train)*100 > accuracy_train [1] 89.80892</pre>
<pre>> Recall <- (ctab_train[2, 2]/sum(ctab_train[2,]))*100 > Recall [1] 83.14607 > TNR <- (ctab_train[1, 1]/sum(ctab_train[1,]))*100 > TNR [1] 63.46154 > Precision <- (ctab_train[2, 2]/sum(ctab_train[, 2]))*100 > Precision [1] 79.56989 > F_Score <- (2 * Precision * Recall / (Precision + Recall))/100 > F_Score [1] 0.8131868</pre>	<pre>> Recall <- (ctab_train[2, 2]/sum(ctab_train[2,]))*100 > Recall [1] 97.52066 > TNR <- (ctab_train[1, 1]/sum(ctab_train[1,]))*100 > TNR [1] 63.88889 > Precision <- (ctab_train[2, 2]/sum(ctab_train[, 2]))*100 > Precision [1] 90.07634 > F_Score <- (2 * Precision * Recall / (Precision + Recall))/100 > F_Score [1] 0.9365079</pre>
<pre>> auc(roc) Area under the curve: 0.8053</pre>	<pre>> auc(roc) Area under the curve: 0.8053</pre>

Testdaten	Modell 18/19	Modell 19/20
2014-2018 <pre>> summary(test_1018\$muster) Mode FALSE TRUE logical 164 365</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5) FALSE TRUE FALSE 64 100 TRUE 69 284 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 67.31141</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5) FALSE TRUE FALSE 124 40 TRUE 86 267 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 75.62863</pre>
2018/19 <pre>> summary(test_1819\$muster) Mode FALSE TRUE logical 52 97</pre>		<pre>> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5) FALSE TRUE FALSE 21 31 TRUE 14 75 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 68.08511</pre>
2019/20 <pre>> summary(test_1920\$muster) Mode FALSE TRUE logical 36 123</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5) FALSE TRUE FALSE 32 4 TRUE 61 60 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 58.59873</pre>	

Testdaten:		
Station:	Magdeburger Hütte und Hechenberg	
Seehöhe:	1646m und 1922m	
Subregion:	Karwendel (AT-07-4)	
Exposition:	NW	
Testdaten	Modell 18/19	Modell 19/20
2014-2018 > summary(test_1018\$muster) Mode FALSE TRUE logical 164 365	> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5) FALSE TRUE FALSE 82 82 TRUE 110 255 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 63.7051	> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5) FALSE TRUE FALSE 126 38 TRUE 107 258 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 72.58979
2018/19 > summary(test_1819\$muster) Mode FALSE TRUE logical 49 97	> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5) FALSE TRUE FALSE 42 7 TRUE 58 39 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 55.47945	> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5) FALSE TRUE FALSE 8 41 TRUE 14 83 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 62.32877
2019/20 > summary(test_1920\$muster) Mode FALSE TRUE logical 32 129	> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5) FALSE TRUE FALSE 25 7 TRUE 46 83 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 67.08075	> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5) FALSE TRUE FALSE 31 1 TRUE 66 63 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 58.3509

Testdaten:		
Station:	Mosesgipfel Schneestation und Mosesgipfel Windstation	
Seehöhe:	2235m und 2550m	
Subregion:	Östliche Deferegger Alpen (AT-07-27)	
Exposition:	SO	
Testdaten	Modell 18/19	Modell 19/20
2018/19 > summary(test_1819\$muster) Mode FALSE TRUE logical 52 97	> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5) FALSE TRUE FALSE 35 17 TRUE 14 83 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 79.19463	> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5) FALSE TRUE FALSE 4 48 TRUE 11 86 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 60.40268
2019/20 > summary(test_1920\$muster) Mode FALSE TRUE logical 35 121	> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5) FALSE TRUE FALSE 25 10 TRUE 49 72 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 62.17949	> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5) FALSE TRUE FALSE 21 14 TRUE 6 115 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 87.17949

Testdaten:		
Station:	Nachtweide und Palinkopf	
Seehöhe:	2030m und 2864m	
Subregion:	Samnaungruppe (AT-07-13)	
Exposition:	W	
Testdaten	Modell 18/19	Modell 19/20
2010-2018 > summary(test_1018\$muster) Mode FALSE TRUE logical 395 708	> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5) FALSE TRUE FALSE 186 208 TRUE 115 590 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 70.60965	> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5) FALSE TRUE FALSE 126 268 TRUE 21 684 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 73.70337
2018/19 > summary(test_1819\$muster) Mode FALSE TRUE logical 44 104	> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5) FALSE TRUE FALSE 35 9 TRUE 34 70 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 70.94595	> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5) FALSE TRUE FALSE 0 44 TRUE 1 103 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 69.59459
2019/20 > summary(test_1920\$muster) Mode FALSE TRUE logical 34 128	> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5) FALSE TRUE FALSE 26 8 TRUE 27 91 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 76.97368	> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5) FALSE TRUE FALSE 21 13 TRUE 10 108 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 84.86842

Testdaten:		
Station:	Tuxerjoch Schneestation und Tuxerjoch Windstation	
Seehöhe:	2380m und 2518m	
Subregion:	Westliche Tuxer Alpen (AT-07-15)	
Exposition:	NO	
Testdaten	Modell 18/19	Modell 19/20
2010-2018 > summary(test_1018\$muster) Mode FALSE TRUE logical 395 708	> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5) FALSE TRUE FALSE 91 171 TRUE 77 440 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 68.16431	> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5) FALSE TRUE FALSE 102 160 TRUE 44 473 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 73.81258
2018/19 > summary(test_1819\$muster) Mode FALSE TRUE logical 46 100	> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5) FALSE TRUE FALSE 37 8 TRUE 30 70 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 73.7931	> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5) FALSE TRUE FALSE 0 45 TRUE 9 91 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 62.75862
2019/20 > summary(test_1920\$muster) Mode FALSE TRUE logical 33 129	> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5) FALSE TRUE FALSE 18 15 TRUE 11 104 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 82.43243	> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5) FALSE TRUE FALSE 20 13 TRUE 17 98 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 79.72973

Testdaten:		
Station:	Rendl Riffel 1 und Salzboden	
Seehöhe:	1895m und 1985m	
Subregion:	Westliche Verwallgruppe (AT-07-10)	
Exposition:	N	
Testdaten	Modell 18/19	Modell 19/20
2015-2018 > summary(test_1018\$muster) Mode FALSE TRUE logical 104 289	> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5) FALSE TRUE FALSE 91 13 TRUE 206 82 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 44.13265	> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5) FALSE TRUE FALSE 68 36 TRUE 35 253 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 81.88776
2018/19 > summary(test_1819\$muster) Mode FALSE TRUE logical 44 103	> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5) FALSE TRUE FALSE 44 0 TRUE 75 28 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 48.97959	> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5) FALSE TRUE FALSE 1 43 TRUE 12 91 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 62.58503
2019/20 > summary(test_1920\$muster) Mode FALSE TRUE logical 34 128	> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5) FALSE TRUE FALSE 18 2 TRUE 97 25 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 30.28169	> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5) FALSE TRUE FALSE 15 5 TRUE 41 81 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 67.60563

Testdaten:		
Station:	Valdafur und Tscheyegg	
Seehöhe:	2500m und 2668m	
Subregion:	Glockturmgruppe (AT-07-19)	
Exposition:	SW	
Testdaten	Modell 18/19	Modell 19/20
2010-2018 > summary(test_1018\$muster) Mode FALSE TRUE logical 395 708	> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5) FALSE TRUE FALSE 162 228 TRUE 110 560 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 68.11321	> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5) FALSE TRUE FALSE 43 347 TRUE 14 656 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 65.9434
2018/19 > summary(test_1819\$muster) Mode FALSE TRUE logical 44 104	> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5) FALSE TRUE FALSE 34 10 TRUE 44 60 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 63.51351	> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5) FALSE TRUE FALSE 0 44 TRUE 0 104 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 70.27027
2019/20 > summary(test_1920\$muster) Mode FALSE TRUE logical 34 128	> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5) FALSE TRUE FALSE 28 6 TRUE 44 71 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 66.44295	> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5) FALSE TRUE FALSE 0 34 TRUE 1 114 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 76.51007

Anhang 2.8: Modellerstellung zu gm.6, Modell 3: Rendl Riffel 1 und Salzboden

18/19	19/20
<pre>> summary(test_1819\$muster) Mode FALSE TRUE NA's logical 44 103 35</pre>	<pre>> summary(test_1920\$muster) Mode FALSE TRUE NA's logical 34 128 20</pre>
<pre>> summary(logistic_model1819) Call: glm(formula = muster ~ HS + LF + LT + WG + Differenz, family = binomial(), data = train_1819) Deviance Residuals: Min 1Q Median 3Q Max -2.6926 -0.7191 0.3540 0.7719 1.6625 Coefficients: Estimate Std. Error z value Pr(> z) (Intercept) -0.253497 1.123701 -0.226 0.821520 HS -0.004371 0.004800 -0.911 0.362537 LF -0.015382 0.012799 -1.202 0.229429 LT -0.305879 0.067185 -4.553 5.29e-06 *** WG 0.245440 0.177033 1.386 0.165623 Differenz 0.290702 0.086685 3.354 0.000798 *** --- Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1 (Dispersion parameter for binomial family taken to be 1) Null deviance: 179.42 on 146 degrees of freedom Residual deviance: 132.85 on 141 degrees of freedom (35 observations deleted due to missingness) AIC: 144.85 Number of Fisher Scoring iterations: 5</pre>	<pre>> summary(logistic_model1920) Call: glm(formula = muster ~ HS + LF + LT + WG + Differenz, family = binomial(), data = train_1920) Deviance Residuals: Min 1Q Median 3Q Max -3.0507 0.1073 0.2179 0.4903 1.1940 Coefficients: Estimate Std. Error z value Pr(> z) (Intercept) -0.35638 1.72015 -0.207 0.8359 HS 0.01012 0.01295 0.781 0.4346 LF 0.03331 0.02109 1.580 0.1142 LT -0.47517 0.11115 -4.275 1.91e-05 *** WG 0.06459 0.29565 0.218 0.8271 Differenz 0.23927 0.14107 1.696 0.0899 . --- Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1 (Dispersion parameter for binomial family taken to be 1) Null deviance: 115.444 on 141 degrees of freedom Residual deviance: 75.173 on 136 degrees of freedom (40 observations deleted due to missingness) AIC: 87.173 Number of Fisher Scoring iterations: 6</pre>
<pre>> train_1819\$pred_class <- ifelse(logistic_model1819\$fitted.values >= 0.5, "TRUE", "FALSE") > ctab_train <- table(train_1819\$muster, train_1819\$pred_class) > ctab_train FALSE TRUE FALSE 25 19 TRUE 8 95 > > accuracy_train <- sum(diag(ctab_train))/sum(ctab_train)*100 > accuracy_train [1] 81.63265</pre>	<pre>> train_1920\$pred_class <- ifelse(logistic_model1920\$fitted.values >= 0.5, "TRUE", "FALSE") > ctab_train <- table(train_1920\$muster, train_1920\$pred_class) > ctab_train FALSE TRUE FALSE 11 9 TRUE 1 121 > > accuracy_train <- sum(diag(ctab_train))/sum(ctab_train)*100 > accuracy_train [1] 92.95775</pre>
<pre>> Recall <- (ctab_train[2, 2]/sum(ctab_train[2,]))*100 > Recall [1] 92.23301 > TNR <- (ctab_train[1, 1]/sum(ctab_train[1,]))*100 > TNR [1] 56.81818 > Precision <- (ctab_train[2, 2]/sum(ctab_train[, 2]))*100 > Precision [1] 83.33333 > F_Score <- (2 * Precision * Recall / (Precision + Recall))/100 > F_Score [1] 0.875576</pre>	<pre>> Recall <- (ctab_train[2, 2]/sum(ctab_train[2,]))*100 > Recall [1] 99.18033 > TNR <- (ctab_train[1, 1]/sum(ctab_train[1,]))*100 > TNR [1] 55 > Precision <- (ctab_train[2, 2]/sum(ctab_train[, 2]))*100 > Precision [1] 93.07692 > F_Score <- (2 * Precision * Recall / (Precision + Recall))/100 > F_Score [1] 0.9603175</pre>
<pre>> auc(roc) Area under the curve: 0.8268</pre>	<pre>> auc(roc) Area under the curve: 0.8268</pre>

Testdaten	Modell 18/19	Modell 19/20
2015-2018 <pre>> summary(test_1018\$muster) Mode FALSE TRUE logical 104 289</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5) FALSE TRUE FALSE 55 49 TRUE 30 258 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 79.84694</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5) FALSE TRUE FALSE 27 77 TRUE 6 282 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 78.82653</pre>
2018/19 <pre>> summary(test_1819\$muster) Mode FALSE TRUE logical 44 103</pre>		<pre>> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5) FALSE TRUE FALSE 4 40 TRUE 0 103 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 72.78912</pre>
2019/20 <pre>> summary(test_1920\$muster) Mode FALSE TRUE logical 34 128</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5) FALSE TRUE FALSE 12 8 TRUE 17 105 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 82.39437</pre>	

Testdaten:		
Station:	Magdeburger Hütte und Hechenberg	
Seehöhe:	1646m und 1922m	
Subregion:	Karwendel (AT-07-4)	
Exposition:	NW	
Testdaten	Modell 18/19	Modell 19/20
2014-2018 <pre>> summary(test_1018\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 164 365</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 69 95</pre> <pre>TRUE 24 341</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 77.50473</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 64 100</pre> <pre>TRUE 22 343</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 76.93762</pre>
2018/19 <pre>> summary(test_1819\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 49 97</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 22 27</pre> <pre>TRUE 8 89</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 76.0274</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 21 28</pre> <pre>TRUE 1 96</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 80.13699</pre>
2019/20 <pre>> summary(test_1920\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 32 129</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 21 11</pre> <pre>TRUE 23 106</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 78.88199</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 23 9</pre> <pre>TRUE 24 105</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 79.50311</pre>

Testdaten:		
Station:	Mosesgipfel Schneestation und Mosesgipfel Windstation	
Seehöhe:	2235m und 2550m	
Subregion:	Östliche Deferegger Alpen (AT-07-27)	
Exposition:	SO	
Testdaten	Modell 18/19	Modell 19/20
2018/19 <pre>> summary(test_1819\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 52 97</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 11 41</pre> <pre>TRUE 1 96</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 71.81208</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 7 45</pre> <pre>TRUE 0 97</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 69.79866</pre>
2019/20 <pre>> summary(test_1920\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 35 121</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 13 22</pre> <pre>TRUE 5 116</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 82.69231</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 8 27</pre> <pre>TRUE 0 121</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 82.69231</pre>

Testdaten:		
Station:	Nachtweide und Palinkopf	
Seehöhe:	2030m und 2864m	
Subregion:	Samnaungruppe (AT-07-13)	
Exposition:	W	
Testdaten	Modell 18/19	Modell 19/20
2010-2018 > summary(test_1018\$muster) Mode FALSE TRUE logical 395 708	> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5) FALSE TRUE FALSE 71 323 TRUE 5 700 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 70.15469	> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5) FALSE TRUE FALSE 61 333 TRUE 6 699 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 69.15378
2018/19 > summary(test_1819\$muster) Mode FALSE TRUE logical 44 104	> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5) FALSE TRUE FALSE 12 32 TRUE 1 103 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 77.7027	> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5) FALSE TRUE FALSE 2 42 TRUE 0 104 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 71.62162
2019/20 > summary(test_1920\$muster) Mode FALSE TRUE logical 34 128	> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5) FALSE TRUE FALSE 18 16 TRUE 9 109 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 83.55263	> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5) FALSE TRUE FALSE 18 16 TRUE 4 114 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 86.84211

Testdaten:		
Station:	Tuxerjoch Schneestation und Tuxerjoch Windstation	
Seehöhe:	2380m und 2518m	
Subregion:	Westliche Tuxer Alpen (AT-07-15)	
Exposition:	NO	
Testdaten	Modell 18/19	Modell 19/20
2010-2018 > summary(test_1018\$muster) Mode FALSE TRUE logical 395 708	> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5) FALSE TRUE FALSE 24 238 TRUE 1 516 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 69.31964	> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5) FALSE TRUE FALSE 16 246 TRUE 2 515 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 68.16431
2018/19 > summary(test_1819\$muster) Mode FALSE TRUE logical 46 100	> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5) FALSE TRUE FALSE 8 37 TRUE 1 99 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 73.7931	> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5) FALSE TRUE FALSE 0 45 TRUE 0 100 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 68.96552
2019/20 > summary(test_1920\$muster) Mode FALSE TRUE logical 33 129	> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5) FALSE TRUE FALSE 7 26 TRUE 0 115 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 82.43243	> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5) FALSE TRUE FALSE 4 29 TRUE 0 115 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 80.40541

Testdaten:		
Station:	St. Veit Zischke und St. Veit Speikboden	
Seehöhe:	2115m und 2630m	
Subregion:	Östliche Rieserfernergruppe (AT-07-25)	
Exposition:	S	
Testdaten	Modell 18/19	Modell 19/20
2014-2018 > summary(test_1018\$muster) Mode FALSE TRUE logical 164 365	> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5) FALSE TRUE FALSE 47 117 TRUE 11 342 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 75.24178	> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5) FALSE TRUE FALSE 50 114 TRUE 10 343 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 76.01547
2018/19 > summary(test_1819\$muster) Mode FALSE TRUE logical 52 97	> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5) FALSE TRUE FALSE 16 36 TRUE 1 88 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 73.75887	> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5) FALSE TRUE FALSE 14 38 TRUE 1 88 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 72.34043
2019/20 > summary(test_1920\$muster) Mode FALSE TRUE logical 36 123	> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5) FALSE TRUE FALSE 21 15 TRUE 13 108 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 82.16561	> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5) FALSE TRUE FALSE 13 23 TRUE 3 118 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 83.43949

Testdaten:		
Station:	Valdafur und Tscheyegg	
Seehöhe:	2500m und 2668m	
Subregion:	Glockturmgruppe (AT-07-19)	
Exposition:	SW	
Testdaten	Modell 18/19	Modell 19/20
2010-2018 > summary(test_1018\$muster) Mode FALSE TRUE logical 395 708	> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5) FALSE TRUE FALSE 21 369 TRUE 0 670 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 65.18868	> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5) FALSE TRUE FALSE 3 387 TRUE 0 670 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 63.49057
2018/19 > summary(test_1819\$muster) Mode FALSE TRUE logical 44 104	> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5) FALSE TRUE FALSE 4 40 TRUE 1 103 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 72.2973	> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5) FALSE TRUE FALSE 0 44 TRUE 0 104 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 70.27027
2019/20 > summary(test_1920\$muster) Mode FALSE TRUE logical 34 128	> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5) FALSE TRUE FALSE 5 29 TRUE 1 114 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 79.86577	> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5) TRUE FALSE 34 TRUE 115 > > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 22.81879

Anhang 2.9: Modellerstellung zu gm.10, Modell 1: Rendl Riffel 1 und Salzboden

18/19	19/20
<pre>> summary(train_1819\$muster) Mode FALSE TRUE NA's logical 114 33 35</pre> <pre>> summary(logistic_model1819) Call: glm(formula = muster ~ HS + LF + LT + WG + GS + Differenz, family = binomial(), data = train_1819) Deviance Residuals: Min 1Q Median 3Q Max -2.0306 -0.2374 -0.0431 -0.0050 3.1962 Coefficients: Estimate Std. Error z value Pr(> z) (Intercept) -4.547e+00 2.640e+00 -1.723 0.084974 . HS 4.763e-05 1.240e-02 0.004 0.996936 . LF 1.615e-02 1.990e-02 0.812 0.417076 . LT 7.256e-01 1.935e-01 3.751 0.000176 *** WG -7.052e-01 3.080e-01 -2.290 0.022031 * GS 2.281e-02 6.809e-03 3.351 0.000806 *** Differenz -5.438e-01 1.658e-01 -3.280 0.001038 ** --- Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1 (Dispersion parameter for binomial family taken to be 1) Null deviance: 156.564 on 146 degrees of freedom Residual deviance: 57.765 on 140 degrees of freedom (35 observations deleted due to missingness) AIC: 71.765 Number of Fisher Scoring iterations: 8</pre> <pre>> ctab_train <- table(train_1819\$muster, train_1819\$pred_class) > ctab_train FALSE TRUE FALSE 107 7 TRUE 7 26</pre> <pre>> accuracy_train <- sum(diag(ctab_train))/sum(ctab_train)*100 > accuracy_train [1] 90.47619</pre> <pre>> Recall <- (ctab_train[2, 2]/sum(ctab_train[2,]))*100 > Recall [1] 78.78788 > TNR <- (ctab_train[1, 1]/sum(ctab_train[1,]))*100 > TNR [1] 93.85965 > Precision <- (ctab_train[2, 2]/sum(ctab_train[, 2]))*100 > Precision [1] 78.78788 > F_Score <- (2 * Precision * Recall / (Precision + Recall))/100 > F_Score [1] 0.7878788</pre> <pre>> auc(roc) Area under the curve: 0.962</pre>	<pre>> summary(train_1920\$muster) Mode FALSE TRUE NA's logical 126 36 20</pre> <pre>> summary(logistic_model1920) Call: glm(formula = muster ~ HS + LF + LT + WG + GS + Differenz, family = binomial(), data = train_1920) Deviance Residuals: Min 1Q Median 3Q Max -1.44912 -0.01753 -0.00329 -0.00056 2.19472 Coefficients: Estimate Std. Error z value Pr(> z) (Intercept) -21.03021 10.75906 -1.955 0.05062 . HS 0.05137 0.05109 1.006 0.31465 . LF 0.10946 0.07172 1.526 0.12694 . LT 1.22065 0.51927 2.351 0.01874 * WG -1.27598 1.27881 -0.998 0.31838 . GS 0.05985 0.02210 2.708 0.00677 ** Differenz -0.27040 0.28127 -0.961 0.33637 . --- Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1 (Dispersion parameter for binomial family taken to be 1) Null deviance: 129.027 on 141 degrees of freedom Residual deviance: 14.823 on 135 degrees of freedom (40 observations deleted due to missingness) AIC: 28.823 Number of Fisher Scoring iterations: 10</pre> <pre>> ctab_train <- table(train_1920\$muster, train_1920\$pred_class) > ctab_train FALSE TRUE FALSE 116 2 TRUE 2 22</pre> <pre>> accuracy_train <- sum(diag(ctab_train))/sum(ctab_train)*100 > accuracy_train [1] 97.1831</pre> <pre>> Recall <- (ctab_train[2, 2]/sum(ctab_train[2,]))*100 > Recall [1] 91.66667 > TNR <- (ctab_train[1, 1]/sum(ctab_train[1,]))*100 > TNR [1] 98.30508 > Precision <- (ctab_train[2, 2]/sum(ctab_train[, 2]))*100 > Precision [1] 91.66667 > F_Score <- (2 * Precision * Recall / (Precision + Recall))/100 > F_Score [1] 0.9166667</pre> <pre>> auc(roc) Area under the curve: 0.9968</pre>

Testdaten	Modell 18/19	Modell 19/20
2015-2018 <pre>> summary(test_1018\$muster) Mode FALSE TRUE logical 309 84</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5) FALSE TRUE FALSE 273 35 TRUE 22 62</pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 85.45918</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5) FALSE TRUE FALSE 267 41 TRUE 18 66</pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 84.94898</pre>
2018/19 <pre>> summary(test_1819\$muster) Mode FALSE TRUE logical 114 33</pre>		<pre>> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5) FALSE TRUE FALSE 99 15 TRUE 3 30</pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 87.7551</pre>
2019/20 <pre>> summary(test_1920\$muster) Mode FALSE TRUE logical 126 36</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5) FALSE TRUE FALSE 114 4 TRUE 3 21</pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 95.07042</pre>	

Testdaten:		
Station:	Magdeburger Hütte und Hechenberg	
Seehöhe:	1646m und 1922m	
Subregion:	Karwendel (AT-07-4)	
Exposition:	NW	
Testdaten	Modell 18/19	Modell 19/20
2014-2018 <pre>> summary(test_1018\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 416 113</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 380 35</pre> <pre>TRUE 40 73</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 85.79545</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 398 17</pre> <pre>TRUE 55 58</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 86.36364</pre>
2018/19 <pre>> summary(test_1819\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 109 37</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 104 5</pre> <pre>TRUE 15 22</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 86.30137</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 101 8</pre> <pre>TRUE 14 23</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 84.93151</pre>
2019/20 <pre>> summary(test_1920\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 125 36</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 119 6</pre> <pre>TRUE 3 33</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 94.40994</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 125 0</pre> <pre>TRUE 8 28</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 95.03106</pre>

Testdaten:		
Station:	Mosesgipfel Schneestation und Mosesgipfel Windstation	
Seehöhe:	2235m und 2550m	
Subregion:	Östliche Deferegger Alpen (AT-07-27)	
Exposition:	SO	
Testdaten	Modell 18/19	Modell 19/20
2018/19 <pre>> summary(test_1819\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 116 33</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 114 2</pre> <pre>TRUE 17 16</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 87.24832</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 110 6</pre> <pre>TRUE 16 17</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 85.2349</pre>
2019/20 <pre>> summary(test_1920\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 122 34</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 120 2</pre> <pre>TRUE 7 27</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 94.23077</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 118 4</pre> <pre>TRUE 7 27</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 92.94872</pre>

Testdaten:		
Station:	Nachtweide und Palinkopf	
Seehöhe:	2030m und 2864m	
Subregion:	Samnaungruppe (AT-07-13)	
Exposition:	W	
Testdaten	Modell 18/19	Modell 19/20
2010-2018 <pre>> summary(test_1018\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 845 258</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 820 18</pre> <pre>TRUE 141 117</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 85.4927</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 813 25</pre> <pre>TRUE 147 111</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 84.30657</pre>
2018/19 <pre>> summary(test_1819\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 115 33</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 114 1</pre> <pre>TRUE 20 13</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 85.81081</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 109 6</pre> <pre>TRUE 12 21</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 87.83784</pre>
2019/20 <pre>> summary(test_1920\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 127 35</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 115 2</pre> <pre>TRUE 7 28</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 94.07895</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 116 1</pre> <pre>TRUE 7 28</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 94.73684</pre>

Testdaten:		
Station:	Tuxerjoch Schneestation und Tuxerjoch Windstation	
Seehöhe:	2380m und 2518m	
Subregion:	Westliche Tuxer Alpen (AT-07-15)	
Exposition:	NO	
Testdaten	Modell 18/19	Modell 19/20
2012-2018 <pre>> summary(test_1018\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 637 185</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 587 8</pre> <pre>TRUE 114 70</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 84.3389</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 578 17</pre> <pre>TRUE 112 72</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 83.44031</pre>
2018/19 <pre>> summary(test_1819\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 113 33</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 111 1</pre> <pre>TRUE 21 12</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 84.82759</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 107 5</pre> <pre>TRUE 14 19</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 86.89655</pre>
2019/20 <pre>> summary(test_1920\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 126 36</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 112 0</pre> <pre>TRUE 13 23</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 91.21622</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 112 0</pre> <pre>TRUE 13 23</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 91.21622</pre>

Testdaten:		
Station:	St. Veit Zischke und St. Veit Speikboden	
Seehöhe:	2115m und 2630m	
Subregion:	Östliche Rieserfernergruppe (AT-07-25)	
Exposition:	S	
Testdaten	Modell 18/19	Modell 19/20
2014-2018 <pre>> summary(test_1018\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 416 113</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 385 19</pre> <pre>TRUE 51 62</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 86.46035</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 391 13</pre> <pre>TRUE 67 46</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 84.52611</pre>
2018/19 <pre>> summary(test_1819\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 117 32</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 104 5</pre> <pre>TRUE 14 18</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 86.52482</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 106 3</pre> <pre>TRUE 17 15</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 85.8156</pre>
2019/20 <pre>> summary(test_1920\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 125 34</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 120 3</pre> <pre>TRUE 6 28</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 94.26752</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 121 2</pre> <pre>TRUE 8 26</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 93.63057</pre>

Testdaten:		
Station:	Valdafur und Tscheyegg	
Seehöhe:	2500m und 2668m	
Subregion:	Glockturmgruppe (AT-07-19)	
Exposition:	SW	
Testdaten	Modell 18/19	Modell 19/20
2010-2018 <pre>> summary(test_1018\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 845 258</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 774 30</pre> <pre>TRUE 122 133</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 85.64684</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 670 134</pre> <pre>TRUE 64 191</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 81.30312</pre>
2018/19 <pre>> summary(test_1819\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 116 32</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 116 0</pre> <pre>TRUE 26 6</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 82.43243</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 109 7</pre> <pre>TRUE 10 22</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 88.51351</pre>
2019/20 <pre>> summary(test_1920\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 127 35</pre>		

Anhang 2.10: Modellerstellung zu gm.10, Modell 2: St. Veit

18/19	19/20
<pre>> summary(train_1819\$muster) Mode FALSE TRUE NA's logical 117 32 35</pre>	<pre>> summary(train_1920\$muster) Mode FALSE TRUE NA's logical 125 34 23</pre>
<pre>> summary(logistic_model1819) Call: glm(formula = muster ~ HS + LF + LT + WG + GS + Differenz, family = binomial(), data = train_1819) Deviance Residuals: Min 1Q Median 3Q Max -1.97793 -0.33879 -0.06519 -0.00636 2.63045 Coefficients: Estimate Std. Error z value Pr(> z) (Intercept) -6.517209 2.526585 -2.579 0.00990 ** HS 0.011599 0.017348 0.669 0.50376 LF 0.066784 0.020502 3.257 0.00112 ** LT 0.760657 0.184146 4.131 3.62e-05 *** WG -0.310574 0.158306 -1.962 0.04978 * GS 0.010539 0.005955 1.770 0.07673 . Differenz -0.206247 0.128887 -1.600 0.10955 --- Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1 (Dispersion parameter for binomial family taken to be 1) Null deviance: 151.03 on 140 degrees of freedom Residual deviance: 64.48 on 134 degrees of freedom (43 observations deleted due to missingness) AIC: 78.48 Number of Fisher Scoring iterations: 7</pre>	<pre>> summary(logistic_model1920) Call: glm(formula = muster ~ HS + LF + LT + WG + GS + Differenz, family = binomial(), data = train_1920) Deviance Residuals: Min 1Q Median 3Q Max -1.73634 -0.01121 -0.00143 -0.00004 2.08822 Coefficients: Estimate Std. Error z value Pr(> z) (Intercept) -25.52006 14.05131 -1.816 0.0693 . HS -0.01535 0.02375 -0.655 0.5125 LF 0.23042 0.12580 1.832 0.0670 . LT 1.00640 0.44924 2.240 0.0251 * WG -0.60367 0.73273 -0.824 0.4100 GS 0.07302 0.03207 2.277 0.0228 * Differenz 0.20251 0.22158 0.914 0.3607 --- Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1 (Dispersion parameter for binomial family taken to be 1) Null deviance: 164.071 on 136 degrees of freedom Residual deviance: 19.062 on 150 degrees of freedom (25 observations deleted due to missingness) AIC: 33.062 Number of Fisher Scoring iterations: 10</pre>
<pre>> train_1819\$pred_class <- ifelse(logistic_model1819\$fitted.values >= 0.5, "TRUE", "FALSE") > ctab_train <- table(train_1819\$muster, train_1819\$pred_class) > ctab_train FALSE TRUE FALSE 103 6 TRUE 7 25 > accuracy_train <- sum(diag(ctab_train))/sum(ctab_train)*100 > accuracy_train [1] 90.78014</pre>	<pre>> train_1920\$pred_class <- ifelse(logistic_model1920\$fitted.values >= 0.5, "TRUE", "FALSE") > ctab_train <- table(train_1920\$muster, train_1920\$pred_class) > ctab_train FALSE TRUE FALSE 121 2 TRUE 2 32 > accuracy_train <- sum(diag(ctab_train))/sum(ctab_train)*100 > accuracy_train [1] 97.45223</pre>
<pre>> Recall <- (ctab_train[2, 2]/sum(ctab_train[2,]))*100 > Recall [1] 78.125 > TNR <- (ctab_train[1, 1]/sum(ctab_train[1,]))*100 > TNR [1] 94.49541 > Precision <- (ctab_train[2, 2]/sum(ctab_train[, 2]))*100 > Precision [1] 80.64516 > F_Score <- (2 * Precision * Recall / (Precision + Recall))/100 > F_Score [1] 0.7936508</pre>	<pre>> Recall <- (ctab_train[2, 2]/sum(ctab_train[2,]))*100 > Recall [1] 94.11765 > TNR <- (ctab_train[1, 1]/sum(ctab_train[1,]))*100 > TNR [1] 98.37398 > Precision <- (ctab_train[2, 2]/sum(ctab_train[, 2]))*100 > Precision [1] 94.11765 > F_Score <- (2 * Precision * Recall / (Precision + Recall))/100 > F_Score [1] 0.9411765</pre>
<pre>> auc(roc) Area under the curve: 0.9501</pre>	<pre>> auc(roc) Area under the curve: 0.9964</pre>

Testdaten	Modell 18/19	Modell 19/20
2014-2018 <pre>> summary(test_1018\$muster) Mode FALSE TRUE logical 416 113</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5) FALSE TRUE FALSE 369 35 TRUE 42 71 > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 85.10638</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5) FALSE TRUE FALSE 370 34 TRUE 41 72 > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 85.49323</pre>
2018/19 <pre>> summary(test_1819\$muster) Mode FALSE TRUE logical 117 32</pre>		<pre>> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5) FALSE TRUE FALSE 101 8 TRUE 11 21 > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 86.52482</pre>
2019/20 <pre>> summary(test_1920\$muster) Mode FALSE TRUE logical 125 34</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5) FALSE TRUE FALSE 110 13 TRUE 5 29 > accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100 > accuracy_test [1] 88.53503</pre>	

Testdaten:		
Station:	Magdeburger Hütte und Hechenberg	
Seehöhe:	1646m und 1922m	
Subregion:	Karwendel (AT-07-4)	
Exposition:	NW	
Testdaten	Modell 18/19	Modell 19/20
2014-2018 <pre>> summary(test_1018\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 416 113</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 369 35</pre> <pre>TRUE 42 71</pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 85.10638</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 370 34</pre> <pre>TRUE 41 72</pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 85.49323</pre>
2018/19 <pre>> summary(test_1819\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 109 37</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 88 21</pre> <pre>TRUE 3 34</pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 83.56164</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 103 6</pre> <pre>TRUE 14 23</pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 86.30137</pre>
2019/20 <pre>> summary(test_1920\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 125 36</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 112 13</pre> <pre>TRUE 2 34</pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 90.68323</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 119 6</pre> <pre>TRUE 1 35</pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 95.65217</pre>

Testdaten:		
Station:	Mosesgipfel Schneestation und Mosesgipfel Windstation	
Seehöhe:	2235m und 2550m	
Subregion:	Östliche Deferegger Alpen (AT-07-27)	
Exposition:	SO	
Testdaten	Modell 18/19	Modell 19/20
2018/19 <pre>> summary(test_1819\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 116 33</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 110 6</pre> <pre>TRUE 11 22</pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 88.5906</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 106 10</pre> <pre>TRUE 8 25</pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 87.91946</pre>
2019/20 <pre>> summary(test_1920\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 122 34</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 111 11</pre> <pre>TRUE 6 28</pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 89.10256</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 116 6</pre> <pre>TRUE 2 32</pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 94.87179</pre>

Testdaten:		
Station:	Nachtweide und Palinkopf	
Seehöhe:	2030m und 2864m	
Subregion:	Samnaungruppe (AT-07-13)	
Exposition:	W	
Testdaten	Modell 18/19	Modell 19/20
2010-2018 <pre>> summary(test_1018\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 845 258</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 800 38</pre> <pre>TRUE 115 143</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 86.04015</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 787 51</pre> <pre>TRUE 113 145</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 85.0365</pre>
2018/19 <pre>> summary(test_1819\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 115 33</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 109 6</pre> <pre>TRUE 11 22</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 88.51351</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 110 5</pre> <pre>TRUE 13 20</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 87.83784</pre>
2019/20 <pre>> summary(test_1920\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 127 35</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 113 4</pre> <pre>TRUE 7 28</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 92.76316</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 114 3</pre> <pre>TRUE 4 31</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 95.39474</pre>

Testdaten:		
Station:	Tuxerjoch Schneestation und Tuxerjoch Windstation	
Seehöhe:	2380m und 2518m	
Subregion:	Westliche Tuxer Alpen (AT-07-15)	
Exposition:	NO	
Testdaten	Modell 18/19	Modell 19/20
2012-2018 <pre>> summary(test_1018\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 637 185</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 572 23</pre> <pre>TRUE 98 86</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 84.46727</pre>	<pre>> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 533 62</pre> <pre>TRUE 67 117</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 83.44031</pre>
2018/19 <pre>> summary(test_1819\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 113 33</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 107 5</pre> <pre>TRUE 13 20</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 87.58621</pre>	<pre>> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 106 6</pre> <pre>TRUE 13 20</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 86.89655</pre>
2019/20 <pre>> summary(test_1920\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 126 36</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 111 1</pre> <pre>TRUE 10 26</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 92.56757</pre>	<pre>> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 110 2</pre> <pre>TRUE 4 32</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 95.94595</pre>

Testdaten:		
Station:	Rendl Riffel 1 und Salzboden	
Seehöhe:	1895m und 1985m	
Subregion:	Westliche Verwallgruppe (AT-07-10)	
Exposition:	N	
		
Testdaten		Modell 18/19
2015-2018 <pre>> summary(test_1018\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 309 84</pre>		<pre>> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 241 67</pre> <pre>TRUE 17 67</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 78.57143</pre>
2018/19 <pre>> summary(test_1819\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 114 33</pre>		<pre>> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 90 24</pre> <pre>TRUE 4 29</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 80.95238</pre>
2019/20 <pre>> summary(test_1920\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 126 36</pre>		<pre>> ctab_test <- prob_test(test_1920, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 99 19</pre> <pre>TRUE 2 22</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 85.21127</pre>
		Modell 19/20
		<pre>> ctab_test <- prob_test(test_1018, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 271 37</pre> <pre>TRUE 20 64</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 85.45918</pre>
		<pre>> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 109 5</pre> <pre>TRUE 8 25</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 91.15646</pre>
		<pre>> ctab_test <- prob_test(test_1920, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 115 3</pre> <pre>TRUE 2 22</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 96.47887</pre>

Testdaten:		
Station:	Valdafur und Tscheyegg	
Seehöhe:	2500m und 2668m	
Subregion:	Glockturmgruppe (AT-07-19)	
Exposition:	SW	
		
Testdatensatz		
Modell 18/19		Modell 19/20
2010-2018: <pre>> summary(test_1018\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 845 258</pre>		<pre>> ctab_test <- prob_test(test_1018, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 759 45</pre> <pre>TRUE 115 140</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 84.89141</pre>
2018/19: <pre>> summary(test_1819\$muster)</pre> <pre>Mode FALSE TRUE</pre> <pre>logical 116 32</pre>		<pre>> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 519 285</pre> <pre>TRUE 21 234</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 71.10482</pre>
<pre>> ctab_test <- prob_test(test_1819, logistic_model1819, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 113 3</pre> <pre>TRUE 17 15</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 86.48649</pre>		<pre>> ctab_test <- prob_test(test_1819, logistic_model1920, 0.5)</pre> <pre>FALSE TRUE</pre> <pre>FALSE 112 4</pre> <pre>TRUE 12 20</pre> <pre>></pre> <pre>> accuracy_test <- sum(diag(ctab_test))/sum(ctab_test)*100</pre> <pre>> accuracy_test</pre> <pre>[1] 89.18919</pre>