

Erkennung von Hangrutschungssystemen mit Neuronalen Netzen als Grundlage für Georisikoanalysen

Zur Erlangung des akademischen Grades eines
Doktors der Naturwissenschaften
an der Fakultät für Bio- und Geowissenschaften
der
Universität Karlsruhe
genehmigte
DISSERTATION

von
Tomás Manuel Fernández-Steeger
aus
Schwäbisch Hall

2002

Tag der mündlichen Prüfung: 15.5.2002
Referent: Prof. Dr. Dr. K. Czurda
Koreferent: Prof. Dr. W. Menzel

KURZFASSUNG

Im Rahmen von Risikoanalysen spielt die Kenntnis über das Vorhandensein und die Lage von Gefahrenherden eine ganz wesentliche Rolle. Neben den bisher bekannten deterministischen und statistischen Verfahren können auch künstliche Neuronale Netze zur automatischen Gefahrenerkennung genutzt werden. Der Vorteil Neuronaler Netze liegt in ihrer Fähigkeit begründet, nichtlineare Zusammenhänge gut darzustellen und mit sehr großen Datenmengen gut zurechtzukommen.

Für die Erkennung von Hangrutschungsgebieten sind mehrere neuronale Modelle entwickelt und untersucht worden. Eine Besonderheit ist, dass die Netze verschiedene Massenbewegungstypen erkennen können. Es wird auch nicht nur die Rutschung sondern der ganze Einflussbereich der Massenbewegung erkannt. Bei der Entwicklung der Netze sind verschiedene Strategien verfolgt worden. Neben Netzen zur Rutschungserkennung sind in Reihe geschaltete Netze und nach dem MTL-Ansatz trainierte Netze untersucht worden. Dabei hat sich gezeigt, dass die einzelnen Modelle z.T. unterschiedliche Spezialisierungen entwickeln.

Bei Versuchen mit den Netzen Rutschungen in Testgebieten in den Ostalpen zu erkennen, haben die besten Netze bis zu 86% der Gebiete richtig klassifiziert. Dabei hat sich gezeigt, dass die Netze Massenbewegungen in Zusammenhang mit Wildbach- und Erosionsprozessen besonders gut erkennen können. Durch gezielte Abfragen konnten die Ergebnisse auf bis zu 89 % erhöht werden.

Schlüsselwörter: Risikoanalyse, Gefahrenerkennung, Rutschungserkennung, Massenbewegung, Rutschung, Neuronales Netz, MLP, Vorwärtsgerichtete Neuronale Netze, PROP, MTL, Salzkammergut, Stambach, Zlambach.

ABSTRACT

In the frame of risk analysis the knowledge of the existence and location of hazard zones is of major importance. Besides the traditional deterministic and statistic methods for automatic hazard analysis, the use of artificial Neural Nets is a new and interesting approach. The advantage of Neural Nets is their ability to handle non-linearities as well as large and complex data sets.

Several types of neural models have been developed and tested for landslide recognition. It is a characteristic of these Neural Nets that they are capable to recognize different types of mass movements. Not only the landslide itself but also the complete area influenced by mass movements. Various strategies have been pursued to develop the Neural Nets. Besides the standard nets for landslide recognition, also nets switched in line and nets using the MTL-approach have been trained and tested. The tests demonstrated that the different net models develop different specializations.

The best nets for landslide recognition classified up to 86% of the test sites in the Eastern Alps correctly. The tests showed that these nets are especially qualified for the detection of landslides caused by erosional and mount torrent processes. Using query techniques it has been possible to further improve the results up to 89%.

Keywords: risk analysis, hazard analysis, landslide recognition, landslide, neural net, MLP, feed forward net, RPROP, MTL, Salzkammergut, Stambach, Zlambach.

VORWORT

Die vorliegende Dissertation entstand im Rahmen des interfakultativen Graduiertenkollegs „Naturkatastrophen“ am Lehrstuhl für Angewandte Geologie in Zusammenarbeit mit dem Institut für Logik, Komplexität und Deduktionssysteme der Universität Karlsruhe (TH). Finanziell wurde die Arbeit von der Deutschen Forschungsgesellschaft (DFG) durch ein Stipendium unterstützt, wofür ich der DFG danken möchte.

Ohne die Hilfe und Unterstützung vieler Menschen wäre die Arbeit in dieser Form nicht möglich gewesen. Ich möchte mich deshalb an dieser Stelle für das mir entgegengebrachte Vertrauen und die Hilfe herzlich bedanken.

Herrn Prof. Dr. Dr. Kurt Czurda, Lehrstuhl für Angewandte Geologie, danke ich für die Betreuung meiner Arbeit und das mir entgegengebrachte Vertrauen, sowie die große Freiheit, die er mir bei der Bearbeitung des Themas gelassen hat.

Herrn Prof. Dr. Wolfram Menzel, Institut für Logik, Komplexität und Deduktionssysteme, danke ich für die Übernahme des Koreferates und besonders für die Unterstützung sowie die wertvollen Anregungen zu dieser Arbeit.

Weiterhin danke ich den Mitarbeitern vom Lehrstuhl für Angewandte Geologie für ihre Hilfe und das sehr angenehme Arbeitsklima. Besonderer Dank gilt Herrn Dr. Joachim Rohn, der nicht nur stets zu angeregten fachlichen Diskussionen mit mir bereit war, sondern mir auch mit vielen freundschaftlichen Ratschlägen zur Seite stand. Auch meinen „Leidensgenossen“ Alexander Kienzle, der das Büro mit mir teilte, und Wolf Kassebeer möchte ich für die gute und freundschaftliche Zusammenarbeit danken.

Den Mitarbeitern des Instituts für Logik, Komplexität und Deduktionssysteme danke ich für die Unterstützung bei der Entwicklung der Neuronalen Netze, und insbesondere Herrn Dr. Thomas Ragg, der mich in die Simulation Neuronaler Netze eingewiesen und viele wertvolle Hinweise gegeben hat.

An dieser Stelle möchte ich auch meine Kollegen vom Graduierten-

kolleg „Naturkatastrophen“ erwähnen. Für mich war die Zusammenarbeit und Kollegialität im Rahmen des Kollegs eine sehr wertvolle Erfahrung. Besonders die Freundschaften, die sich während des Kollegs entwickelt haben, waren eine wirkliche Bereicherung. Auch den am Kolleg beteiligten Professoren möchte ich danken, die sehr engagiert an der Entwicklung und dem Fortkommen des Kollegs gearbeitet haben und das Kolleg in seiner heutigen Form erst möglich gemacht haben.

Die vielen Freunde, die meine Promotionszeit begleitet haben, möchte ich nicht unerwähnt lassen. Ihnen allen danke ich herzlich für ihr Verständnis und ihre Unterstützung in dieser manchmal nicht einfachen Zeit.

Herzlichen Dank an meine Familie und insbesondere an meine Eltern, die mich bei der Durchführung dieser Arbeit nach Kräften unterstützt und mir den nötigen Rückhalt gegeben haben.

3 MODELL UND METHODIK.....	47
3.1 Modell	48
3.2 Datenaufbereitung (Preprocessing)	52
3.2.1 Geoinformationssysteme (GIS)	52
3.2.2 Digitales Geländemodell (DGM)	53
3.2.3 Untersuchungseinheiten („sample units“)	58
3.2.4 Auswahl der Merkmale	59
3.2.5 Codierung der Merkmale	63
3.3 Analyse	68
3.3.1 Simulation Neuronaler Netze.....	68
3.3.2 Entwicklung und Training der Neuronalen Netze	68
3.3.3 Neuronale Netz-Modelle	71
3.4 Postprocessing	75
4 ERGEBNISSE.....	77
4.1 Ergebnisse der Netze zur Rutschungserkennung.....	77
4.1.1 Einfluss der Merkmale und der Netzwerkarchitektur auf die Klassifikationsleistung.....	78
4.1.2 Einfluss der Größe der Untersuchungseinheiten(Zellen) und Anzahl der Muster auf die Klassifikationsleistung.....	82
4.1.3 Untersuchung der Eignung des Standsicher- heitsfaktors als zusätzliches Eingabemerkmale	83
4.1.4 Darstellung und geologische Interpretation der Ergebnisse im Trainings- und Validierungsgebiet Stambach.....	85
4.1.5 Vergleich und geologische Interpretation der Ergebnisse im Testgebiet Zlambach	92
4.1.6 Nachbarschaftsanalysen zur Verbesserung der Ergebnisse	97
4.1.7 Diskussion	100
4.2 Ergebnisse der in Reihe geschalteten Neuronalen Netze	101
4.2.1 Neuronale Netze zur Abbruchkantenerkennung (KNet)	101

4.2.2 Ergebnisse der in Reihe geschalteten Netze zur Rutschungserkennung im Trainingsgebiet Stambach	104
4.2.3 Ergebnisse der in Reihe geschalteten Netze zur Rutschungserkennung im Testgebiet Zlambach	109
4.2.4 Diskussion	112
4.3 Ergebnisse der nach dem MTL-Ansatz trainierten Neuronalen Netze zur Rutschungserkennung (MTLNet)	116
4.3.1 Ergebnisse im Trainings- und Validierungsgebiet Stambach	116
4.3.2 Ergebnisse im Testgebiet Zlambach	118
4.3.3 Diskussion	120
4.4 Untersuchungen zur Regularisierung	122
5 ZUSAMMENFASSUNG UND AUSBLICK.....	125
5.1 Zusammenfassung	125
5.2 Ausblick.....	129
6 LITERATURVERZEICHNIS	131
ANHANG A	139

ABBILDUNGSVERZEICHNIS

	Seite
Abb. 2-1: Vollständiges vorwärtsgerichtetes Neuronales Netz mit einer 4 - 3 - 1 Topologie. Der vierdimensionale Eingabevektor wird in der verdeckten Schicht verarbeitet und erzeugt eine eindimensionale Ausgabe (nach GUTJAHR, 1999).	6
Abb. 2-2: Logistische und symmetrische Aktivierungsfunktion. In der Nähe des Nullpunktes verhalten sich die beiden Funktionen nahezu linear. Durch hohe Aktivierung der Neuronen wird Nichtlinearität erzeugt (verändert nach ZELL 1997).	8
Abb. 2-3: Beispiele von Problemen, die bei Gradientenverfahren während des Lernens auftreten können. Links ist das Oszillieren in einem lokalen Minimum dargestellt und rechts die lange Lernzeit bei flachen Fehlerplateaus (nach ZELL, 1997).....	13
Abb. 2-4: Trennen einer Datenmenge von zweidimensionalen Vektoren mit unterschiedlich komplexen Modellen (nach BISHOP 1995).	15
Abb. 2-5: Entwicklung des quadratischen Fehlers eines Neuronalen Netzes auf einer Trainingsmenge und einer Validierungsmenge. Nach anfänglicher Abnahme steigt der Fehler auf der Validierungsmenge wieder an, sobald das Overfitting des Netzes beginnt.....	18
Abb. 2-6: Idealisieretes Blockbild einer komplexen Massenbewegung, die sich aus einer Rotationsrutschung und einem Schuttstrom zusammensetzt. (verändert nach Varnes 1978, Original im Anhang A).....	21
Abb. 2-7: Faktoren, die die Hangstabilität beeinflussen können und deren Zuordnung zu den vorbereitenden und den auslösenden Faktoren (verändert nach POPESCU, 1994).	25
Abb. 2-8: Lage der beiden Modellgebiete (Gebiet Stambach und Gebiet Zlambach) im Salzkammergut bei Bad Ischl/ Österreich.	26

Abb. 2-9: Geologische Karte der Untersuchungsgebiete (verändert nach RÖNNAU, 2001). 28

Abb. 2-10: Schematische Rekonstruktion der vermutlichen Lage der Sedimentationsräume (Faziesräume) der späteren jurassischen Einheiten des Austroalpinen Schelfs während der Trias nach MANDL (2000). Die Untersuchungsgebiete liegen in dem umrandeten Bereich (Ischl - Aussee) auf einer Schwelle im Tiefschelf (verändert und übersetzt nach MANDL, 2000). 32

Abb. 2-11: Geotechnische Karte des Untersuchungsgebietes Stambach (nach ROHN, 1991). 34

Abb. 2-12: Geotechnische Karte des Zlambachgebietes (nach RESCH, 1997). 36

Abb. 2-13: Rutschungssystem am Kleinen Zlambach. Beginnend an der Hauptabbrisskante ändert sich die Bewegungsart von Rotationsgleitung über translative Gleitungen zu fließenden Bewegungen (verändert nach RESCH, 1997). 40

Abb. 2-14: Lage der großen zusammenhängenden Rutschkessel und Rutschungssysteme im Gebiet Stambach. 42

Abb. 2-15: Lage der großen zusammenhängenden Rutschkessel und Rutschungssysteme im Gebiet Zlambach. 45

Abb. 3-1: Schematische Darstellung der Arbeitsschritte des Modells zur Erkennung von Rutschungen mit Neuronalen Netzen. Die Pfeile stellen die Datenwege dar, wobei die dicken Pfeile die Schnittstellen zur „realen“ Welt darstellen. 49

Abb. 3-2: Schematische Darstellung der Arbeitsschritte im Preprocessing. 52

Abb. 3-3: Schematische Darstellung des digitalen „geologischen“ Geländemodells (DGM) und der Informationsebenen, aus denen es sich zusammensetzt. 54

Abb. 3-4: Überführung von vektorisierten Daten in Rasterdaten. Die maximal mögliche Auflösung des Rasters wird durch die Genauigkeit der Vektordaten vorgegeben (Aufnahmegenauigkeit und Fehler). 55

Abb. 3-5: Mögliche Formate für Untersuchungseinheiten. Das TRN und TIN sind punktgestützte Verfahren, bei denen versucht wird, die Vorteile des Raster- und Vektorformates zu verbinden.	58
Abb. 3-6: Untersuchungseinheit in einem Grid. Die Merkmale bzw. Eigenschaften der Zelle werden codiert in Zeilen gespeichert. So entsteht ein für die Zelle charakteristisches Muster, das analysiert werden kann.	59
Abb. 3-7: Merkmale die als mögliche Eingabe in das Neuronale Netz-Modell getestet wurden. Die Merkmale sind wie in Abb. 2-7 dargestellt den Gruppen zugeordnet, welche die Hangstabilität beeinflussen.	61
Abb. 3-8: Codierung der Exposition durch Normalisierung mit der Cosinusfunktion. Der inverse Wert des S-Sektors und der N-Sektor werden als eigene Merkmale analysiert.	64
Abb. 3-9: Die tabellarischen, im ASCII-Format gespeicherten Musterdaten werden mit einem Perl-Script neu sortiert und in das SNNS-Format (Zell, 1997) umgewandelt.	67
Abb. 3-10: Schematische Darstellung der Arbeitsschritte bei in „Reihe geschalteten Neuronalen Netzen“.	72
Abb. 3-11: MTL-Netz, in dem mehrere Aufgaben zusammengeführt und gleichzeitig analysiert werden. Neben der Hauptaufgabe Rutschungserkennung werden auch Informationen von der Nebenaufgabe Abrisskantenerkennung bei der Optimierung der Gewichte berücksichtigt.	74
Abb. 3-12: Visualisierungsmöglichkeiten der Analyseergebnisse mit dem Desktop-GIS ArcView von ESRI.	75
Abb. 4-1: Lage der instabilen Hangbereiche (Rutschungsbereiche aus der geotechnischen Kartierung) in den Untersuchungsgebieten (unskalierte Darstellung).	77
Abb. 4-2: Große Abrissssysteme innerhalb des Stambachschuttstroms.	87
Abb. 4-3: Rutschungsanalyse für das Trainings- und Validierungsgebiet Stambach in 20 m Auflösung mit dem DNet (Netz mit Standsicherheitsfaktor).	88

Abb. 4-4: Rutschungskessel bei Riedln bzw. Hölln auf der Leitn. Die dunkel schraffierten Bereiche sind von dem Neuronalen Netz als Rutschungsbereiche erkannt worden. (Legende geotechnische Karte siehe Abb. 4-2). 89

Abb. 4-5: Rutschungssystem bei Rotmoos, das praktisch nicht erkannt wurde. Nur die dunkel schraffierten Bereiche sind vom Netz als Rutschung erkannt worden. (Legende geotechnische Karte siehe Abb. 4-2). 90

Abb. 4-6: Vergleich der Erkennung von Rutschungen in unterschiedlich "reifen" Wildbachsystemen. Links ist das sehr junge System am Schwarzenbachloch und rechts die ausgeprägten reifen Systeme südlich der Rossmoosalm zu erkennen. (schraffierte Bereiche sind als Rutschung erkannt worden). 91

Abb. 4-7: Rutschungssysteme an den steileren direkten Einhängen des Trauntals. Die schraffierten Bereiche sind als Rutschungen erkannt worden (Legende s. Abb. 4-2). 92

Abb. 4-8: Rutschungsanalyse für das Testgebiet Zlambach in 20 m Auflösung mit dem DNet (Netz mit Standsicherheitsfaktor). 93

Abb. 4-9: Rutschungskessel bei der Leislingalm. Die dunkel schraffierten Bereiche sind von dem Neuronalen Netz als Rutschungsbereiche erkannt worden. (Legende geotechnische Karte s. Abb. 4-2). 95

Abb. 4-10: Revidierte Rutschungsanalyse für das Testgebiet Zlambach in 20 m Auflösung auf der Grundlage der erweiterten Gefahrenkarte mit DNet (gleiches Netz wie in Abb. 4-8). Die Erkennungsrate erhöht sich von 70,6 % auf 82,8 %..... 96

Abb. 4-11: Ergebnis der mit Nachbarschaftsanalysen optimierten Rutschungsanalyse des DNet aus Abbildung 4-10. Die Erkennungsrate erhöht sich durch die Optimierung von 82,8 auf 83,3 %..... 98

Abb. 4-12:Ergebnis der im Postprocessing durch Abfragen optimierten Rutschungsanalyse des DNet aus Abbildung 4-10. Die Erkennungsrate erhöht sich durch die Optimierung von 82,8 auf 84,5 %.....	99
Abb. 4-13:Analyse der Abrisskantenerkennung mit dem Neuronalen Netz mit Standsicherheitsfaktor (KNet).....	103
Abb. 4-14:Abrisskantenerkennung am großen Rutschkessel des Kleinen Zlambach. Die schraffierten Bereiche sind vom Neuronalen Netz als Zellen mit Abrisskanten erkannt worden.....	104
Abb. 4-15:Rutschungsanalyse für das Trainings- und Validierungsgebiet Stambach in 20 m Auflösung mit dem RNet (in Reihe geschaltete Netze mit Standsicherheitsfaktor). Die Erkennungsrate liegt bei 85,8 %.....	106
Abb. 4-16:Als instabil erkannte Bereiche (schraffiert) in den großen Rutschkesseln bei Hölln auf der Leitn.	107
Abb. 4-17:Als instabil erkannte Bereiche (schraffiert) an einem „jungen“ noch nicht so deutlich ausgebildeten Wildbach bei Solbach nördlich von St. Agatha.....	108
Abb. 4-18:Rutschungskessel am Kleinen Zlambach. Die Schraffur zeigt den vom Netz als instabil erkannten Bereich.....	110
Abb. 4-19:Revidierte Rutschungsanalyse für das Testgebiet Zlambach auf Grundlage der erweiterten Gefahrenkarte mit RNet. Die Erkennungsrate erhöht sich von 71,2 % auf 85,4 %.....	111
Abb. 4-20:Ergebnis der im Postprocessing optimierten Rutschungsanalyse des RNet. Die Erkennungsrate erhöht sich dadurch von 85,4 % auf 88,8 %.....	112
Abb. 4-21:Vergleich der Ergebnisse von Netzen mit (RNet) und ohne Standsicherheitsfaktor (RNet) sowie unterschiedlicher Anzahl an Hiddenneuronen im Zlambachgebiet (Legende s. Abb. 4-1).....	114
Abb. 4-22:Auswertung der Klassifikation des Trainingsgebietes Stambach mit dem MTL Netz mit Standsicherheitsfaktor (DMTLNet).....	117

Abb. 4-23:Revidierte Rutschungsanalyse für das Testgebiet Zlambach
auf Grundlage der ergänzten Gefahrenkarte mit DMTLNet.
Die Erkennungsrate erhöht sich von 72,8%% auf 86,7 %.
..... 119

Abb. 4-24:Ergebnis der im Postprocessing optimierten
Rutschungsanalyse des DMTLNet. Die Erkennungsrate
erhöht sich dadurch von 86,7 % auf 89,1 %..... 120

TABELLENVERZEICHNIS

	Seite
Tab. 2.1: Typen von Massenbewegungen (verändert nach DIKAU et al., 1999, Original im Anhang A). Die hinterlegten Arten von Massenbewegungen im Lockergestein sollen von den verwendeten Neuronalen Netzen erkannt werden.	22
Tab. 2.2: Stratigraphische Tabelle der in den Untersuchungsgebieten aufgeschlossenen Einheiten mit kurzen Gesteinsbeschreibungen.	30
Tab. 2.3: Scherfestigkeit der wechselfesten Gesteine im Untersuchungsgebiet (aus ROHN 1991, HÖCHERL 1991 und XIANG 1997).	37
Tab. 3.1: Merkmale des Eingabevektors und deren Veränderung über die einzelnen Entwicklungsstufen des Modells (von evo1 bis evo 4) hinweg. Die helleren Merkmale sind in der jeweiligen Entwicklungsstufe hinzugefügt worden. In der dritten Evolutionsstufe ist das Merkmal „absolute Höhe“ später zusätzlich eingefügt worden.	62
Tab. 3.2: Codierungsart der Merkmale in dieser Arbeit und die Funktionen die zur Normalisierung der Variablen verwendet wurden.	66
Tab. 4.1: Veränderung der Klassifikationsleistung bei Netzen der 3. Entwicklungsstufe durch Veränderung der Netzarchitektur (bei gleichen Lernparametern im Stambachgebiet).	78
Tab. 4.2: Veränderung Erkennungsrate im Trainingsgebiet Stambach (ohne Schuttströme) in Abhängigkeit von Merkmalen (s. Tab. 3.1) bzw. Netzwerkarchitektur. Die Zahl in Klammern gibt das ungefähre Verhältnis von Eingabeneuronen zu Hiddenneuronen an (Untersuchungsraster 30 m).	79
Tab. 4.3: Vergleich der Erkennungsrate von Netzen, die im Trainingsgebiet Stambach (ohne Schuttströme) trainiert wurden. ...	80
Tab. 4.4: Kreuzkorrelation von besonders hoch korrelierten Merkmalen.	81

Tab. 4.5:	Klassifikationsleistung der besten Netze zur Rutschungs-erkennung (ohne Schuttströme) im Stambachgebiet bei unterschiedlichen Rasterweiten.	82
Tab. 4.6:	Klassifikationsleistung der besten Netze zur Rutschungs-erkennung (ohne Schuttströme) im Stambachgebiet mit reduzierten Trainingsdatensätzen bei unterschiedlichen Rasterweiten.	83
Tab. 4.7:	Vergleich der Erkennungsrate von Netzen ohne und mit Standsicherheitsfaktor als zusätzliches Merkmal im Gebiet Stambach (20 m Raster).....	84
Tab. 4.8:	Erkennungsrate von Netzen, die das Gebiet Stambach einmal ohne und einmal mit Schuttstrom erkennen mussten. Die Ergebnisse sind für die Netze mit (DNet) und ohne Standsicherheitsfaktor (NNet) als Merkmal dargestellt.	86
Tab. 4.9:	Erkennungsrate von Netzen im Gebiet Zlambach, die im Stambachgebiet ohne und mit Schuttstrom trainiert wurden. Die Ergebnisse sind für die Netze mit (DNet) und ohne (NNet) Standsicherheitsfaktor als Merkmal dargestellt.	94
Tab. 4.10:	Erkennungsrate der Netze zur Abbruchkantenerkennung in den beiden Untersuchungsgebieten für Netze mit (KDNet) und ohne Standsicherheitsfaktor (KNNet) bei einer 20 m Auflösung.	102
Tab. 4.11:	Erkennungsrate von in Reihe geschalteten Netzen im Gebiet Stambach. Die Ergebnisse sind für die Netze mit (RDNet) und ohne Standsicherheitsfaktor (RNNet) dargestellt.	105
Tab. 4.12:	Erkennungsrate von in Reihe geschalteten Netzen im Gebiet Zlambach für die alte Gefahrenkarte. Die Ergebnisse sind für die Netze mit (RDNet) und ohne Standsicherheitsfaktor (RNNet) dargestellt.	109
Tab. 4.13:	Erkennungsrate der mit MTL trainierten Netze im Gebiet Stambach. Die Ergebnisse sind für die Netze mit (DMTLNet) und ohne Standsicherheitsfaktor (NMTLNet) dargestellt.	117
Tab. 4.14:	Erkennungsrate der mit MTL trainierten Netze im Gebiet Zlambach. Die Ergebnisse sind für die Netze mit (DMTLNet) und ohne Standsicherheitsfaktor (NMTLNet) dargestellt, bezogen auf die alte Gefahrenkarte.	118

1 EINLEITUNG

1.1 Problemstellung

Die Häufung großer Naturkatastrophen in den letzten Jahren und der starke Anstieg der Schadenssummen initiierte 1998 die Gründung des DFG Graduiertenkollegs "Naturkatastrophen". Entsprechend der inter-fakultativen Ausrichtung des Graduiertenkollegs "Naturkatastrophen" sollen hier nicht nur Naturkatastrophen und deren Auswirkungen untersucht, sondern auch neue Ansätze im Rahmen inter-fakultativer Zusammenarbeit erprobt werden.

Unter den Naturkatastrophen stellen Massenbewegungen, entgegen dem öffentlichen Eindruck, eine nicht unerhebliche Gefahr für Menschen und Infrastruktur dar. Meistens treten diese allerdings zusammen mit anderen "grossen" Naturkatastrophen wie Erdbeben oder Gewitterstürmen (Hurrikane) auf, bzw. werden von diesen ausgelöst. Die Schäden werden deshalb irrtümlicherweise meist dem auslösenden und nicht dem eigentlichen verursachenden Ereignis zugeordnet. So entstanden viele Schäden in Venezuela während des Hurrikans Mitch 1999, bei dem vermutlich 30.000 Menschen ums Leben kamen, nicht durch den Hurrikan selbst, sondern durch die anschließenden Massenbewegungen (IFRC 2001). Bereits 1985 wurden die Kosten, welche jährlich in den Vereinigten Staaten durch Massenbewegungen entstehen, vom National Research Council auf 1,2 bis 2,4 Milliarden US-Dollar geschätzt (SCHUSTER 1996).

Allein diese Zahlen verdeutlichen schon, wie wichtig es heute ist, Gefahrenanalysen für betroffene Regionen zu erstellen, um geeignete Schutzmaßnahmen zu entwickeln. Dies ist um so bedeutender, da durch Entwaldung, Siedlungsdruck und regionale Klimaveränderungen in den nächsten Jahren eher mehr als weniger Massenbewegungen in menschlichen Siedlungsräumen auftreten werden (IDNDR 1997, SCHUSTER 1996).

Die effektivste und zugleich wirtschaftlichste Möglichkeit Gefahren durch Massenbewegungen abzuwehren ist, die gefährdeten Gebiete zu meiden und nur extensiv zu nutzen. Daraus erwächst die Notwendigkeit, großräumig Informationen über vorhandene bzw. potentielle Rutschungsgebiete zu erheben. Da dies mit der klassischen Methode, der geotechnischen Kartierung durch den Geologen zu aufwendig ist, müs-

sen Verfahren zur automatischen Erkennung von Hangrutschungsgebieten verstärkt genutzt und weiterentwickelt werden.

Aus dieser Intention heraus und entsprechend der interfakultativen Ausrichtung des Graduiertenkollegs entstand die Idee, Massenbewegungen bzw. deren Auswirkungen nicht mit den bisher bekannten statistischen und deterministischen Verfahren (s. ALEOTTI & CHOWDHURY, 1999) zu modellieren, sondern auf Methoden aus dem Bereich des "Maschinellen Lernen" zurückzugreifen. Zu dies werden je nach Betrachter z.B. Entscheidungsbäume ("decision trees"), vorwärtsgerichtete Neuronale Netze (MLP), Kohonen Netze (SOM, "Self-Organizing-Maps"), evolutionäre Algorithmen oder neuerdings auch Support Vektor Maschienen (SV, "Kernel Machines") gezählt.

Aufgrund der Problemstellung (s.u.) und des zu Beginn der Arbeit zugänglichen Wissensstandes sind die künstlichen Neuronalen Netze (KNN) und hier im besonderen die vorwärtsgerichteten Neuronalen Netze als praktikabelste, sowie erfolgversprechendste Methode zur Modellierung des Problems ausgewählt worden. Dies ist sinnvoll, da Neuronale Netze sowohl mit nichtlinearen, als auch mit sehr großen und verrauschten Datenmengen zurechtkommen. Eben diese beiden Schwierigkeiten treten insbesondere bei geologischen Modellierungen wie z.B. bei der Rutschungserkennung auf.

Auf die Untersuchung von Support Vektor Maschinen wurde hier verzichtet, da diese erst im Laufe der Arbeit verstärkt in den Fokus der Forschung traten, was aber nicht als Wertung gegenüber dieser Methode verstanden werden darf.

1.2 Zielsetzung

Im Rahmen dieser interdisziplinären Arbeit soll die Rutschungserkennung im Lockergesteinsbereich mit Verfahren aus dem Bereich des "Maschinellen Lernens", den vorwärtsgerichteten Neuronalen Netzen, untersucht werden. Darüber hinaus wurde gezielt der Ansatz verfolgt, nicht nur auf primäre Merkmale sondern auch auf sekundäre und tertiäre Merkmale zur Problemlösung zurückzugreifen, da diese in der Praxis wesentlich häufiger und in zunehmend besserer Qualität verfügbar sind. Gerade hier kommen die Vorteile der Neuronalen Netze gegenüber anderen Verfahren voll zum tragen.

Es wird die Systematik entwickelt und untersucht, die notwendig ist, bekannte Verfahren aus der Neuroinformatik auf das Problem der Rutschungserkennung anzuwenden. Durch die Zusammenarbeit mit dem Institut für Logik, Komplexität und Deduktion wird versucht, den Erfordernissen beider Disziplinen, Geologie und Informatik, gerecht zu werden und nicht übermäßiges Gewicht auf eine Herangehensweise zu legen.

Das geologische Wissen über Rutschungen und die Untersuchungsgebiete helfen, ein Verfahren zur Aufbereitung und Analyse der Daten zu entwickeln. Auf dessen Basis kann wiederum das richtige Verfahren zur Codierung ausgewählt bzw. entwickelt werden. Durch die Zusammenarbeit mit der Informatik können auch neuere Verfahren aus der Forschung eingesetzt und verschiedene Netztypen entwickelt werden. So sind nicht nur mehrschichtige vorwärtsgerichtete Netze (MLP) für die Rutschungs- bzw. Abbruchkantenerkennung benutzt worden, sondern auch in Reihe geschaltete Netze und verschiedene Lernverfahren wie RPROP und MTL untersucht worden.

Um nicht unter künstlichen und vereinfachten Rahmenbedingungen arbeiten zu müssen, wurden zwei Rutschungsgebiete in den Ostalpen ausgewählt, die sowohl ausreichend viele Rutschungen aufweisen, als auch sehr gut untersucht bzw. verstanden sind. Somit können aus den Ergebnissen der Netze auch Rückschlüsse auf Schwächen und Stärken der einzelnen Netze gezogen werden.

1.3 Aufbau und Vorgehensweise

Der Aufbau der Arbeit entspricht in etwa dem chronologischen Herangehen an die Arbeit.

Ausgangspunkt der Arbeit sind die vorwärtsgerichteten Neuronalen Netze und die Rutschungssysteme. Zu diesem Zweck werden im zweiten Kapitel die notwendigen Grundlagen, soweit sie zum Verständnis notwendig sind, an den Anfang gestellt. Darüber hinaus werden die beiden Testgebiete vorgestellt, um einen Eindruck von der Geologie und den ingenieurgeologischen Zusammenhängen zu erhalten.

Im dritten Kapitel wird die Herangehensweise und die Methodik vorgestellt, um Rutschungen mit Neuronalen Netzen erkennen zu können.

1.3 Aufbau und Vorgehensweise

Zunächst wird die Aufbereitung und Codierung der Daten beschrieben. Anschließend wird auf die Netzentwicklung und Optimierung, sowie die neuronalen Modelle, welche entwickelt wurden, eingegangen. Abschließend werden die Aufbereitungs- und Darstellungsmöglichkeiten der Ergebnisse beschrieben.

Die Anwendung und die Ergebnisse der Netze in den Untersuchungsgebieten wird im vierten Kapitel beschrieben. Dabei wird getrennt auf die Netze zur Rutschungserkennung, die in Reihe geschalteten und die mit dem Multitask Learning-Ansatz (MTL) trainierten Netze eingegangen. Auch Maßstabeffekte und Besonderheiten der einzelnen Netze werden beschrieben.

Am Ende der Arbeit werden die Ergebnisse im Hinblick auf die Eignung künstlicher Neuronaler Netze zur Rutschungserkennung und die Vor- bzw. Nachteile der einzelnen Modelle diskutiert. Im Fazit wird noch ein Ausblick auf künftige Anknüpfungspunkte gegeben.

2 GRUNDLAGEN

2.1 Neuronale Netze

Die Theorie der künstlichen Neuronalen Netze entstand aus der Idee, die biologische Informationsverarbeitung, im Besonderen das Lernen mit mathematischen Methoden zu simulieren.

Eine Definition für künstliche Neuronale Netze (kurz KNN) lautet, dass es sich um informationsverarbeitende Systeme handelt, die aus einer großen Anzahl einfacher Einheiten (Zellen bzw. Neuronen) bestehen, die sich Informationen in Form der Aktivierung von Zellen über gerichtete Verbindungen zusenden (ZELL 1997). Mathematisch ausgedrückt, erfolgt die Abbildung eines n -dimensionalen Eingabevektors x in einen m -dimensionalen Ausgabevektor y .

$$F : x \rightarrow y \quad (2.1)$$

Die gezielte Veränderung des Gesamtverhaltens von Neuronalen Netzen durch die mathematische Optimierung der Gewichte, den gewichteten Verbindungen zwischen den Neuronen, wird als Lernen bezeichnet. Vereinfacht gesagt sind Neuronale Netze Programme (Software) oder Hardware, die nach bestimmten Regeln „lernen“, Informationen zu verarbeiten. Beim Lernen ist allerdings nicht die exakte Reproduktion des Erlernten entscheidend, sondern eher das Generalisierungsverhalten. Dies bedeutet, dass die Optimierung der Gewichte so durchgeführt werden muss, dass die Netze auch in unbekanntem Situationen möglichst richtig reagieren. Es sollen also assoziative Fähigkeiten entwickelt werden und die hinter den erlernten Beispielen verborgenen Gesetzmäßigkeiten erkannt werden.

Die Vorteile von Neuronalen Netzen liegen einerseits in ihrer Fähigkeit, auch nichtlineare Zusammenhänge sehr gut darstellen zu können, und andererseits in ihrer Robustheit gegen Störungen und verrauschte Daten.

Im Folgenden wird die bekannteste und auch hier verwendete Klasse Neuronaler Netze beschrieben, das mehrschichtige vorwärtsgerichtete Neuronale Netz, auch MLP (Multi Layer Perceptron) genannt. Eine ausführliche Einführung in die Theorie der Neuronalen Netze findet sich in BISHOP (1995) und ZELL (1997).

2.1.1 Vorwärtsgerichtete Neuronale Netze (MLP)

Bei vorwärtsgerichteten Neuronalen Netzen sind die Recheneinheiten, die sogenannten *Neuronen*, in Schichten angeordnet. Die Neuronen jeder Schicht sind mit den Neuronen der nächsten Schicht über die Gewichte verbunden und zwar immer in Richtung von der Eingabe zur Ausgabe des Netzes. Die Schichten werden nach ihrer Position bzw. Funktion im Netzwerk klassifiziert. In der *Eingabeschicht* werden dem Neuronalen Netz alle für das Problem relevanten Informationen zur Verfügung gestellt. Die *Ausgabeschicht* gibt das berechnete Ergebnis des Netzes nach außen zurück. Die dazwischenliegenden Schichten werden *verdeckte Schichten* bzw. *Hiddenschichten* genannt. Sie dienen nur der Informationsverarbeitung innerhalb des Netzes.

Im Rahmen dieser Arbeit werden nur vollständige Neuronale Netze verwendet, d. h. jedes Neuron der Schicht k ist mit allen Neuronen der Schicht $k+1$ verbunden.

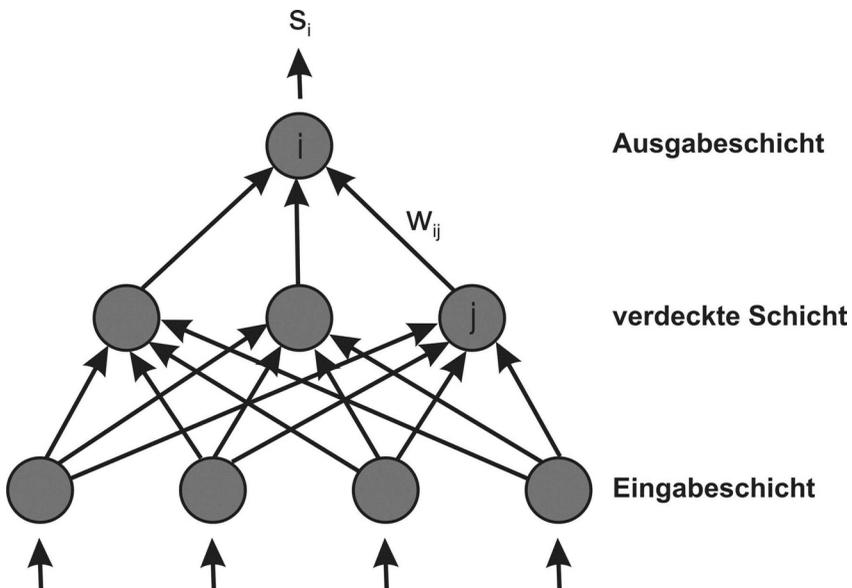


Abb. 2-1: Vollständiges vorwärtsgerichtetes Neuronales Netz mit einer 4 - 3 - 1 Topologie. Der vierdimensionale Eingabevektor wird in der verdeckten Schicht verarbeitet und erzeugt eine eindimensionale Ausgabe (nach GUTJAHR, 1999).

Die Netzeingabe net_i für jedes Neuron der Ausgabe- bzw. Hidden-schicht wird mit der Propagierungsfunktion durch die gewichtete Addition aus den Ausgaben der Vorgängerneuronen und einer zum Neuron gehörenden Konstanten berechnet.

$$net_i = \sum_{j \in pred(i)} w_{ij} s_j - \theta_i \quad (2.2)$$

Dabei bezeichnet $w_{ij} s_j$ die gewichtete Aktivierung des Neurons j und $pred(i)$ die Menge aller Neuronen j , die eine Verbindung zum Neuron i haben. Der Schwellenwert bzw. *Bias* θ_i gibt die Schwelle an, ab der das Neuron i aktiv ist. Er kann mit einer biologischen Reizschwelle verglichen werden und fällt mit der grössten Steigung der Aktivierungsfunktion zusammen (s. Abb. 2-2).

Die Berechnung der Aktivierungen aller Neuronen der Ausgabe- bzw. Hiddenschichten durch sukzessive Anwendung der Gleichungen (2.2) und (2.3) wird als *Vorwärtspropagieren* bezeichnet. Die Aktivierungsfunktion berechnet die Ausgabe des Neurons i nach der Formel:

$$s_i = f_{act}(net_i) \quad (2.3)$$

Für die Aktivierungsfunktion f_{act} kann im Prinzip jede beliebige eindimensionale Funktion verwendet werden. Bei mehrschichtigen Netzen wird für die verborgenen Schichten häufig die nichtlineare, logistische (sigmoid) Funktion f_{log} verwendet, deren Ausgabe im Bereich von (0,1) liegt (BISHOP 1996).

$$f_{log}(x) = \frac{1}{1 + \exp(-x)} \quad (2.4)$$

Um auch negative Werte zuzulassen, kann die symmetrische Aktivierungsfunktion f_{sym} , der Tangens hyperbolicus, verwendet werden, deren Ausgabe im Bereich (-1,1) liegt. Diese kann durch eine einfache lineare Transformation aus der logistischen Funktion hergeleitet werden (BISHOP 1996).

$$f_{sym}(x) = 2f_{log}(x) - 1 = \frac{1 - \exp(-x)}{1 + \exp(-x)} \quad (2.5)$$

Um nichtlineare Abhängigkeiten zu modellieren, sind die oben beschriebenen Sigmoidfunktionen notwendig (Abb. 2-2). Sie lösen das

2.1 Neuronale Netze

Problem, dass die Netze häufig auf Aktivierungen extrem unterschiedlicher Amplituden reagieren müssen, wobei sie bei kleinen Amplituden wesentlich sensibler sein müssen. Sigmoidfunktionen haben eben ihre höchste Sensibilität bzw. größte Steigung im Bereich um den Schwellenwert θ (0). Dort weisen sie ein nahezu lineares Verhalten auf (s. Abb. 2-2). Bei hohen Aktivierungen verhält sich die Funktion eher nichtlinear und die Steigung nimmt ab.

Die Funktionen sind streng monoton wachsend und ihre Ableitungen lassen sich in einfacher Weise durch die Funktion selbst ausdrücken (GUTJAHR 1999). Es gilt:

$$f'_{\log}(x) = f_{\log}(x)(1 - f_{\log}(x)) \quad (2.6)$$

bzw.

$$f'_{\text{sym}}(x) = \frac{1}{2}(1 - f_{\text{sym}}(x))^2. \quad (2.7)$$

Diese Eigenschaft ist bedeutend, da die Ableitung der Aktivierungsfunktion für viele Lernverfahren (z.B. Backpropagation) benötigt wird. Im Rahmen dieser Arbeit sind für „lineare“ zweischichtige Netzwerke einfache lineare Aktivierungsfunktionen verwendet worden. Für „nichtlineare“ mehrschichtige (meist dreischichtige) Netze ist aus den oben genannten Gründen die symmetrische Aktivierungsfunktion verwendet worden.

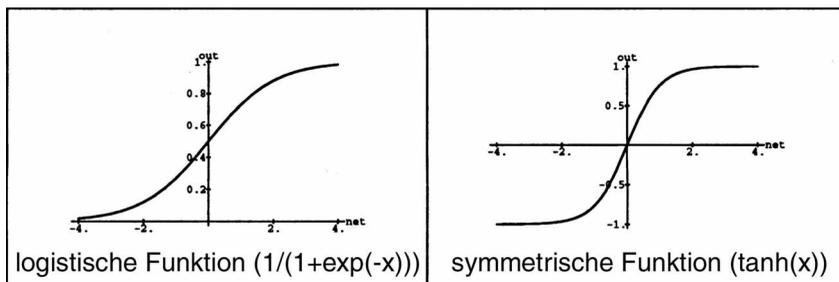


Abb. 2-2: Logistische und symmetrische Aktivierungsfunktion. In der Nähe des Nullpunktes verhalten sich die beiden Funktionen nahezu linear. Durch hohe Aktivierung der Neuronen wird Nichtlinearität erzeugt (verändert nach ZELL 1997).

2.1.2 Lernverfahren

Prinzipiell lassen sich drei Arten von Lernverfahren unterscheiden. Das *überwachte Lernen* (supervised learning) kann als imitieren oder lernen an Beispielen beschrieben werden. Dabei wird ein Eingabemuster mit einer Sollausgabe verglichen und die Gewichte so optimiert, dass das Netz nach der Präsentation mehrere Paare von Ein- und Ausgabemustern assoziativ als ähnliche Muster erkennen kann. Eine weitere Möglichkeit ist das Lernen aus Erfahrung bzw. *bestärkendes Lernen* (reinforcement learning). Bei diesem Verfahren wird dem Eingabemuster nicht eine erwünschte Sollausgabe entgegengesetzt, sondern nur geprüft, ob die Ausgabe falsch oder richtig ist. Dieses Verfahren hat den Vorteil, dass es biologisch plausibler ist, da das Netz die richtige Ausgabe (Zielwert) selbst finden muss. Allerdings ist es bei bekannter Ausgabe deutlich langsamer als die überwachten Lernverfahren. Die dritte Möglichkeit ist das *unüberwachte Lernen* (unsupervised learning), bei dem es nur Eingabemuster jedoch keine Soll- oder Erwartungsausgabe gibt. Der Lernalgorithmus versucht hier selbständig Gruppen ähnlicher Eingabevektoren zu erkennen und diese auf Gruppen ähnlicher oder benachbarter Neuronen abzubilden.

Aufgrund der höheren Geschwindigkeit beim Lernen, und der Art sowie der Qualität der Daten sind im Rahmen dieser Arbeit nur überwachte Lernverfahren angewendet worden.

Das Lernen selbst wird im Allgemeinen durch die Modifikation der Gewichte w_{ij} erreicht. Während des Lernens bzw. Trainings geht es darum, die Gewichte so einzustellen, dass das Netz einen unbekanntem funktionalen Zusammenhang zwischen Ein- und Ausgabe optimal darstellen kann. Trainiert wird das Neuronale Netz anhand einer Trainingsmengenmenge D , die aus Musterpaaren $P = (x^p, t^p) \in D$ besteht. Dabei stellt x^p eine konkrete Eingabe und t^p die entsprechende Sollausgabe dar. Anhand der Mengenmenge D versucht das Netz, die Gewichte so einzustellen, dass für jede konkrete Eingabe x^n möglichst die entsprechende Sollausgabe $t^n = t(x^n)$ erzeugt wird. Auf diese Weise soll das Netz lernen, die Funktion darzustellen, welche die Mengenmenge D erzeugt hat.

Eine Möglichkeit die Gewichte zu optimieren, ist die Betrachtung der Fehlerfunktion, die die Entwicklung des quadratischen Fehlers des Neuronalen Netzes auf der Trainingsmenge abbildet. Dabei wird der quadratische Abstand zwischen Sollausgabe t^p und Netzausgabe s^p be-

trachtet. Der Gesamtfehler E des Gewichtsvektors W ergibt sich als Summe der Fehler aller Musterpaare $P \in D$.

$$E = \sum_{p \in P} E^p = \frac{1}{2} \sum_{p \in P} (s^p - t^p)^2 \quad (2.8)$$

Der Faktor $1/2$ wird verwendet, um ihn gegen eine 2 zu kürzen, die später beim Differenzieren entsteht. Dies ist möglich, da es keine Rolle spielt, ob der ganze oder der halbe Fehler minimiert wird.

Aufgrund der nichtlinearen Aktivierungsfunktion ist es allerdings nicht möglich, das Minimum von E analytisch zu berechnen. Deshalb wird mit einem *Gradientenabstiegsverfahren*, der Methode des steilsten Abstiegs versucht, ein möglichst globales Minimum der Fehlerfunktion zu finden, in dem die Fehlersumme über alle Trainingsmuster hinweg minimal ist. Dazu werden die Gewichte um einen Bruchteil des negativen Gradienten der Fehlerfunktion in Richtung des Gradienten verschoben.

$$\Delta W = -\eta \nabla E(W) \quad (2.9)$$

ΔW stellt die Änderung des Gewichtsvektors und $-\nabla E(W)$ den negativen Gradienten der Fehlerfunktion dar. Für die Änderung eines einzelnen Gewichts gilt:

$$\Delta w_{ij} = -\eta \frac{\partial}{\partial w_{ij}} E(W). \quad (2.10)$$

Der Lernparameter $\eta > 0$, auch Schrittweite genannt, regelt wie stark der Gewichtsvektor W in Richtung des negativen Gradienten verändert wird.

Das Lernen, also die Berechnung des Gradienten und die adaptive Gewichtsveränderung (Gewichtsupdate) wird im Rahmen dieser Arbeit mit dem *Rprop-Algorithmus*, einer Weiterentwicklung des *Backpropagation-Algorithmus* durchgeführt. Zum besseren Verständnis wird zunächst kurz der Backpropagation-Algorithmus erklärt, auf dem der Rprop-Algorithmus wesentlich basiert.

2.1.2.1 Backpropagation-Algorithmus

Die zentrale Frage lautet: Wie kann der Gradient der Fehlerfunktion berechnet werden? Da der Fehler E^p als differenzierbare Funktion der Netzausgabe betrachtet werden kann und unter Berücksichtigung der

Formel (2.8) ist es möglich, die Ableitung der Fehlerfunktion E als Summe über die partiellen Ableitungen der Fehler der einzelnen Trainingsmuster zu betrachten. Deshalb wird zunächst die partielle Ableitung des Fehlers eines einzelnen Musters nach dem Gewicht w_{ij} betrachtet.

$$\frac{\partial E^P}{\partial w_{ij}} = \frac{\partial E^P}{\partial net_i} \frac{\partial net_i}{\partial w_{ij}} \quad (2.11)$$

Um die Übersichtlichkeit zu wahren, wird hier die Abhängigkeit der Ausgabe vom Trainingsmuster P unterdrückt. Der erste Faktor der Gleichung (2.11) wird nun einfach als *Fehlersignal* δ definiert.

$$\delta_i = \frac{\partial E^P}{\partial net_i} \quad (2.12)$$

Unter Berücksichtigung von Gleichung (2.2) ist

$$\frac{\partial net_i}{\partial w_{ij}} = s_j \quad (2.13)$$

sodass durch Substitution aus der Gleichung (2.11) folgt

$$\frac{\partial E^P}{\partial w_{ij}} = \delta_i s_j. \quad (2.14)$$

Aus Gleichung (2.14) folgt, dass die gesuchte Ableitung der Fehlerfunktion einfach erhalten wird, indem δ für das Neuron berechnet wird, zu dem das Gewicht w_{ij} zeigt und mit der Aktivierung des Neurons multipliziert wird, von dem das Gewicht w_{ij} wegzeigt. Da für die Ermittlung des Fehlers die Aktivierung s_j bereits zuvor nach Gleichung (2.3) berechnet wurde, muss nun nur noch das Fehlersignal δ für alle Neuronen der Hidden- und Ausgabeschicht berechnet werden.

Für die Ausgabeneuronen ergibt sich aus (2.12)

$$\delta_k = \frac{\partial E^P}{\partial net_i} = \frac{\partial E^P}{\partial s_i} f'_{act}(net_i) = (s_i - t_i) f'_{act}(net_i). \quad (2.15)$$

Um δ für die Hiddenneuronen zu ermitteln wird wie bei Gleichung (2.11) die Kettenregel für partielle Ableitungen benötigt, um die Summe über alle Nachfolgeneuronen $k \in succ(i)$ zu bilden, welche mit den Vorgän-

gerneuronen i verbunden sind.

$$\delta_i = \frac{\partial E^p}{\partial net_i} = \sum_{k \in succ(i)} \frac{\partial E^p}{\partial net_k} \frac{\partial net_k}{\partial net_i} \quad (2.16)$$

Die Neuronen k können dabei sowohl Hiddenneuronen als auch Ausgabeneuronen sein. Indem nun das δ aus Gleichung (2.12) in (2.16) eingesetzt wird, kann der Fehler für ein Hiddenneuron nach folgender Gleichung ermittelt werden.

$$\delta_i = f'_{act}(net_i) \sum_{k \in succ(i)} \delta_k w_{ki} \quad (2.17)$$

Um das Fehlersignal δ_i für ein bestimmtes Neuron der Hiddenschicht zu erhalten, wird der δ_k -Wert der Vorgängerschicht ausgewertet. Da dieser Vorgang im Gegensatz zum Vorwärtspropagieren bei der Ermittlung der Aktivierung von der Ausgabe hin zur Eingabe berechnet wird, handelt es sich hier um ein *Rückwärtspropagieren*. Dies gibt dem Lernverfahren auch seinen Namen *Backpropagation*.

Die Ableitung der Aktivierungsfunktion in Gleichung (2.15) und (2.17) kann direkt aus der Aktivierung der Neuronen nach Gleichung (2.6) oder (2.7) während des Vorwärtspropagierens ermittelt werden.

Der Backpropagation-Lernalgorithmus zur Ermittlung der Ableitung des Fehlers E^p nach den Gewichten lässt sich somit in 4 Schritte gliedern:

1. Ermittlung der Aktivierung aller Hidden- und Ausgabeneuronen durch Vorwärtspropagieren nach Gleichung (2.2) und (2.3).
2. Berechnung des Fehlersignals δ_k für die Ausgabeneuronen nach (2.15).
3. Durch Rückwärtspropagieren wird aus dem δ mit Gleichung (2.17) die δ_i für jedes Hiddenneuron ermittelt.
4. Mit Gleichung (2.14) kann die gesuchte Ableitung der Fehlerfunktion berechnet werden.

Der Gesamtfehler kann dann ermittelt werden, indem die oben beschriebenen Schritte für alle Musterpaare P der Trainingsmustersmenge

D durchgeführt werden und aufsummiert werden.

$$\frac{\partial E}{\partial w_{ij}} = \sum_{p \in P} \frac{\partial E^p}{\partial w_{ij}} \quad (2.18)$$

Basierend auf der Idee des Gradientenabstiegs sind zahlreiche Modifikationen bzw. Verfahren zur Verbesserung und Beschleunigung des Backpropagation-Algorithmus entwickelt worden. In ZELL (1997) sind zumindest die wichtigsten wie z.B. Quickprop oder SuperSAB dargestellt. Ein weiteres Verfahren, das die Vorteile verschiedener Verfahren kombiniert, ist die Resilient Backpropagation, kurz Rprop-Algorithmus (RIEDMILLER & BRAUN, 1992), der hier verwendet wurde.

2.1.2.2 Rprop-Algorithmus

Der Backpropagation-Algorithmus hat wie alle Gradientenverfahren den Nachteil, dass es sich um ein lokales Verfahren handelt. Dies bedeutet, dass es keine Informationen über die ganze Fehlerfläche hinweg gibt. Die Gewichtsanzpassung während des Lernvorgangs (Training) wird allerdings von der konstanten Schrittweite η und der lokalen Ableitung $ME/M_{w_{ij}}$ gesteuert. Bei einer steilen Fehlerkurve wird deshalb das Gewicht unter Umständen sehr stark verändert, während bei einer flachen Fehlerkurve, z.B. einem flachen Plateau, praktisch keine Änderung durchgeführt wird (s. Abb. 2-3).

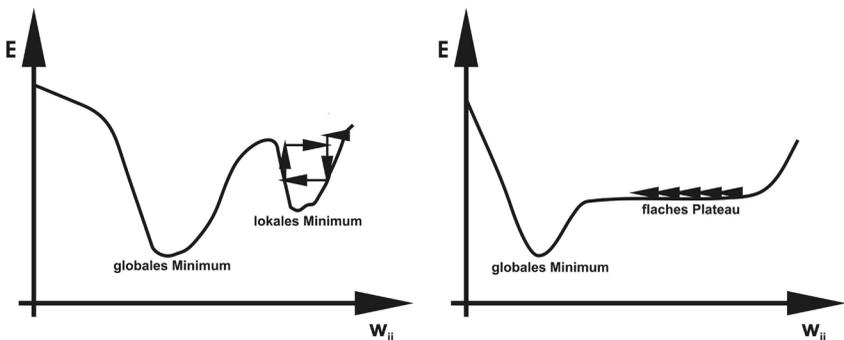


Abb. 2-3: Beispiele von Problemen, die bei Gradientenverfahren während des Lernens auftreten können. Links ist das Oszillieren in einem lokalen Minimum dargestellt und rechts die lange Lernzeit bei flachen Fehlerplateaus (nach ZELL, 1997).

Das kann z.B. dazu führen, dass der Lernvorgang unverhältnismäßig lange dauert oder dass es zu Oszillation um ein unter Umständen lokales Minimum (Abb. 2-3) kommt. Weitere Probleme, die daraus resultieren können, sind das „Hängenbleiben“ in lokalen Minima und das Verlassen von globalen Minima („Verlernen“).

Daher ist ein Verfahren wünschenswert, das eine adaptive Schrittweitenregelung durchführt, mit dessen Hilfe die Lernrate automatisch angepasst werden kann. Die *Resilient Backpropagation* (Rprop) ist ein solches Verfahren. Im Unterschied zum Backpropagation-Algorithmus werden die Gewichte nicht nach dem Betrag des Gradienten der Fehlerfunktion, sondern nur nach dem Vorzeichen dieses Gradienten geändert. Bei der Änderung der Gewichte wird nicht nur die aktuelle Steigung der Fehlerfunktion, sondern auch die vorhergehende berücksichtigt. Außerdem kann aufgrund des Algorithmus für jedes Gewicht eine eigene Schrittweite verwendet werden, die während des Lernprozesses separat angepasst werden kann.

Im Vergleich zu dem Backpropagation-Algorithmus und anderen Gradientenabstiegsverfahren zeichnet sich der Rprop-Algorithmus durch ein deutlich schnelleres Lernverhalten aus (RIEDMILLER 1994, SCHIFFMANN et al. 1993). Die Reduktion der Gradienten der Fehlerfunktion auf ihre Vorzeichen macht Rprop auch zu einem sehr robusten Verfahren in Bezug auf die zu bestimmenden Lernparameter (GUTJAHR, 1999). Diese sind die maximale Größe der Gewichtsänderung Δw und die Anfangsschrittweite η_{ini} . Durch die Modifikation des Rprop-Algorithmus mit der Einführung des *Weight-Decay* Terms (s. Kap. 2.1.3.2) konnten anfängliche Schwächen hinsichtlich der *Generalisierungsfähigkeit* behoben werden, sodass auch hier der Algorithmus anderen Verfahren ebenbürtig oder überlegen ist (ZELL 1997, RIEDMILLER 1993).

2.1.3 Generalisierungsfähigkeit Neuronaler Netze

Eines der zentralen Probleme, aber auch Ziel des Lernens mit Neuronalen Netzen ist die Generalisierungsfähigkeit der trainierten Netze. Es geht nicht um die exakte Repräsentation von Trainingsmustern, sondern um das Erstellen eines statistischen Modells des Prozesses, der die Daten erzeugt hat (BISHOP, 1995). Nur so kann das Netz auch für unbekannte Muster eine „gute“ Vorhersage machen.

Die Schwierigkeit bei der Optimierung der Generalisierungsfähigkeit liegt darin, dass Neuronale Netze aufgrund ihrer nichtlinearen Struktur eine außergewöhnliche Flexibilität aufweisen. Daraus ergibt sich die

Notwendigkeit die *Komplexität* des Modells, also die Anzahl der freien Parameter zu optimieren, um die beste Generalisierungsleistung zu erhalten. Bei Neuronalen Netzen sind v.a. die Gewichte als freie Parameter einstellbar, was bedeutet, dass mit der Anzahl der Neuronen und der ungehemmten Veränderbarkeit der Gewichte auch die Komplexität ansteigt.

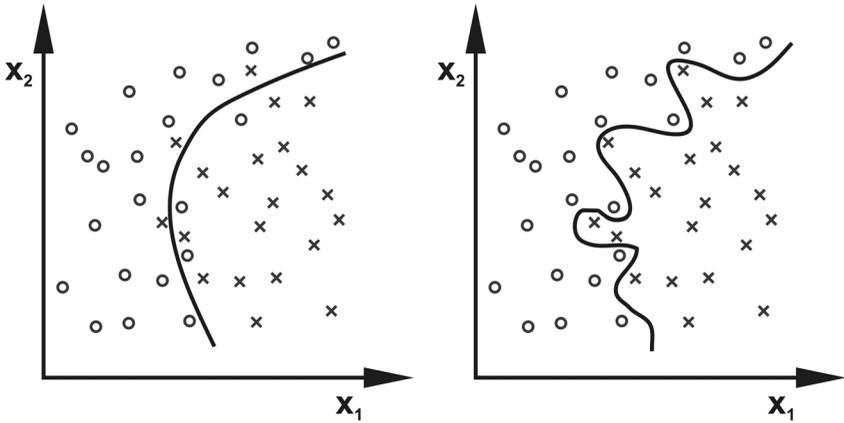


Abb. 2-4: Trennen einer Datenmenge von zweidimensionalen Vektoren mit unterschiedlich komplexen Modellen (nach BISHOP 1995).

In sehr komplexen Modellen ist die Anzahl der freien Parameter unter Umständen so hoch, dass das Neuronale Netz die Trainingsmuster exakt wiedergeben kann (s. Abb. 2-4 rechts). Dabei besteht aber die Gefahr, dass das Netz nicht die den Daten zugrunde liegende Funktion, sondern die Trainingsmuster „auswendig“ lernt. Demzufolge wird das Netz dann aber unbekannte Muster nicht richtig klassifizieren können. Dieses Phänomen wird Überanpassung oder *Overfitting* genannt. Umgekehrt ist es aber mit einem Modell, dessen Komplexität zu klein gewählt ist, nicht möglich, den funktionalen Zusammenhang der den Daten zugrunde liegt, richtig darzustellen und es kommt zum sog. *Underfitting*. Ein Beispiel hierfür wären lineare Modelle, welche die nichtlinearen Zusammenhänge in einer Datenmenge aufgrund der geringen Komplexität nicht beschreiben können.

Diese Schwierigkeit bei der Suche nach der optimalen Generalisierungsfähigkeit wird auch am *Bias-Varianz* Dilemma offensichtlich und in GEMAN et al. (1992) ausführlich diskutiert. Dabei wird der Generalisie-

rungsfehler in die Summe des quadratischen Bias und der Varianz aufgespalten. Hier wird unter Bias allerdings nicht der gleichnamige Schwellwert, sondern der absolute Fehler des Neuronalen Netzes auf der Trainingsmenge verstanden. Er ist im Allgemeinen groß, wenn das Modell zu einfach bzw. zu unflexibel ist. Die Varianz hingegen drückt die Flexibilität des Neuronalen Netzes aus. Sie ist im Allgemeinen groß, wenn das Modell sehr flexibel ist, also über viele freie Parameter verfügt. Das zeigt, dass die Schwierigkeit bei der Optimierung der Komplexität darin besteht, den besten Kompromiss zwischen den gegensätzlichen Forderungen nach einem minimalen Bias und einer minimalen Varianz zu finden.

Um die optimale Balance zwischen Bias und Varianz zu finden, ist es notwendig, die effektive Komplexität des Modells kontrollieren zu können. Bei Neuronalen Netzen stehen dafür prinzipiell zwei Möglichkeiten zur Verfügung:

1. die strukturelle Stabilisierung („structural stabilisation“)
2. die Regularisierung („regularisation“)

2.1.3.1 Strukturelle Stabilisierung

Bei der strukturellen Stabilisierung wird versucht, durch Veränderung der Zahl der freien Parameter im Neuronalen Netz, Einfluss auf die Komplexität des Modells zu nehmen.

Da die Anzahl der Gewichte und somit freien Parameter in einem vollständigen Neuronalen Netz von der Anzahl der Neuronen abhängt, kann das z.B. durch Veränderung der Zahl der Hiddenneuronen bzw. Hiddenschichten geschehen. Dies kann durch Vergleichen mehrerer Modelle geschehen, die eine unterschiedliche Anzahl an Hiddenneuronen haben. Ein anderer Ansatz ist, mit einem sehr komplexen Modell zu beginnen und die am wenigsten signifikanten Verbindungen (Gewichte) abzuschalten oder ganze Neuronen zu entfernen. So kann iterativ die beste Netzwerk-Architektur gesucht werden. Umgekehrt kann auch mit einem sehr einfachen Modell begonnen werden und dieses dann evolutionär entwickelt werden.

Eine weitere Möglichkeit ist die Bildung von *Komitees* aus Neuronalen Netzen (BISHOP, 1995). Dabei wird berücksichtigt, dass während des

Optimierungsprozesses immer nur das beste Netz weiterentwickelt wird. Die Anstrengungen, die bei der Entwicklung der ausgesonderten Netze entstehen, bleiben dabei unberücksichtigt. Nun ist es aber so, dass die Auswahl des „besten“ Netzes auf einer unabhängigen Testmenge zufälligen Schwankungen unterliegt (GUTJAHR, 1999). Bei einer anderen Testmenge zeigt das ausgewählte Netz also unter Umständen nicht mehr die beste Leistung. Indem aus verschiedenen Modellen Komitees gebildet werden und diese über geeignete Verfahren, z.B. Mittelwertbildung, verbunden werden, kann diesem Problem begegnet werden. Diese Komitees können häufig sogar ein besseres Ergebnis erzielen als das „beste“ Netz (BISHOP 1995, GUTJAHR 1999).

2.1.3.2 Regularisierung

Bei der Regularisierung wird die Komplexität des Modells durch das Hinzufügen eines Strafterms, dem sog. Regularisierungsterm, zur Fehlerfunktion E aus Gleichung (2.8) kontrolliert. Der Grad der Regularisierung wird dabei über die Multiplikation des Strafterms Ω mit einem veränderbaren Parameter, dem Regularisierungsparameter, $\lambda \geq 0$ gesteuert.

$$E_{neu} = E + \lambda \Omega \quad (2.19)$$

Im Training werden die Gewichte damit so eingestellt, dass die neue Fehlerfunktion E_{neu} möglichst minimal wird. Dies bedeutet, dass das Neuronale Netz versucht, gleichzeitig die Trainingsmuster zu lernen und den Strafterm Ω zu minimieren, was der Komplexität des Modells entgegenwirkt. Im Folgenden werden zwei einfach anwendbare Verfahren vorgestellt. Weitere Verfahren wie z.B. *Soft-Weight-Sharing* oder *Weight-Pruning* werden ausführlich in BISHOP (1995) und ZELL (1997) dargestellt.

Eine einfache und häufig verwendete Regularisierungsfunktion ist der *Weight-Decay*, das Lernen mit Gewichtsabnahme (BISHOP 1995, ZELL 1997). Der Weight-Decay Strafterm Ω wird aus der Summe der W quadrierten Gewichte gebildet.

$$\Omega = \frac{1}{2} \sum_{i=1}^W w_i^2 \quad (2.20)$$

2.1 Neuronale Netze

Empirisch kann nachgewiesen werden, dass diese Form der Regularisierung zu einer signifikanten Verbesserung der Generalisierungsleistung der Neuronalen Netze führt (BISHOP, 1995). Dies liegt daran, dass die Modellkomplexität reduziert wird durch die Bestrafung großer Gewichte und Bevorzugung kleiner Gewichte. Kleine Gewichte haben den Vorteil, dass die Aktivierung der Neuronen damit eher im linearen Bereich der Aktivierungsfunktion liegt, was die Nichtlinearität des Neuronalen Netzes einschränkt (vgl. Kap. 2.1.1).

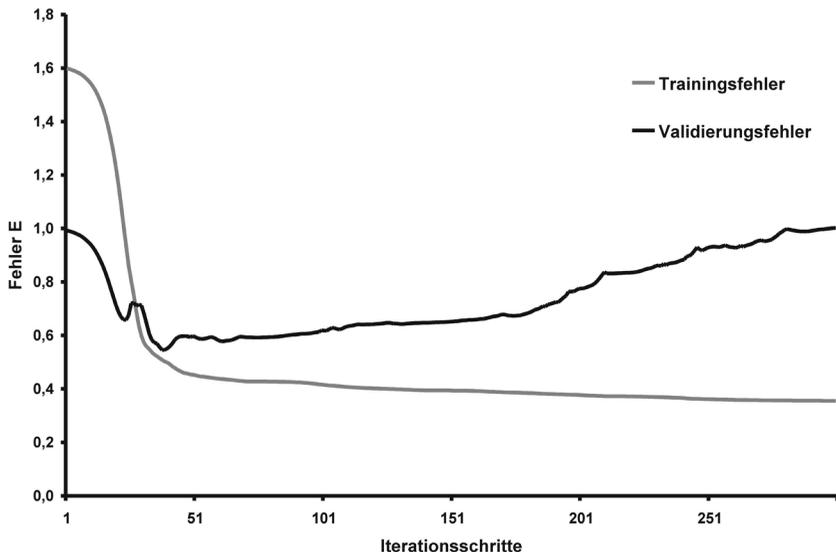


Abb. 2-5: Entwicklung des quadratischen Fehlers eines Neuronalen Netzes auf einer Trainingsmenge und einer Validierungsmenge. Nach anfänglicher Abnahme steigt der Fehler auf der Validierungsmenge wieder an, sobald das Overfitting des Netzes beginnt.

Ein nicht unerhebliches Problem stellt allerdings die optimale Einstellung des Weight-Decay Parameters λ dar. Eine Möglichkeit das Problem heuristisch zu lösen, ist die *Kreuzvalidierung* (cross-validation), bei der der Trainingsdatensatz in eine Trainings- und eine Validierungsmenge getrennt wird. Während des Trainings wird dann die Trainingsmenge genutzt, um die Gewichte einzustellen und die Validierungsmenge, um den Generalisierungsfehler zu ermitteln. Ausgehend von

sehr kleinem λ wird dessen Wert so lange erhöht, bis der Fehler auf der Trainings- und der Validierungsmenge gleich hoch ist.

Eine alternative simple Methode zur Regularisierung ist das *Early-Stopping*. Hierbei wird der Lernprozess an einem iterativ ermittelten oder vorher definierten Fehlerminimum unterbrochen. Da normalerweise während des Trainings der Fehler mit der Anzahl der Iterationschritte (Epochen) abnimmt, kann er fast als monoton abnehmende Funktion dieser gesehen werden. Wenn nun der Fehler auf einer Trainingsmenge mit dem einer unabhängigen Validierungsmenge verglichen wird, nimmt dieser auf beiden Mengen zuerst ab. Sobald das Neuronale Netz aber beginnt, sich zu stark an den Trainingsdatensatz anzupassen, also der Overfitting-Effekt eintritt, beginnt der Fehler auf der Validierungsmenge wieder zu steigen (s. Abb. 2-5). Da hierbei das Training nicht beim kleinsten Trainingsfehler, sondern vorher beim Minimum des Validierungsfehlers unterbrochen wurde, schränkt auch das die Komplexität des Modells ein.

2.2 Massenbewegungen

Die heute wohl gängigste und weltweit gebräuchliche Definition einer Massenbewegung stammt von CRUDEN (1991) und lautet:

"A movement of a mass of rock, earth or debris down a slope".

Es handelt sich also immer um die Verlagerung einer Fels- oder Lockermasse entsprechend dem topographischen Gradienten.

Im Folgenden werden die wichtigsten Arten von Massenbewegungen und deren Ursachen vorgestellt. Dabei wird v.a. auf Hangrutschungen bzw. Gleitungen und fließende Bewegungen im Lockergestein eingegangen, da diese für die Arbeit besonders relevant sind. Eine umfassende Darstellung des Themas Massenbewegungen findet sich z.B. in TURNER & SCHUSTER (1996) und in DIKAU et. al. (1999).

Die in Abbildung 2-6 dargestellte exemplarische Massenbewegung ist eine Rotationsrutschung, die in einen Schuttstrom übergeht. In dieser anschaulichen Abbildung sind die wichtigsten Elemente von Massenbewegungen im Lockergestein dargestellt und benannt. An der oberen Kante der Hangrutschung bzw. Rutschung liegt die *Hauptabrissskante*, welche durch die Bewegung der *Rutschmasse* auf dem anstehenden Untergrund entsteht. Sie ist der sichtbare Teil der *Hauptscherfläche* bzw. Gleitbahn, welche sich in einer Schwächezone ausbildet und die untere Grenze zwischen umgelagertem Material und anstehendem Gestein bildet. Das gesamte umgelagerte Gestein wird *Rutschmasse* genannt. Der obere Teil der Rutschmasse wird *Kopf* der Rutschung genannt und die Stelle, an der die Rutschmasse an die Hauptabrissskante stößt, wird als *Top* bezeichnet. Oberhalb der Hauptscherfläche bildet das anstehende Gestein die *Krone*, die zusammen mit den *Flanken* den *Hauptrutschkörper* einfasst. Dieser Hauptrutschkörper stellt den Teil der Rutschmasse dar, in dem die rezente Oberfläche der Rutschmasse unterhalb der ehemaligen Geländeoberkante liegt. Im Hauptrutschkörper sind häufig noch größere zusammenhängende Schollen zu erkennen, die durch *untergeordnete* oder *sekundäre Abrisskanten* getrennt sind. Diese untergeordneten Abrisse entstehen durch Bewegungsunterschiede innerhalb der Rutschmasse. Bei kleineren Bewegungsunterschieden oder an starken Unebenheiten der Gleitfläche entstehen *Querspalten*, an denen aber keine Vertikalbewegungen stattfinden.

2.2 Massenbewegungen

Der Verschnitt der ehemaligen Geländeoberfläche mit der Gleitbahn ist der *Ausbiss der Hauptscherfläche* und bildet das Ende des Hauptrutschungskörpers. An dieser Stelle geht auch der *Ablations- oder Verarmungsbereich* der Rutschung in den *Akkumulationsbereich* über. Im Verarmungsbereich kommt es zum Massenaustrag und im Akkumulationsbereich zum Masseneintrag bzw. zur Ablagerung des umgelagerten Materials. Auf Grund dessen liegt die neue Geländeoberkante über der alten. Die ehemalige Geländeoberfläche bildet nun die *Trennfläche* zwischen der Rutschmasse und dem anstehenden Gestein. Der gesamte untere Bereich der Rutschmasse, welcher über der alten Geländeoberfläche liegt, wird als *Fuß* der Rutschung bezeichnet. Das untere meist gebogene Ende der Rutschmasse bildet den *Zeh* der Rutschung. Auf dem Rutschungsfuß bilden sich manchmal durch laterale Ausbreitung *Radialspalten* und durch Stauchungen können sogenannte *Querwülste* entstehen. Je nach Massenbewegungstyp sind die oben beschriebenen Merkmale mehr oder weniger ausgebildet oder fehlen ganz.

Tab. 2.1: Typen von Massenbewegungen (verändert nach DIKAU et al., 1999, Original im Anhang A). Die hinterlegten Arten von Massenbewegungen im Lockergestein sollen von den verwendeten Neuronalen Netzen erkannt werden.

Bewegungsart	Felsgestein	vorwiegend rolliges Lockergestein	vorwiegend bindiges Lockergestein
Sturz	Steinschlag Felssturz Bergsturz	Lockergesteinssturz	
Kippen	Felskipfung	Kippung im Lockergestein	
Gleiten, rotativ	Felsgleitung: einfache multiple sukzessive	Rotationsrutschung: einfache multiple sukzessive	
Gleiten, translativ planar	planare Felsgleitung	Translationsrutschung	
----- nicht rotativ	Blockgleitung	Schollenrutschung	Blattanbruch
Blockdeformation	Felsdriften	Schuttdriften	Bodendriften
Fließen	Talzus Schub	Mure Schuttstrom	Schlammstrom
zusammengesetzte komplexe Bewegungen	z.B. Sturzstrom	z.B. Muschelanbruch mit Vermurung	z.B. Muschelanbruch mit folgender Bodenverflüssigung

Entsprechend der anfangs angeführten Definition werden Massenbewegungen nach der Verlagerungs- bzw. Bewegungsart und dem Materialtyp unterschieden. Die heute gebräuchlichste Gliederung stammt von VARNES (1978) und wurde im Rahmen des EPOCH Projektes auf die in Europa gängigen Klassifikationsmuster erweitert (Tab. 2.1).

Stürze sind vorwärts gerichtete, freie Bewegungen von Material aus einer steilen Oberfläche heraus. Das Material bewegt sich dabei fallend, springend und rollend durch die Luft.

Bei *Kippungen* handelt es sich im Allgemeinen um vorwärts gerichtete Rotationen von Material aus einem Hang heraus. Der Drehpunkt der bewegten Masse liegt hier unterhalb des Gewichtsschwerpunktes. Kippungen gehen in der Folge häufig in eine stürzende oder gleitende Bewegung über.

Gleitungen werden meist unter dem Begriff Rutschungen zusammengefasst und sind hangabwärts gerichtete Bewegungen von Material entlang einer definierten Bewegungsbahn (Scherfläche) oder einer dünnen Scherzone. Da sich sowohl die Standsicherheitsnachweise und damit die mechanischen Grundlagen, als auch die Sanierungsmaßnahmen bei rotativen und translativen Gleitungen unterscheiden, ist es nach VARNES (1978) wichtig, diese getrennt zu betrachten. In homogenem Material bilden sich meist Rotationsgleitungen, deren Bewegungsbahn eine gebogene und konkave Form hat. Die Achse um die die Rotation stattfindet, liegt außerhalb des Hanges und verläuft meist parallel zum Hang. Bei den flachgründigen *Translationsgleitungen* werden die Massen entlang einer ebenen oder ondulierenden Scherbahn hangabwärts bewegt. Im Gegensatz zu *Rotationsgleitungen*, die durch die Bewegung eine Wiederherstellung des Kräftegleichgewichts anstreben und somit selbst stabilisierend sind, können sich die Translationsbewegungen bei ausreichender Neigung der Bewegungsfläche unkontrolliert fortsetzen.

Spreizung bzw. *Driften* wird als Auseinanderdriften von Fest- oder Lockergestein kombiniert mit einem Einsinken der bewegten Masse in das unterlagernde weichere Gestein definiert. Dabei wird meist keine klar definierte Bewegungsfläche ausgebildet.

2.2 Massenbewegungen

Das *Fließen* von Fest- oder Lockergestein kann als Massenbewegung beschrieben werden, in der sich die einzelnen Partikel voneinander unabhängig in der Masse bewegen. Innerhalb dieser räumlich kontinuierlichen Bewegung bilden sich, wenn überhaupt, nur kleine, kurzlebige Scherflächen aus.

Die Ursache für Massenbewegungen liegt darin, dass in jedem Hang Kräfte wirken, die eine Massenverlagerung hangabwärts unterstützen und solche, die dieser entgegenwirken. Wenn dieses Hanggleichgewicht durch ein Anwachsen der Hangabtriebskräfte gestört wird, kommt es zur Auslösung von Massenbewegungen. Nach CRUDEN & VARNES (1996) lassen sich daraus die folgenden prinzipiellen Ursachen für Massenbewegungen ableiten, nämlich eine Zunahme der Scherspannung, die zu einer Verringerung der Festigkeit führt und eine niedrige Materialfestigkeit.

Die einzelnen Ursachen, die zu einer Zunahme der Scherspannung führen oder die Materialfestigkeit beeinflussen, lassen sich in vier Gruppen gliedern (s.a. Abb. 2-7).

1. Geologische Verhältnisse
2. Morphologische Ursachen
3. Anthropogene Ursachen
4. Physikalische Ursachen

In Abbildung 2-7 sind die wichtigsten Beispiele der Ursachen von Massenbewegungen nach Gruppen gegliedert angeführt, ohne jedoch alle Möglichkeiten zu nennen. Da meist nicht einzelne Ursachen, sondern das Zusammentreffen mehrerer Faktoren zur Aktivierung einer Massenbewegung führen, ist es wichtig diese, wie von POPESCU (1994) vorgeschlagen, in vorbereitende („preparatory causes“) und auslösende Ursachen („triggering causes“) zu unterteilen (s. Abb. 2-7).

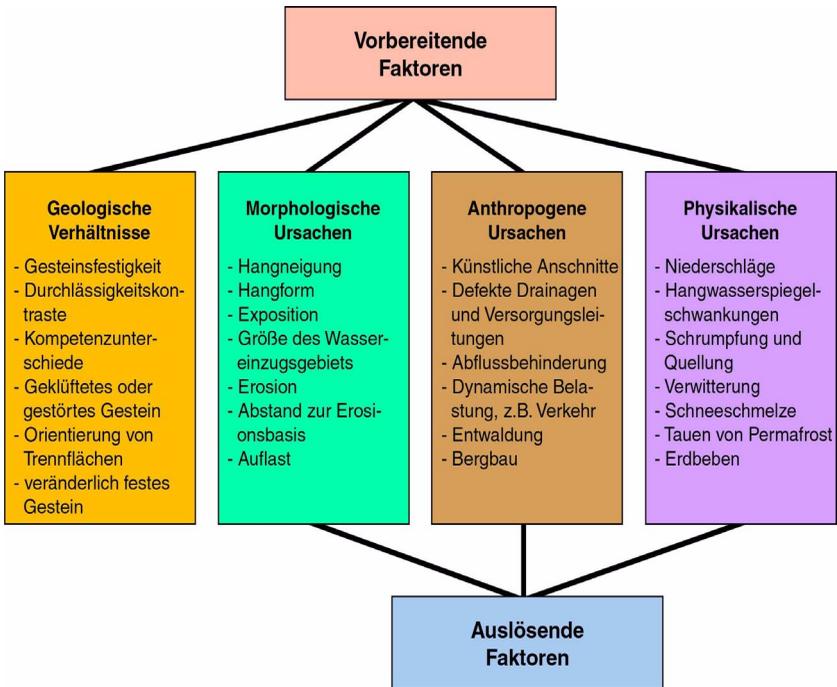


Abb. 2-7: Faktoren, die die Hangstabilität beeinflussen können und deren Zuordnung zu den vorbereitenden und den auslösenden Faktoren (verändert nach POPESCU, 1994).

Unter vorbereitenden Ursachen werden permanente Faktoren verstanden, die den Hang für Bewegungen anfällig machen, ohne diese jedoch direkt auszulösen. Sie beeinflussen die Hangstabilität dauerhaft und versetzen diesen in einen metastabilen Zustand. Im Gegensatz dazu sind auslösende Ursachen variable Einflussfaktoren, die zeitlich und in der Intensität schwanken. Sie leiten die Bewegungen im Hang ein und versetzen diesen in ein aktives Bewegungsstadium.

2.3 Modellgebiete

Um das Modell zur Rutschungserkennung mit Neuronalen Netzen nicht anhand von „künstlichen“ Datensätzen entwickeln zu müssen, sind zwei Gebiete in den Ostalpen bei Bad Ischl als Modellgebiete ausgewählt worden. Die Gebiete sind besonders geeignet, da sie im Rahmen mehrerer Doktorarbeiten (ROHN 1991, XIANG 1997) und Diplomarbeiten (RESCH 1997, RÖHNAU 2001) sehr detailliert geologisch und geotechnisch untersucht wurden, sodass hier eine außergewöhnlich hohe Datendichte und –auflösung vorhanden ist. Außerdem liegen die Gebiete in einem stark differenzierten geologischen Umfeld mit zahlreichen Massenbewegungen, sodass genügend zum Teil komplexe Massenbewegungen vorhanden sind um das Problem zu modellieren.

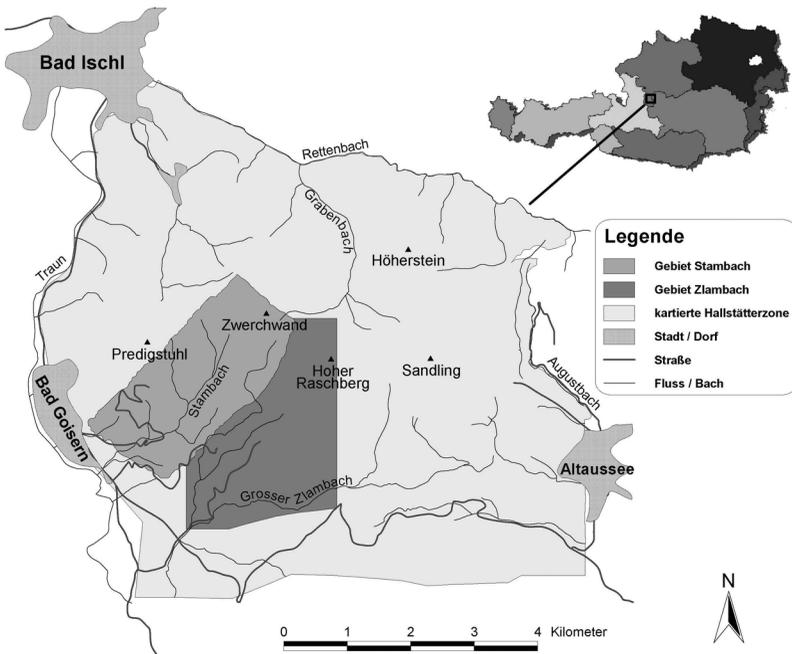


Abb. 2-8: Lage der beiden Modellgebiete (Gebiet Stambach und Gebiet Zlambach) im Salzammergut bei Bad Ischl/Österreich.

2.3.1 Geographischer Überblick

Die Untersuchungsgebiete liegen bei Bad Goisern im oberösterreichischen Teil des Salzkammergutes, etwa 50 Kilometer ost-südöstlich von Salzburg.

Das nordöstliche Gebiet Stambach ist ca. 8,4 km² groß und liegt im Einzugsgebiet des Stambachs, der rechtsufrig in die Traun mündet. Das Gelände steigt von 525 mSh im Trauntal bis auf 1326 mSh bei der Zwerchwand an. Auf den flachen bis mittelsteilen Hängen wird extensive Alm- und Waldwirtschaft betrieben. Die vorwiegend aus Mergeln aufgebauten Hänge werden v.a. im oberen Teil des Gebietes von massigen Kalken überlagert, die bis zu 100 m hohe Felswände ausbilden. Die markantesten Felswände bilden die Ewige Wand, der Predigstuhl und die Zwerchwand. Weitere Steilkanten entstanden durch den postglazialen Reliefausgleich an den Flanken des Trauntals. Nach dem Rückzug des Traungletschers, der diesen Talabschnitt stark übertieft hat, entwickelten sich durch das Fehlen des talseitigen Widerlagers bedeutende Hangbewegungen. Zusätzlich führte die Übertiefung des Tals zu einer sehr tief liegenden Erosionsbasis, was die Entstehung zahlreicher Wildbachsysteme begünstigt hat.

Südöstlich schließt sich das ca. 9,8 km² große Gebiet Zlambach an. Es liegt im Einzugsgebiet des Großen und Kleinen Zlambach und steigt von 550 mSh an der Mündung des Kleinen in den Großen Zlambach bis auf 1487 mSh am Gipfel des Hohen Raschbergs an. Wie im Stambachgebiet werden die flacheren unteren Hänge von Mergel aufgebaut, die von massigen Kalkschollen überlagert sind. Diese sind durch ausgeprägte Grabensysteme getrennt und werden aufgrund des steilen Reliefs nur forstwirtschaftlich genutzt. Auf den flacheren Nordhängen des Zlambachtals wird z.T. intensive Alm- und Forstwirtschaft betrieben. Südlich des Großen Zlambachs überlagert eine weitere mächtige Kalkscholle die flachen Mergelhänge. Ähnlich dem Gebiet Stambach führt auch hier die tief liegende Erosionsbasis im Trauntal zu einer starken Eintiefung der Bäche, was die Ausbildung lokal steiler Hangflanken begünstigt.

2.3 Modellgebiete

2.3.2 Geologischer Überblick

Die Untersuchungsgebiete liegen im Mittelabschnitt der Nördlichen Kalkalpen, also im Ostalpin. Sie werden vorwiegend aus permischen bis jurassischen Sedimenten aufgebaut, die zur Hallstätter Zone von Bad Ischl - Bad Aussee gehören.

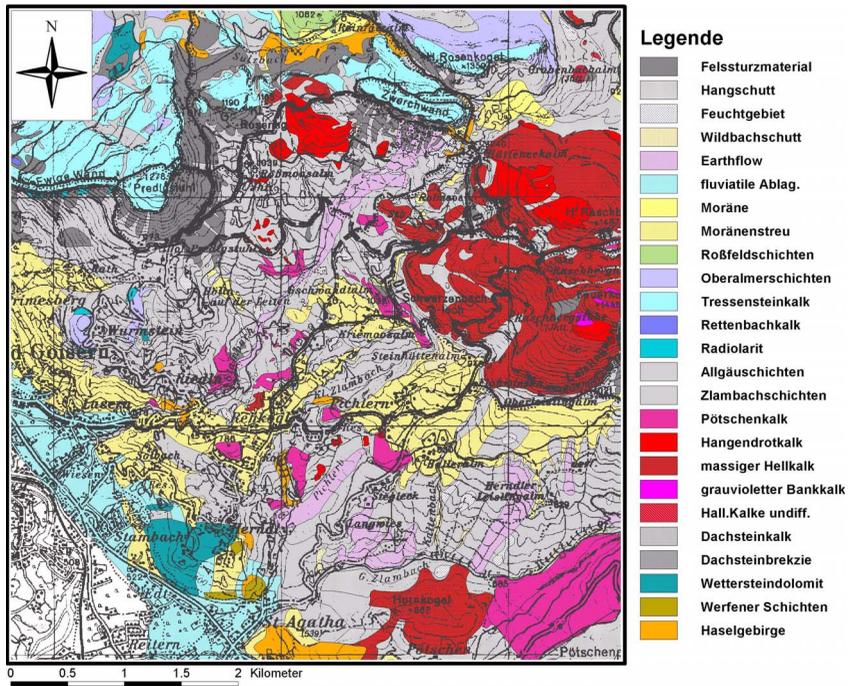


Abb. 2-9: Geologische Karte der Untersuchungsgebiete (verändert nach RÖNNAU, 2001).

Geographisch versteht man unter den „Nördlichen Kalkalpen einen 40 - 50 km breiten Streifen, der sich von West nach Ost, vom Rheintal bis zum Wiener Becken erstreckt (PLÖCHINGER, 1983).

Geologisch sind die Nördlichen Kalkalpen ein langgezogener Falten- und Überschiebungsgürtel mit einem komplexen inneren Aufbau (GAWLICK et al., 1999). Als Teil des Ostalpin stellen sie den in der Folge der Alpengeneese abgescherten ehemaligen nördlichen, distalen (adriatischen) Kontinentalschelf des Tethysmeeres dar. Sie werden tektonisch in eine untere bavarische, mittlere tirolische und obere juvavische Ein-

heit bzw. „Decke“ unterteilt. Die oberste, das Juvavikum, lässt sich weiter in das Tiefjuvavikum des Hallstätter Faziesraums, in dem die Untersuchungsgebiete liegen, und das Hochjuvavikum der Dachsteinfazies gliedern.

Die Sedimentationsgeschichte setzt in den Untersuchungsgebieten im *Perm* mit der Ablagerung von marin geprägten Evaporiten und Siliziklastika (Haselgebirge) in Becken ein (MANDL, 2000), welche sich durch die gleichzeitig einsetzende Basin-and-Range Extension des variszischen Basements gebildet hatten (EISBACHER, 1996).

In der *Trias* setzt sich diese Extension sowie die damit verbundene Subsidenz fort. Es entwickelt sich ein passiver Kontinentalrand. In der Untertrias findet noch keine ausgeprägte Faunendifferenzierung statt, und v.a. Flachwassersedimente (Werfener Schichten) werden abgelagert. Ab der Mittleren Trias kommt es durch die zunehmende Subsidenz und Bruchschollenbildung zu einer faziellen Differenzierung (s. Abb. 2-10) in flache Karbonatplattformen (Flachscheff) und Beckenbereiche (Tiefscheff). Auf dem Flachscheff werden die Serien in der Dachsteinfazies (Wettersteinkalke und –dolomite) abgelagert, während im Becken (Tiefscheff) die Serien in der Hallstätter Fazies (Hallstätter Kalke, Pötschenkalke) abgelagert werden (MANDL, 2000). Diese Gliederung in Plattformsedimente und Beckensedimente bleibt während der ganzen Mittleren und Oberen Trias erhalten. Am Ende der Trias nimmt der terrigene Einfluss wieder zu und es kommt zur Ablagerung mergelig kalkiger Serien (Zlambachsichten, Allgäuschichten) bis in den mittleren Jura hinein.

Im *Jura* beginnen die Karbonatplattformen zu zerbrechen, und der Austroalpine Schelf versinkt durch die verstärkte Subsidenz im Zusammenhang mit der Öffnung des Penninischen Ozeans im Norden. Im Mittleren Jura hat sich auch die Prototethys im Süden vollständig geschlossen und der Austroalpine ehemalige „Schelfbereich“ erreicht seine tiefste Absenkung. Es kommt zur Ablagerung von kieseligen Tiefwasserserien (Radiolarit). Die beginnende erste Phase der Alpenorogenese führt zu einer erneuten Gliederung des Meeresbodens, was zur Ablagerung von Plattformkarbonaten (Tressensteinkalk, Oberalmerkalke) und pelagischen Kalksteinen (Oberalmerschichten) in den dazwischenliegenden Becken führt (MANDL, 2000).

2.3 Modellgebiete

Tab. 2.2: *Stratigraphische Tabelle der in den Untersuchungsgebieten aufgeschlossenen Einheiten mit kurzen Gesteinsbeschreibungen.*

Epoche	Stufe	Einheit	Gesteine	
Quartär	Holozän	Flussablagerungen	Helle sandige bis schluffige Ablagerungen mit stellenweise hohem Kiesanteil.	
		Felssturzmateriale	Grobblockige bis zu 1000 m ³ große Blöcke aus Kalkstein.	
		Hangschutt	Grobkörniger, steiniger Hangschutt aus Kalk oder Dolomit und feinkörniger mergeliger Hang- und Verwitterungsschutt.	
		Wildbachschutt	Schlecht sortierte und klassierte Geschiebe unterschiedlicher Rundungsgrade.	
		Schuttstrom / Rutschmassen	Strukturlose, plastische, dunkle, mergelig tonige Grundmasse in der z.T. große Kalkblöcke schwimmen.	
	Pleistozän (Würm)	Moräne	Weiß, grau, gelb bis rotbraune, tonig-schluffig bis sandige Ablagerungen mit wechselndem Kiesanteil, z.T. mit gekritztem Geschiebe; hohe Lagerungsdichte, z.T. überkonsolidiert.	
Moränenstreu				
Jura	Kimmeridgium - Thitonium	Tressensteinkalk	Dickbankige bis massige, hellbraune oder gelblich weiße Kalke mit brekziösem oder mikritischem Charakter.	
	Thitonium - Berriasium	Oberalmerschichten	Wohl gebankte, graue bis braune mikritische Kalke; z.T. mit eingelagerten Hornsteinlinsen oder -schichten.	
	Oxfordium - Thitonium	Radiolarit	Gut geschichtete, schwarz, grün oder rot gefärbte Radiolarite (Kieselgesteine); stellenweise sind tonige bzw. Tonschieferlagen eingeschaltet.	
	Aalenium - Callovium Hettangium - Toarcium	Allgäuschichten, kieselig Allgäuschichten	Monotone Wechsellagerung aus gut gebankten grauen mergeligen Kalken und dünnen fleckigen Mergellagen, stellenweise, v.a. im Hangendbereich kieselige Abfolgen.	
Trias Hallstätter F.	Norium - Rhätium	Zlambachschiechten	Graue bis braune, plattig geschichtete Mergel- und Kalksteine sowie weiche, dunkle schiefrige Mergel-Tonsteinlagen.	
	Karnium - Norium	Pötschenkalke	Gebankte, hell- bis dunkelgraue, feinkörnig bis mikritische Kalke in Wechsellagerung mit dünnen grauen Mergellagen; stellenweise Hornsteineinschaltungen.	
	Norium	Hallstätter Kalke	Hangendrotkalk / roter Hellkalk	Wellige bis plattige, rote, mikritische Kalksteine; stark fossilführend.
	Ladinium - Norium		Massiger Hellkalk	Massig bis undeutlich gebankte, weisse, mikritische Kalke.
	Ladinium - Karnium		Roter Bankkalk	Gebankte, fleischfarbene bis hellrote, biomikritische Kalke.
	Anisium - Karnium		Grauvioletter Bankkalk	Gebankte, violette, mikrosparitische Kalke; an der Basis z.T. Hornsteineinschaltungen.
Trias Dachstein F.	Ladinium	Wettersteindolomit	Massige und gebankte, graue bis graugelbe Dolomite, grobkörnig.	
	Skythium	Werfener Schichten	Geschichtete, graue bis bräunliche Mergel mit Tonstein-Einschaltungen.	
Perm	Lopingium - Skythium	Haselgebirge	Schichtungsloser, grauer bis schwarzer toniger Schluff mit Gipseinlagerungen.	

Mit Beginn der *Kreide* gehen die Schichten bedingt durch zunehmenden terrigenen Einfluss bei Zunahme der Wassertiefe gleichmäßig in mergelige Aptychenkalke (Schrambachschichten) über. Direkt über diesen werden im Mittleren Jura sandige Mergel einer syntektonischen klastischen Fazies (Rossfeldschichten) an der Front der entstehenden alpinen Decken abgelagert. Im Mittleren Jura ist dann die marine Sedimentation im Ostalpin abgeschlossen und ab dem Oberjura beginnt die isostatische Heraushebung des Alpenorogens zum Hochgebirge.

Die zunehmende Plattenkonvergenz während der Alpenogenese ab dem Oberen Jura und der daraus resultierende nach Norden gerichtete Schub führten zur Zerstückelung und Überschiebung der marin geprägten Schichtenfolge. Die genaue Rekonstruktion dieser Bewegungen ist auch heute noch nicht abschließend geklärt. Problematisch ist hierbei die Position der Hallstätter Fazieszone (Beckenbereich) zwischen Hauptdolomitfazies (Rückriffbereich) im Norden und Dachsteinfazies (Riffbereich) im Süden.

Im Wesentlichen lassen sich zwei Gruppen von Theorien unterscheiden:

Die einen gehen von einer Entstehung der Hallstätter Zone im Süden der Dachsteindecke aus (s. Abb. 2-10). Im Zuge der Orogenese ist die Hallstätter Decke über die Dachsteindecke hinweg und anschließend auf den Hauptdolomit transportiert worden (SPRENGLER 1956, SCHÄFFER 1976, TOLLMANN 1981, MANDL 2000).

Die andere Gruppe geht von einer Entstehung nördlich der Dachsteindecke in Becken aus. Im Rahmen des nordgerichteten Deckenschubs ist die Hallstätter Zone dann von der Dachsteindecke teilweise überfahren und zusammen mit dieser auf den Hauptdolomit aufgeschoben worden (KOBEL 1927, MEDWENITSCH 1951, TOLLMANN 1960).

Schließlich führt die intensive Vergletscherung des Gebietes im Quartär einerseits zur Übersteilung der Talflanken durch glaziale Erosion, und andererseits kommt es zur weiträumigen Ablagerung von glazialen Geschieben und Moränen. Nach der letzten Vereisungsperiode im Würm setzt im Holozän der erneute Reliefausgleich mit zahlreichen kleinen aber auch großräumigen Massenbewegungen ein (s. Kap. 3.3.3)

2.3 Modellgebiete

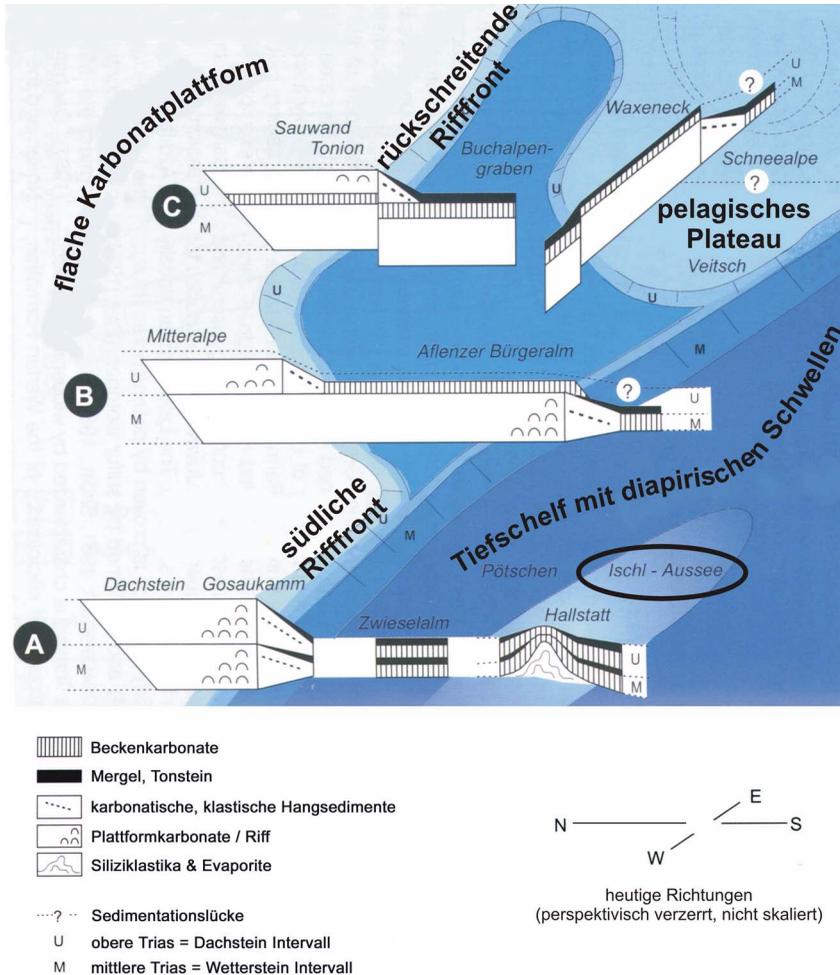


Abb. 2-10: Schematische Rekonstruktion der vermutlichen Lage der Sedimentationsräume (Faziesräume) der späteren jurassischen Einheiten des Austroalpinen Schelfs während der Trias nach MANDL (2000). Die Untersuchungsgebiete liegen in dem umrandeten Bereich (Ischl - Aussee) auf einer Schwelle im Tiefschelf (verändert und übersetzt nach MANDL, 2000).

2.3.3 Ingenieurgeologischer Überblick

Die Untersuchungsgebiete sind aus ingenieurgeologischer Sicht sehr problematisch und befinden sich auch heute noch über weite Bereiche nur in einem metastabilen bis instabilen Zustand. Einerseits führen die hohe Reliefenergie und der steile topographische Gradient zu Ausgleichsbestrebungen (Hanggleichgewicht). Dies drückt sich in den zahlreichen Rutschungen aus. Andererseits ist die Lagerung mächtiger kompetenter Kalkplatten auf inkompetenten Mergeln (System „Hart auf Weich“ nach POISEL & EPPENSTEINER, 1989) extrem ungünstig und führt zu z.T. großräumigen und tiefgreifenden Bewegungen im Gebirge.

Im Rahmen dieser Arbeit sollen allerdings v.a. oberflächliche Massenbewegungen (Tiefgang < 10 m) in Lockergesteinen untersucht und automatisch erkannt werden. Im Folgenden werden die Untersuchungsgebiete aus ingenieurgeologischer Sicht vorgestellt.

2.3.3.1 Ingenieurgeologische Klassifikation der Gesteine

Neben der oben angeführten stratigraphischen Gliederung (Tab. 2.2) lassen sich die Gesteine auch nach ihren ingenieurgeologischen Eigenschaften gliedern. Dabei werden Fest-, Wechselfeste- und Lockergesteine unterschieden. Im Rahmen dieser Arbeit werden entsprechend der Klassifikation aus Tabelle 2.1 die Wechselfesten- und die Lockergesteine meist als Lockergesteine zusammengefasst, da die untersuchten Massenbewegungen ausschließlich in den verwitterten wechselfesten Gesteinen, also deren Lockerform auftreten.

Den *Festgesteinen* werden alle Kalke und Dolomite, unabhängig von ihrer Ausbildung und ihrem Alter, zugeordnet. Im Wesentlichen handelt es sich dabei um mächtige Kalkplatten aus Tressensteinkalk und Hallstätter Kalken. Sie liegen auf einer weichen, mobilen Unterlage und bauen die nördlichen Berggipfel (Zwerchwand, Raschbergmassiv) auf. Im Stambachgebiet sind auch isolierte Schollen von Hallstätter Kalken und Pötschenkalken aufgeschlossen, die z.T. gravitativ in ihre heutige Position geglitten sind (ROHN et al., 2002).

Die Kalke sind feinkörnig bis mikritisch, stellenweise auch brekziös und wechselnd massig bis wohlgebankt ausgebildet. Die Klüftung ist meist weitständig und die Öffnungsweite gering. Am Rand der Kalkplatten und an aktiven Abrisszonen nimmt die Kluftweite ab und die Öffnungsweite zu. Die Dolomite treten deutlich seltener auf, sind meist feinkörnig und weisen eine durchgängig engständige Klüftung auf.

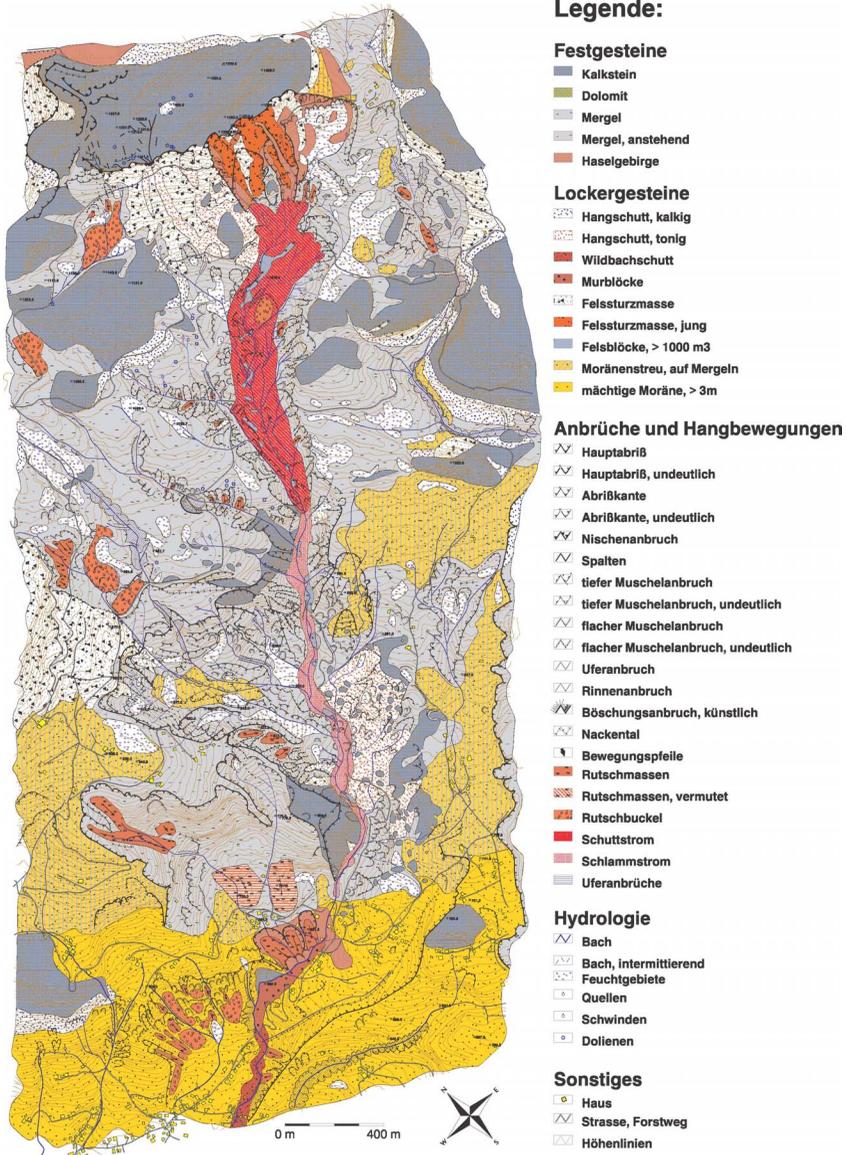


Abb. 2-11: Geotechnische Karte des Untersuchungsgebietes Stammbach (nach ROHN, 1991).

Stellenweise treten im SW des Stambachgebietes zusammen mit Kalcken der Oberalmerschichten auch Radiolarite auf, die aber ingenieur-geologisch unbedeutend sind.

Unter *Wechselfesten Gesteinen* werden Gesteine verstanden, die im unverwitterten Zustand Festgesteinscharakter aufweisen, durch Verwitterung aber ihre Festigkeit verlieren. In den Untersuchungsgebieten gehören dazu die Mergel der Zlambach- und Allgäuschichten sowie das Haselgebirge.

In beiden Untersuchungsgebieten sind die Mergel und deren Verwitterungsprodukte weit verbreitet. Je nach Kalkgehalt der Mergel wechselt allerdings deren Verwitterungsanfälligkeit und -tiefe erheblich. So sind die basalen Bereiche der Zlambachsichten, die am Kleinen und Großen Zlambach im Zlambachgebiet aufgeschlossen sind, deutlich kalkiger als die darüber liegenden und können über 40 m hohe, nahezu senkrechte Böschungen aufbauen. Die tonreicheren, überlagernden Mergelschichten verwittern wesentlich tiefer und bilden eher flache Böschungen aus. Ähnliches kann in den Mergeln der Allgäuschichten beobachtet werden, in denen westlich des Stambaches beim Wurmstein bis zu 60 m hohe, nahezu senkrechte Böschungen ausgebildet sind. Die hier etwas kieseligen Mergelheiten könnten eventuell bereits zu den hangenden, verkieselten Allgäuschichten gehören. Durch die chemische Verwitterung verlieren die Mergel ihr vorwiegend karbonatisches Bindemittel, was zu einem Festigkeitsverlust führt. Es entwickelt sich ein grauer oder brauner toniger Schluff, in dem auch quellfähige mixed-layer Tonminerale des Illit-Montmorillonit und Illit-Smecktit Typs auftreten (HÖCHERL 1991, XIANG 1997). Aufgrund ihrer Verwitterungsanfälligkeit und ihres Mineralgehaltes sind die Mergel der Zlambach- und Allgäuschichten besonders anfällig für Erosion und Massenbewegungen.

Das Haselgebirge ist nirgends in den Untersuchungsgebieten unverwittert über Tage aufgeschlossen. Im unverwitterten Zustand handelt es sich um ein Mischgestein aus Tonstein, leicht löslichem Steinsalz und Anhydrit. Wegen seiner sehr geringen Verwitterungsbeständigkeit zersetzt es sich in Oberflächennähe in eine schichtlose tonige bis schluffige Matrix, in der vereinzelt Gips, Schluff- oder Tonsteinintraclasten eingelagert sind. Im Gegensatz zu den Mergeln treten allerdings keine quellfähigen Tonminerale auf.

2.3 Modellgebiete

Legende:

Festgesteine

- Kalkstein
- Kalksteine und Dolomite
- Mergel
- Haselgebirge

Lockergesteine

- Hangschutt, kalkig
- Wildbachschutt
- Bachablagerungen
- Felssturzmasse
- Schuttstrom
- Moranenstreu, auf Mergeln

Anbrüche und Hangbewegungen

- ☒ Begrenzung Talzuschubsmasse
- ☒ Abrißkante im Festgestein
- ☒ Abrißkante im Lockergestein
- ☒ Nischenanbruch
- ☒ Spalten
- ☒ tiefer Muschelanbruch
- ☒ flacher Muschelanbruch
- ☒ Uferanbruch
- ☒ Rinnenanbruch
- ☒ Nackental
- Rutschmassen
- Uferanbrüche
- Rutschbuckel

Hydrologie

- ☒ Bach
- ☒ Feuchtgebiete
- ☒ Dolinen

Sonstiges

- ☒ Haus
- ☒ Befestigte Fahrwege
- ☒ Unbefestigte Forstwege
- ☒ Wanderwege
- ☒ Höhenlinien

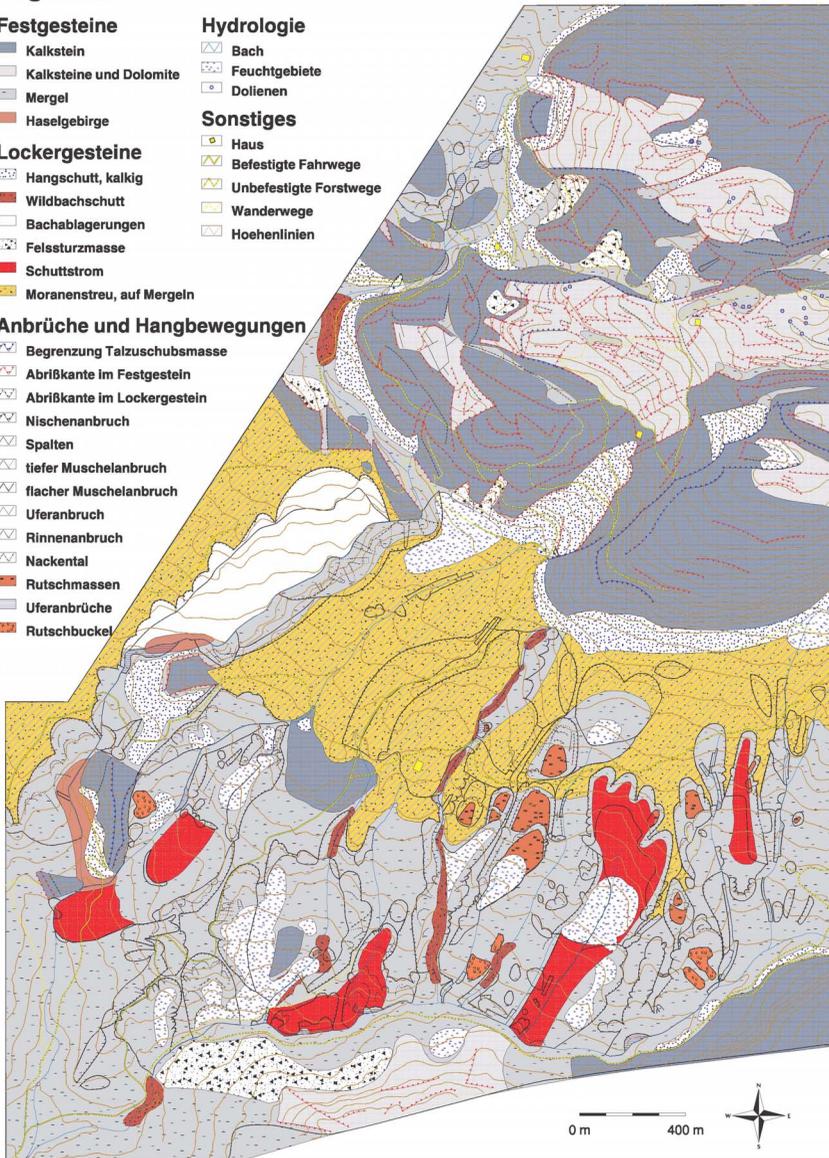


Abb. 2-12: Geotechnische Karte des Zlambachgebietes (nach RESCH, 1997).

Die Untersuchungen von ROHN (1991) und RESCH (1997) zeigen, dass das Haselgebirge eine steife bis breiige Konsistenz aufweist und diese extrem sensitiv auf Schwankungen des Wassergehalts reagiert. Aus diesem Grund sind Haselgebirgsvorkommen häufig mit Massenbewegungen verbunden.

Die bodenmechanischen Kennwerte der wechselfesten Gesteine können den Arbeiten von ROHN (1991), HÖCHERL (1991), XIANG (1997) und RESCH (1997) entnommen werden.

Tab. 2.3: Scherfestigkeit der wechselfesten Gesteine im Untersuchungsgebiet (aus ROHN 1991, HÖCHERL 1991 und XIANG 1997).

	Haselgebirge	Zlambachmergel (unverwittert)	Allgäumergel
Reibungswinkel [°]	18 - 27	35	11,2 - 22
Kohäsion [KN/m ²]	5 - 18	128	5 - 21

Unter den *Lockergesteinen* sind v.a. die Moränenablagerungen geotechnisch relevant. In den Untersuchungsgebieten wird zwischen Moränenstreu, der stellenweise bis zu 2 m mächtig wird und teilweise über 20 m mächtigen Moränen, die allerdings nur am Rand des Trauntals auftreten, unterschieden. Bei der Moränenstreu handelt es sich wahrscheinlich um Reste von Grundmoränenablagerungen aus dem Würm, während die mächtigen Moränenablagerungen im Trauntal zumindest z.T. auch Seitenmoränen der letzten Rückzugsstadien darstellen. Ansonsten sind beide gleich ausgebildet und weisen nach v. HUSEN (1977) eine wechselnde Klassierung auf. Allerdings tritt der Feinkornanteil mit 30 – 60 % deutlich hervor, gefolgt von kiesigen Komponenten mit 20 – 40 %. Die Komponenten bestehen aus den aufgearbeiteten lokal anstehenden Ton- und Mergelsteinen sowie Kalksteinen. Je nach Entkalkungsgrad weisen die Moränen deutliche Festigkeitsunterschiede auf. Besonders die mächtigen, kalkigen Moränen im Trauntal können auch mehrere Meter hohe, steile Böschungen ausbilden. In diesen können auch tiefergehende Massenbewegungen auftreten. Sonst treten vor allem Blattanbrüche und flache Muschelanbrüche (1 – 2 m) auf.

Unterhalb von Felswänden sind stellenweise sehr ausgedehnte, allerdings nur geringmächtige Hangschuttablagerungen aufgeschlossen, weshalb diese nicht berücksichtigt wurden. Die übrigen Lockergesteine bestehen aus Ablagerungen der Massenbewegungen im Untersuchungsgebiet, wie Felssturzmassen, Wildbachschutt und Schuttstromablagerungen. Aufgrund ihrer geringen Mächtigkeit oder ihres geringen Einflusses auf die Massenbewegungen sind diese bei den Analysen nicht beachtet worden, sondern nur das unterlagernde Gestein.

2.3.3.2 Massenbewegungen in den Untersuchungsgebieten

In den Untersuchungsgebieten ist auf engstem Raum eine ungewöhnlich hohe Dichte an Massenbewegungen konzentriert. Auch sind verschiedene Typen von Massenbewegungen erkennbar und deren gegenseitige Beeinflussung gut rekonstruierbar.

Während im Stambachgebiet ca. 40 % der Gesamtfläche von Massenbewegungen beeinflusst ist, ist im Zlambachgebiet ca. 70 % der Fläche von Massenbewegungen betroffen, wobei über 30 % auf große und tiefgreifende Massenbewegungen im Festgestein entfallen. Um die geotechnischen Zusammenhänge und Wechselwirkungen darzustellen, werden außer den untersuchten Massenbewegungen im Lockergestein auch die Massenbewegungen im Festgestein beschrieben.

Die *Massenbewegungen im Festgestein* konzentrieren sich im Stambachgebiet auf die Zwerchwand. Die nach NNW einfallende Pultscholle bildet an ihrem SW Rand eine bis zu 120 m hohe, über weite Strecken überhängende Felswand aus Tressensteinkalken. Die Kalkscholle liegt als rigide Platte auf einem nachgiebigen Untergrund aus Haselgebirge und Mergeln, was v.a. im Westen zu einer intensiven Zerlegung führt. Diese stärkere Zerlegung im Westen kann zum Teil auch durch den darunter liegenden Salzbergbau (ROHN, 1991) bedingt sein. Besonders interessant sind aber die Felssturzzonen und freistehenden Felstürme an der südwestlichen Steilwand. Durch Massenbewegungen am Fuß der Wand und Ausquetschung der unterliegenden Mergel sowie des Haselgebirges wird diese Wand destabilisiert. Dadurch kommt es zu riesigen Felsstürzen und Felskippen. Das wird durch die ausgedehnten Felssturzablagerungen am Fuß der Wand beeindruckend dokumentiert.

Ansonsten treten im Stambachgebiet noch vereinzelte Kalkschollen

aus Pötschen- und Hallstätter Kalken auf, die allochthon auf Mergeln liegen. Diese sind zum Teil als riesige Schollengleitungen vom Raschbergmassiv vermutlich gravitativ in ihre heutige Position geglitten (ROHN et al., 2002).

Im nördlichen Teil des Zlambachgebietes können ähnliche Phänomene wie im Stambachgebiet beobachtet werden, nur in einem größeren Maßstab. Hier ist die rigide Kalkplatte des Raschbergmassives durch Spreizungsvorgänge bereits in mehrere Schollen zerlegt, die auch intern intensiv zergliedert sind. Es scheint, dass hier der gesamte Gipfel zerfällt und einzelne Schollen gravitativ in das Tal gleiten. Randlich gehen diese Spreizungsvorgänge in große Rotationsschollen und Fels- bzw. Blockgleitungen über. Die oben beschriebenen allochthonen Kalkschollen im Stambachgebiet haben vermutlich hier ihren Ursprung. Am Rand großer Plattenfragmente sind wie an der Zwerchwand ausgehende Felssturzzoneen erkennbar, bei denen die Einzelereignisse allerdings wesentlich kleinere Dimensionen haben. Diese Massenbewegungen sind ursächlich auf die starke glaziale Erosion durch den Traungletscher im Würm zurückzuführen. Im Würm wurden durch die starke Erosion die Talflanken z.T. erheblich übersteilt. Durch den Gletscherrückzug am Ende des Würms fehlt den steilen Hängen nun das talseitige Widerlager. Durch das Abtauen des Permafrosts im Postglazial kommt es dann endgültig zur Destabilisierung der Hänge und zu Ausgleichsbewegungen in den Talflanken, sowie in den Gipfelbereichen. Dadurch versucht das Gebirge ein neues Hanggleichgewicht zu erreichen. Dieser Effekt wird noch zusätzlich durch das System von harten rigiden Kalkplatten auf weichen inkompetenten Mergeln und Tonen verstärkt. Durch den hohen topographischen Gradienten und die weiche mobile Unterlage zerbrechen die mächtigen Kalkplatten in einzelne Schollen, die sich dann in Richtung des höchsten topographischen Gradienten bewegen. Diese Spreizungsvorgänge sind in geringerem Maße an der Zwerchwand, aber umso eindrucksvoller am Raschbergmassiv und am östlich gelegenen Sandlingmassiv zu beobachten (ROHN et al., 2002).

Für die Wechselbeziehung zwischen Massenbewegungen im Fest- und Lockergestein sind vorwiegend die Vorgänge am Rand der Platten entscheidend. Hier können Felskippen und -stürze durch undrainierte Belastung in den unterliegenden Mergeln und Tonen zur Auslösung von großen Rotationsrutschungen oder zur Aktivierung von Schuttströmen führen (ROHN et al., 2002).

2.3 Modellgebiete

Häufiger treten in beiden Gebieten *Massenbewegungen im Lockergestein* auf. Dabei handelt es sich vorwiegend um Rotations- und Translationsgleitungen (s. Kap. 3.2) sowie Schuttströme (earthflows). Diese können in den Untersuchungsgebieten aber nicht isoliert betrachtet werden, da sie sich gegenseitig beeinflussen und ineinander übergehen. RESCH (1997) zeigt exemplarisch am Kleinen Zlambach, wie sich solche Systeme von der Hauptabbrisskante weg von multiplen Blockrotationsrutschungen über sich teilweise translativ bewegende ehemalige Rotationsschollen hin zu Schuttströmen entwickeln können (s. Abb. 2-13).

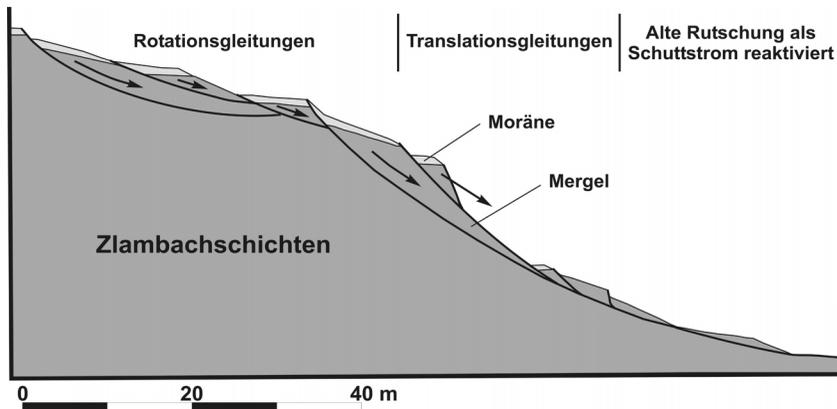


Abb. 2-13: Rutschungssystem am Kleinen Zlambach. Beginnend an der Hauptabbrisskante ändert sich die Bewegungsart von Rotationsgleitung über translative Gleitungen zu fließenden Bewegungen (verändert nach RESCH, 1997).

Bei genauerer Betrachtung der Gebiete können drei unterschiedliche Rutschungssysteme aus sich gegenseitig beeinflussenden Massenbewegungstypen beobachtet werden:

1. Systeme, bei denen ausgehend von der Hauptabbrisskante zunächst Rotationsgleitungen auftreten, die dann in translative Bewegungen (Translationsgleitung) übergehen. Häufig gehen diese dann am Fuß selbst in Schuttströme über oder sie reaktivieren alte Massenbewegungen als Schuttströme. Diese Systeme können als Ausgleichsbewegungen der durch Tiefenerosion der Bäche übersteilten Hänge verstanden werden, die wieder einen natürlichen, stabilen Böschungswinkel auszubilden versuchen.

2. Systeme, bei denen wie an den direkten Einhängen des Stambachs, die Hänge durch glaziale Erosion übersteilt sind und an denen zahlreiche Rotations- und Translationsrutschungen auftreten. Am Stambach treten diese in Wechselwirkung mit dem großen Schuttstrom. Die Rutschmassen nähren einerseits den großen Stambach-Schuttstrom und andererseits erodiert dieser die alten Rutschmassen bzw. den Hangfuß, sodass rückschreitend weitere Rutschungen entstehen.
3. Systeme, die nahe an Felswänden liegen und bei denen es durch zusätzliche Auflast von Felssturzmassen zu undrainierter Belastung kommt. Dort treten dann große Rotationsrutschungen in den unterlagernden weichen Gesteinen auf, die in der Folge wieder in Schuttströme übergehen oder solche aktivieren können.

Daneben treten noch vereinzelt Massenbewegungen auf, die aber in keine der oben genannten Kategorien passen. Es handelt sich dabei z.B. um Schuttkriechen im Hangschutt unterhalb der Zwerchwand oder Rutschbuckel, die Kriechvorgänge im Haselgebirge anzeigen. Stellenweise treten in den Gebieten größere Rutschungen auf, die aber auf lokale Ursachen wie z.B. temporäre, lokal begrenzte Porenwasserüberdrücke oder lokal auf z.T. anthropogen übersteilte Hänge zurückzuführen sind.

Im Stambachgebiet treten Rutschungssysteme aller drei Typen auf. Am Fuß der Zwerchwand sind in den ausgedehnten Hangschutt- und Felssturzmassen stellenweise Anzeichen für Schuttkriechen zu erkennen. Am östlichen Ende der Zwerchwand liegt ein großer aktiver Rutschkessel, der sich bis zur Hütteneckalm hinzieht. In diesem bewegen sich große Felssturzmassen auf einer Unterlage aus Haselgebirge hangabwärts und versorgen den großen Schuttstrom mit neuem Material. Diese Massenbewegungen gehören zu den Rutschungssystemen des dritten Typs. Die Felssturzmassen bewegen sich passiv auf dem als Rotationsrutschung oder Schuttstrom aktivierten Untergrund aus Haselgebirge und Mergeln talwärts. Diese Massen können den alten Stambachschuttstrom reaktivieren und so weitere Massenbewegungen initiieren (ROHN, 1996). Wie die Beschreibungen zeigen, hängen die Massenbewegungen im Lockergestein somit oft mit den Massenbewegungen im Festgestein zusammen bzw. stehen damit in Wechselwirkung.

2.3 Modellgebiete

Ein weiteres Rutschungsgebiet liegt an den unteren Hängen des Trauntals in mächtigen Moränenablagerungen. Hierbei handelt es sich im Wesentlichen um flache Rotations- und Translationsrutschungen. Diese sind einerseits auf die glaziale Übersteilung dieses Bereiches zurückzuführen, andererseits auf den Festigkeitsverlust der kalkigen Moräne durch die Verwitterung. Zusätzlich liegen die Hauptabbrisskanten an einer Geländestufe, was erhöhten Strömungsdruck und Porenwasserdruck bei Starkniederschlagsereignissen als zusätzliche rutschungsauslösende Faktoren wahrscheinlich macht (ROHN & FERNANDEZ-STEEGER, 2000).

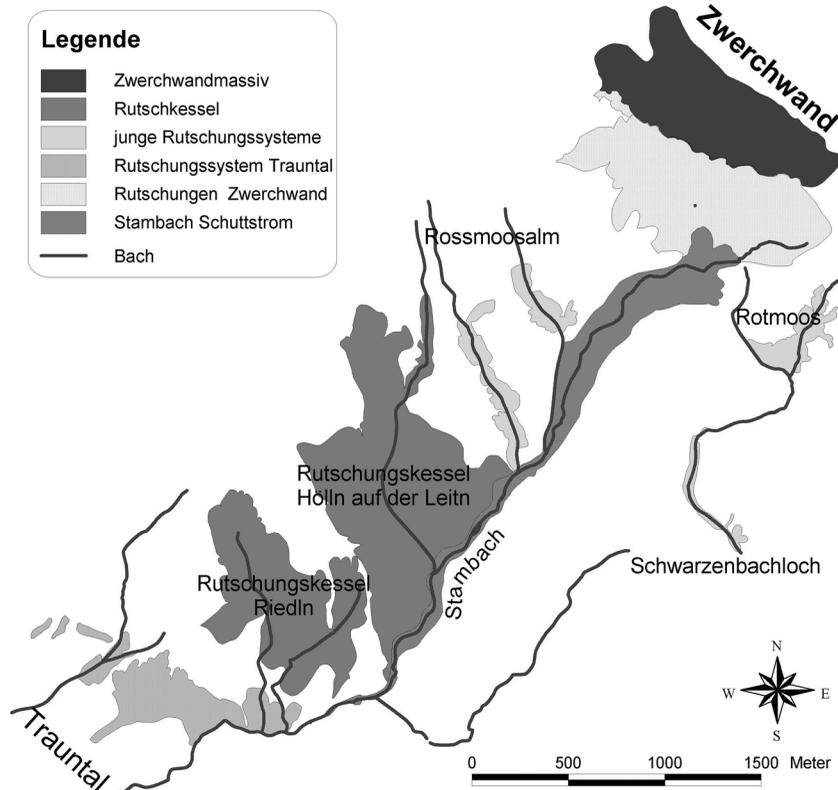


Abb. 2-14: Lage der großen zusammenhängenden Rutschkessel und Rutschungssysteme im Gebiet Stambach.

Die übrigen Rutschungen im Stambachgebiet gehören vorwiegend zu Rutschungssystemen des ersten und zweiten Typs. Für die Ausbildung der Massenbewegungen ist neben der glazialen Übersteilung der Hänge die starke Tiefenerosion der Bäche in den Untersuchungsgebieten verantwortlich. Da die Traun als Erosionsbasis der Bäche dient, müssen diese auf relativ kurzer Distanz Höhendifferenzen von bis zu 670 m (Kleiner Zlambach) überwinden. Dabei liegt das mittlere Gefälle der Bäche zwischen 15 % und 7 %, lokal sind sogar noch höhere Gefälle zu beobachten. Diese Wildbäche haben aufgrund des Gefälles eine sehr hohe Schleppekraft und erodieren die weichen Mergelgesteine sehr leicht. Die starke Tiefenerosion übersteilt die seitlichen Hänge im Einzugsgebiet der Bäche. Dies führt zu den oben beschriebenen Rutschungssystemen, in denen sowohl Rotations- als auch Translationsrutschungen und Schuttströme auftreten. Obwohl die einzelnen Rutschungen nicht besonders groß sind (Abrisskanten zwischen 10 und 40 m Länge) und der Tiefgang selten 2 m übersteigt, können sich aus diesen Systemen große Rutschungskessel mit einer Fläche von bis zu 0,65 km² bilden.

Im Gebiet Stambach ist die evolutionäre Entwicklung hin zu solchen Rutschungskesseln sehr schön nachvollziehbar und in den verschiedenen Stadien mit Beispielen belegbar. Zunächst bilden sich entlang der sich eintiefenden Bäche durch die Übersteilung der Flanken ausgeprägte Rutschungssysteme wie auf der Rossmoosalm und beim Schwarzbachloch aus (junge Wildbachsysteme in Abb. 2-14). Wenn diese sich bei weiterer Eintiefung der Bäche lateral ausbreiten, bilden sich wie bei Hölln auf der Leitn tiefe Rutschungskessel mit steilen Flanken aus. In diesen kommt es am Rand zu Rutschungen (Gleitungen) und im Inneren der Kessel zu Fließbewegungen. Die Rutschmassen im Inneren der Kessel werden z.T. durch die Bäche ausgeräumt oder erodiert. Dies führt einerseits wieder rückschreitend zur Destabilisierung der Randbereiche und andererseits wird durch die hohe Geschiebefracht die Erosionskraft der Bäche erhöht. Mit der Zeit wird das ganze verwitterte Gestein so aus den Kesseln herausgetragen, und es bleiben sehr steile weniger aktive Rutschungskessel übrig. Der Rutschungskessel bei Riedln ist ein Beispiel für solch einen alten Rutschungskessel. Dennoch sind auch in diesem noch heute aktive Massenbewegungen zu beobachten.

An den direkten Einhängen orographisch links und rechts des Stambachs liegen in den steilen Flanken des Taleinschnittes zahlreiche Rotations- und Translationsrutschungen. ROHN (1991) nimmt an, dass die-

se steilen Talflanken durch glaziale Erosion entstanden sind, und die Massenbewegungen schon lange als Liefergebiete für den großen Schuttstrom dienen. Das lässt sich an der lithologischen Zusammensetzung des Schuttstroms erkennen. Allerdings treten zumindest im oberen Teil des Schuttstroms auch Rutschungen parallel zur Aktivierung des Schuttstroms auf. Das lässt darauf schließen, dass diese in Wechselwirkung mit dem Schuttstrom stehen und durch Erosion am Fuß der zusammengesetzten Rutschungen bzw. durch Reduktion des Widerlagers (Schuttstrom) reaktiviert werden. Im unteren Bereich des Schuttstroms, der dort in einen Schlammstrom übergeht, scheint auch der Schuttstrom selbst sowie Tiefenerosion durch Wildbachvorgänge zur Destabilisierung der Talflanken beizutragen.

Im Gebiet Zlambach treten fast ausschließlich Rutschungssysteme des ersten Typs auf, die an die Wildbäche im Gebiet gebunden sind. So lassen sich 6 bis 7 große Rutschungskessel erkennen (Abb. 2-15). Während aber im Stambachgebiet die Rutschungssysteme an Wildbächen vom Trauntal weg immer jünger werden, weisen diese im Gebiet Zlambach einen sehr ähnlichen Reifegrad auf.

Prinzipiell lassen sich die Rutschkessel am Großen Zlambach von denen am Kleinen Zlambach unterscheiden. Die Kessel am Großen Zlambach sind durch das Zusammenwachsen mehrerer kleiner Kessel entstanden und breiten sich auch rezent lateral aus. Sie sind bis zu 0,9 km² groß. Im Vergleich zum Stambachgebiet sind hier auch häufiger ausgeprägte Fließbewegungen innerhalb der Kessel zu beobachten. So bilden sich auch heute noch gelegentlich große Schuttströme aus den Rutschmassen (RESCH, 1997). Am Kleinen Zlambach sind die Kessel eher langgestreckt und noch nicht ganz so weit entwickelt wie am Großen Zlambach. Zwar sind große Rutschungssysteme aus Rotations- und Translationsrutschungen ausgebildet, allerdings fehlt der Übergang zu fließenden Bewegungen. Neben den großen Rutschkesseln sind an den direkten Einhängen des Großen Zlambachs zahlreiche flache Rotations- und Translationsrutschungen zu erkennen.

Die hohe Dichte und Verbreitung von Massenbewegungen führt dazu, dass von einem zusammenhängenden Rutschungsgebiet am Großen und einem lateral weniger ausgebreiteten am Kleinen Zlambach gesprochen werden kann. Besonders am Großen Zlambach sind die Hänge nördlich des Baches bis zu einer Geländeverflachung, die sich von Pichlern über die Haller Alm bis zur Oberleislingalm hinzieht und mit den oberen Abrisskanten der Rutschkessel zusammenfällt, als instabil

oder rutschgefährdet anzusehen. Südlich des Baches reichen die Massenbewegungen bis an die Hallstätter Kalke des Hornkogel und der Pötschenwand. Am Kleinen Zlambach konzentrieren sich die Massenbewegungen auf die Hänge entlang des Baches.

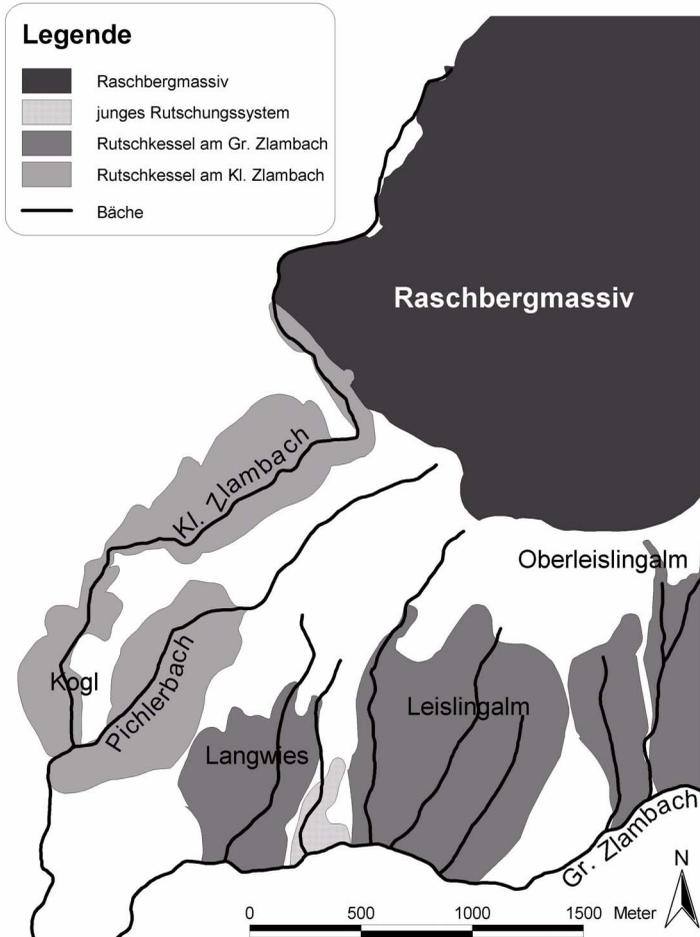


Abb. 2-15: Lage der großen zusammenhängenden Rutschkessel und Rutschungssysteme im Gebiet Zlambach.

2.3 Modellgebiete

In dem Bereich oberhalb der Hauptrutschgebiete des Großen Zlambaches und unterhalb des Raschbergmassivs sind noch größere z.T. tiefgreifende Rutschungen mit geringen Versätzen zu erkennen. Hier scheinen sich langsam neue Systeme entlang eines Baches zu entwickeln, die aber noch undeutlich sind. Ansonsten scheint dieser Bereich seit langer Zeit inaktiv zu sein.

Zusammenfassend lässt sich sagen, dass die beiden Untersuchungsgebiete in einem sehr viel größeren "Rutschungskessel" liegen, der von den Felsmassiven des Predigstuhl, der Zwerchwand, des Raschberg, der Pötschenwand und dem Trauntal im Südwesten begrenzt wird. Die untersuchten, flachen Massenbewegungen im Lockergestein sind vorwiegend auf Rutschungssysteme in Zusammenhang mit Wildbachprozessen und glazial übersteilten Hängen zurückzuführen. Im Stambachgebiet treten darüber hinaus Massenbewegungen aufgrund von undrainierter Belastung, Erosion durch Schuttströme und lokalen Porenwasserüberdruckbereichen auf.

3 MODELL UND METHODIK

Als Grundlage für Risikoanalysen von Massenbewegungen werden Gefahrenkarten („danger maps“ bzw. „level 2 maps“) oder Massenbewegungskataster („inventories“) benötigt. Diese enthalten zum einen alle vergangenen und aktuellen Massenbewegungsereignisse, zum anderen „potentiell“ instabile Hänge (EINSTEIN, 1997). Aus den Ereignissen kann über die Wiederholungsfrequenz P_G der auslösenden Faktoren einer Massenbewegung und der Verletzlichkeit V_O der gefährdeten Objekte („elements at risk“) das Risiko R ermittelt werden.

$$R = P_G \times V_O \quad (3.1)$$

Daraus ist ersichtlich, wie wichtig eine objektive, reproduzierbare Erkennung von Massenbewegungen als Basis für die Risikoanalyse ist. Nur auf einer solchen Grundlage lassen sich später sichere quantifizierbare Aussagen über ein spezielles Risiko treffen.

Für die Raumplanung reicht es jedoch, die räumliche Verteilung der nicht quantifizierten Gefahr zu kennen („susceptibility“). Diese kann z.B. durch Überlagerung der Gefahrenkarte mit der Landnutzungskarte erhalten werden. So können potentiell gefährdete Objekte erkannt werden, um im Bedarfsfall durch Detailuntersuchungen das soziale wie auch ökonomische Risiko („risk“) bzw. die Gefährdung („hazard“) zu ermitteln.

Das neu entwickelte Modell beschränkt sich deshalb ausschließlich auf die Erkennung der Gefahren d.h. der Massenbewegungen im Lockergestein (s.a. Kap. 2.2). Dabei wird besonderer Wert auf die Rutschungen gelegt, unabhängig von ihrem Bewegungsmechanismus. Neben diesen werden auch Massenbewegungen, die auf fließende Bewegungen zurückzuführen sind, wie z.B. Schuttströme, untersucht. Auch zusammengesetzte komplexe Massenbewegungen, die sich aus gleitenden und fließenden Bewegungen zusammensetzen, werden berücksichtigt, da diese wie in Kapitel 2.3.3 angedeutet, in den Gebieten häufig nicht getrennt betrachtet werden können. Im weiteren Verlauf der Arbeit wird der Begriff Rutschung auch wie im Englischen „landslide“ als Überbegriff für alle untersuchten Massenbewegungen (s.o.) benutzt. Im

Bedarfsfall wird auf die Bewegungsmechanismen eingegangen.

3.1 Modell

Prinzipiell wird bei der Gefahrenerkennung bzw. Rutschungserkennung zwischen quantitativen und qualitativen Verfahren unterschieden. Die Basis qualitativer Rutschungsuntersuchungen für Gefahrenkarten ist die Felduntersuchung durch den Geologen bzw. Geotechniker im Gelände. Dieses Verfahren hat allerdings den Nachteil, dass es stark von der Erfahrung des Bearbeiters (subjektiv) abhängt und sehr zeitintensiv ist (FERNANDEZ-STEGER & CZURDA, 2001).

Einen Ausweg aus diesem Dilemma bilden die quantitativen Untersuchungen mit deterministischen oder statistischen Methoden, die seit Anfang der 80er Jahre eine starke Entwicklung erleben (s. CHUNG et al, 1995). Hier wird mit Modellen versucht, die Untersuchungen und Entscheidungsprozesse der qualifizierten Bearbeiter zu simulieren bzw. zu ergänzen. Eine Möglichkeit dafür bieten die hier verwendeten künstlichen Neuronalen Netze aus dem Bereich der künstlichen Intelligenz (s.a. KOBAYASHI et. al. 1998, ALEOTTI & CHOWDHURY 1999).

Die Grundidee dieses quantitativen Modells mit Neuronalen Netzen ist somit, den Entscheidungsprozess des Geologen bei der Unterscheidung von stabilen und instabilen Hangbereichen zu simulieren. Daraus ergibt sich die Frage: Wie erkennen Geologen Rutschungen im Gelände ?

Um ein Bild von dem Gelände und den Prozessen innerhalb des Gebietes zu erhalten, untersucht der Geologe im Wesentlichen das Gebiet auf folgende Merkmale:

- Geologie (z.B. Gesteinsart, Raumstellung der Gesteine)
- Morphologie (z.B. Hangneigung, Hangform)
- Vegetation (z.B. Alter und Wuchs von Bäumen, Landnutzung)
- Topographie (z.B. Bäche, Strassen)
- untergeordnet auch Klima (z.B. niederschlagsreiche Gebiete, aride Gebiete)

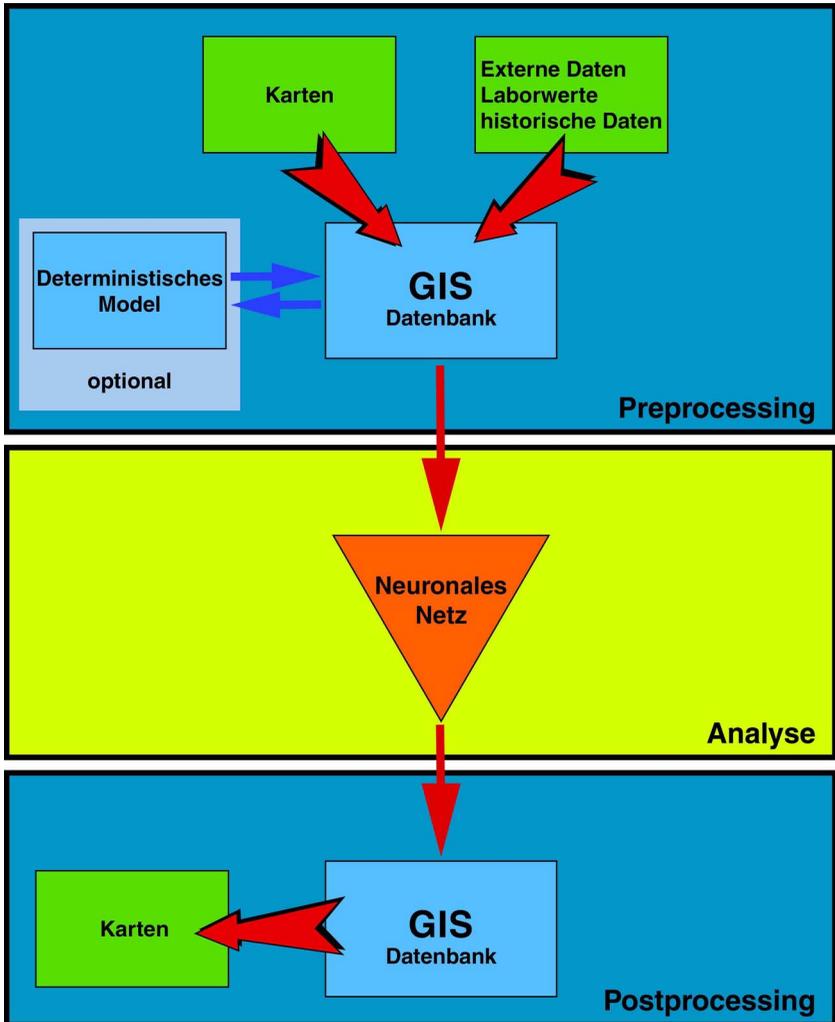


Abb. 3-1: Schematische Darstellung der Arbeitsschritte des Modells zur Erkennung von Rutschungen mit Neuronalen Netzen. Die Pfeile stellen die Datenwege dar, wobei die dicken Pfeile die Schnittstellen zur „realen“ Welt darstellen.

Dies bedeutet, dass der Geologe das Gelände entsprechend seiner Erfahrung klassifiziert. Stark vereinfacht kann dieser Prozess als Vergleich der realen Geländesituation mit Faktoren, welche die Hangstabilität beeinflussen, oder mit Merkmalen von Massenbewegungen (s. Kap. 2.2) gesehen werden. Wenn mehrere dieser Faktoren oder Merkmale übereinstimmen und entsprechend ihrer Bedeutung gewichtet werden, kann der untersuchte Bereich dann z.B. als Massenbewegung erkannt werden.

Diese Vorgehensweise lässt sich mit der klassischen Mustererkennung vergleichen und ist mit Neuronalen Netzen simulierbar. So können dem Netz die Faktoren bzw. Merkmale einer Situation oder eines Bereiches als Eingabemuster zur Verfügung gestellt und von diesem analysiert werden. Um das Netz zu trainieren, kann aus mehreren solchen Mustern von stabilen und instabilen Geländesituationen eine Trainingsmenge gebildet werden. An dieser lernt das Netz, die Situation zu klassifizieren.

Daraus ergibt sich eine klar gegliederte Vorgehensweise:

- Um eine Trainingsmenge aus Trainingsmustern aufbauen zu können, müssen die geologischen, morphologischen und topographischen Informationen sowie Informationen zur Vegetation gesammelt und aufbereitet werden. Zunächst wird aus den Geländeinformationen ein vereinfachtes virtuelles Abbild des Geländes, ein digitales Geländemodell (DGM) in einem Geoinformationssystem (GIS) erstellt. Dieses DGM kann dann mit Hilfe des GIS analysiert werden, um die für die Rutschungserkennung relevanten Informationen zu ermitteln. Das GIS bildet damit, wie aus Abbildung 3-1 ersichtlich, das „Herz“ des *Preprocessing* (Vorverarbeitung). In diesem werden die Merkmale bzw. die für die Untersuchungen relevanten Faktoren aus dem virtuellen Geländemodell extrahiert und vorverarbeitet. Zusätzlich können dem DGM Informationen wie Expertenwissen, deterministische Modelle, Laboruntersuchungen ortsbezogen hinzugefügt werden.
- Anhand einer im Preprocessing erstellten Trainingsmenge lernt ein geeignetes Neuronales Netz-Modell in der *Analyse* das Gelände in stabile und instabile Bereiche zu trennen. Um die Generalisierungsfähigkeit zu überprüfen, wird die Leistungsfähigkeit des trainierten

Netzes noch mit einer unabhängigen Testmenge überprüft. Die Analyse findet in einem Modul außerhalb des GIS statt.

- Die Ergebnisse der Analyse werden im *Postprocessing* wieder in das GIS zurückgespielt und ortsbezogen gespeichert. Um die Ergebnisse zu verifizieren oder zu verbessern, können im Postprocessing noch zusätzliche Untersuchungen durchgeführt werden. Mit dem GIS kann die Ausgabe des Neuronalen Netzes auch visualisiert werden, sodass später Gefahrenkarten erstellt werden können. Anhand dieser Karten kann die Leistungsfähigkeit der Analyse zusätzlich analytisch überprüft werden, um die Fähigkeiten des Neuronalen Netzes noch differenzierter zu beurteilen.

In Abbildung 3-1 sind die wichtigsten Verarbeitungsmodule und die Pfade der Datenverarbeitung schematisch dargestellt.

Im Folgenden werden die Module und die Datenverarbeitung im Einzelnen vorgestellt. Dabei werden sowohl die Datenaufbereitung und die benötigten Werkzeuge, als auch die Optimierungsmöglichkeiten und Entwicklungsschritte für das Neuronale Netz-Modell betrachtet.

3.2 Datenaufbereitung (Preprocessing)

Wie erwähnt, werden sämtliche erhältliche Informationen zu den Untersuchungsgebieten in einem *Geoinformationssystem* (GIS) digital gespeichert und aufbereitet. Aus diesen wird im GIS ein *digitales Geländemodell* (DGM) erstellt, welches die Grundlage für alle weiteren Untersuchungen bildet. Aus dem DGM werden anschließend die *Merkmale von Massenbewegungen* entwickelt und extrahiert. Diese Merkmale werden *codiert* und über eine ASCII-Schnittstelle aus dem GIS exportiert, um sie als Trainings- oder Testmenge mit den Neuronalen Netzen zu analysieren.

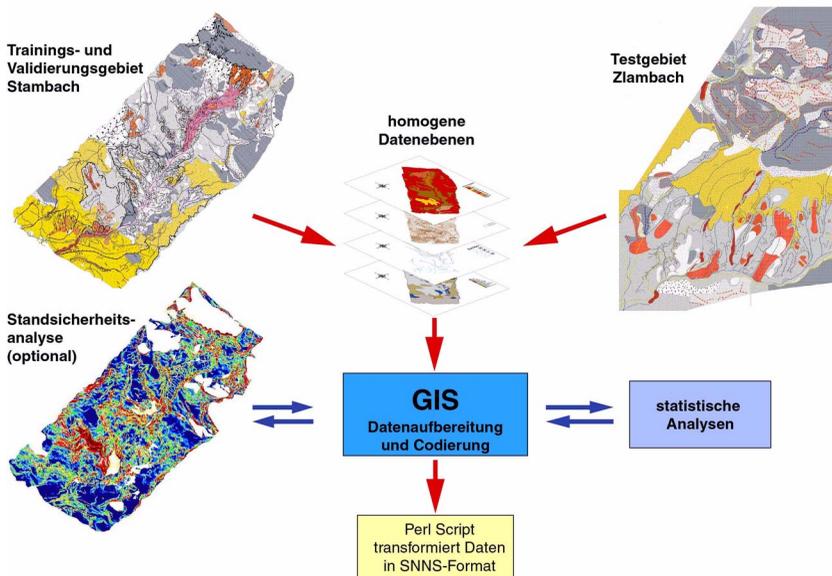


Abb. 3-2: Schematische Darstellung der Arbeitsschritte im Preprocessing.

3.2.1 Geoinformationssysteme (GIS)

Das GIS wird in dieser Arbeit vorwiegend als eine Art Datenbank genutzt, die Informationen ortsbezogen speichert und adressiert. Dadurch können Informationen auch in ihrem räumlichen Bezug zueinander dargestellt und analysiert werden. Darüber hinaus verfügen ausgereifte

highend GIS auch über umfassende Analysewerkzeuge für statistische und räumliche Analysen.

In dieser Arbeit wird die GIS-Software Arc/Info 8.01 der Firma ESRI verwendet. Diese hat den Vorteil, dass sowohl Vektor- als auch Rasterdaten (s.a. Abb. 3-4) gleich gut verarbeitet und ineinander transformiert werden können. Die Informationen werden bei Arc/Info in Datenebenen („coverages“) gespeichert. Vereinfacht können die Datenebenen als digitale Kartenblätter verstanden werden, die mit einem Koordinatensystem versehen sind. An die einzelnen Elemente auf den Kartenblättern können sog. Attributtabelle angehängt werden, in denen die Eigenschaften der Elemente weiter spezifiziert werden. Elemente können prinzipiell Punkte, Linien, Polygone bzw. Flächen oder Rasterzellen sein (s. Abb. 3-4). Ein weiterer Vorteil von Arc/Info sind die zahlreichen Analysewerkzeuge, die sich durch Programmierung beliebig erweitern oder kombinieren lassen. Darüber hinaus können auch große Datenmengen gut verwaltet und schnell verarbeitet werden.

3.2.2 Digitales Geländemodell (DGM)

Unter einem digitalen Geländemodell (DGM) wird ein digitales, virtuelles Abbild eines Geländes verstanden, das ähnlich einer topographischen Karte alle wichtigen geländebezogenen Informationen enthält. Es setzt sich meist aus dem digitalen Höhenmodell (DHM) und den digitalen topographischen Informationen wie Gewässer, Infrastruktur oder Vegetation zusammen. In dieser Arbeit ist das digitale Geländemodell um geologische und geotechnische Informationen erweitert worden (s. Abb. 3-3), sodass es korrekterweise digitales geologisches Geländemodell heißen müsste.

Damit das DGM sinnvoll genutzt werden kann und in sich homogen ist, müssen zumindest die folgenden Grundvoraussetzungen erfüllt sein:

1. Die Daten müssen in ähnlicher Qualität und Auflösung vorliegen. Dabei gibt die schlechteste Datenebene die Auflösung und Qualität des gesamten Modells vor.
2. Die Informationen müssen in homogenen Informationsebenen organisiert werden.

Der erste Punkt ist für die Vergleichbarkeit der Informationen und die Fehlerbetrachtung von Bedeutung. Zu starke Auflösungsunterschiede

3.2 Datenaufbereitung (Preprocessing)

machen es fast unmöglich, alle Daten auf Zellbasis gleichzeitig zu verarbeiten und zu analysieren. Es kann nicht mehr sichergestellt werden, dass die betrachtete Zelle die „Geländesituation“ in allen Aspekten wirklich widerspiegelt. Dadurch kann sich der Fehler im Modell beträchtlich erhöhen. Deshalb gibt immer die schlechteste Datenebene die maximale Auflösung und somit auch die Qualität des gesamten DGM vor. Es ist also wichtig, immer möglichst „gute“ und hochauflösende Daten zu verwenden. Im Zweifelsfall sollten Informationen im Modell unterdrückt (weglassen) werden.

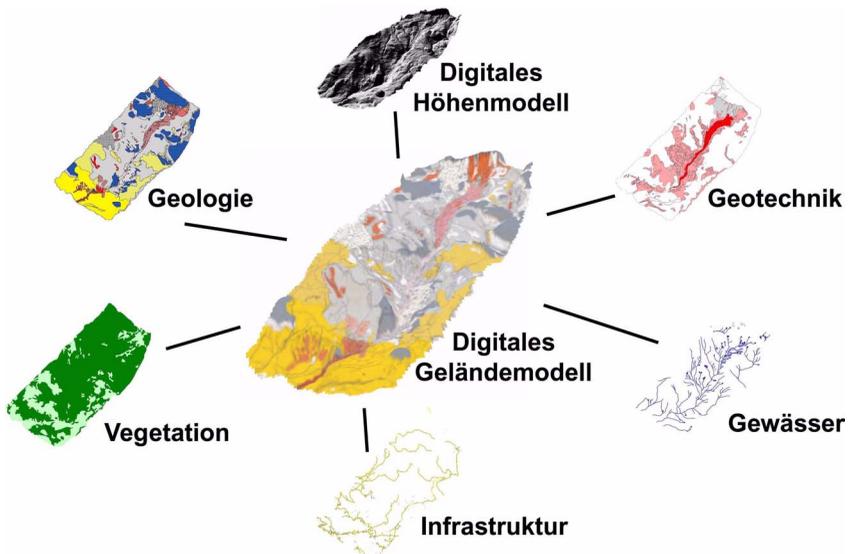


Abb. 3-3: Schematische Darstellung des digitalen „geologischen“ Geländemodells (DGM) und der Informationsebenen, aus denen es sich zusammensetzt.

Homogenität der Informationsebenen ist notwendig, um die Daten beliebig kombinieren und in verschiedene Datenformate überführen zu können. Auf diese Weise kann die Flexibilität des DGM erhöht werden. Die Informationen können z.B. als unskalierte Vektordaten gespeichert und in einer gewünschten Auflösung gerastert werden (Abb. 3-4). Dabei darf die Auflösung des Rasters jedoch nicht die Auflösung bzw. Genauigkeit der Informationen, die in das DGM eingehen, überschreiten.

Ein Problem beim Rastern von Daten ist, dass das Standard-Rasterformat nur eine Information (Wert) pro Zelle speichern kann. Wenn vermischte Informationen in einem Datenformat z.B. Vektorformat vorliegen, müsste beim Umwandeln in das Raster gegebenenfalls entschieden werden, welche davon gespeichert werden soll.

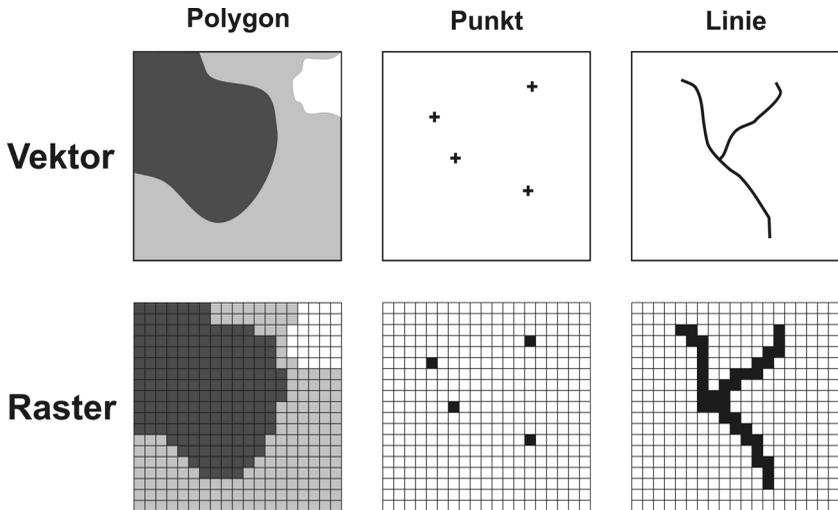


Abb. 3-4: Überführung von vektorisierten Daten in Rasterdaten. Die maximal mögliche Auflösung des Rasters wird durch die Genauigkeit der Vektordaten vorgegeben (Aufnahmege nauigkeit und Fehler).

In der Praxis bedeuten homogene Informationsebenen, dass jede Information in einer eigenen Datenebene (coverage) gespeichert wird. Dazu müssen sowohl thematisch unterschiedliche Informationen als auch innerhalb dieser Linien-, Polygon- oder Punktinformationen voneinander getrennt gespeichert werden. So werden z.B. Bachverläufe, die eine linienhafte Information sind, getrennt von Seen gespeichert, die eine flächenhafte Information sind, obwohl beide zu den Gewässern gehören. Die daraus resultierende starke Aufspaltung der Informationen ist unproblematisch, da es im GIS sehr einfach ist, Informationen wieder zusammenzufügen. Sie hat sogar den Vorteil, dass die Datenabfrage und Analyse später weitgehend automatisiert und vereinfacht werden kann. Umgekehrt ist die spätere Trennung von Daten sehr aufwendig und häufig nicht automatisch realisierbar.

3.2 Datenaufbereitung (Preprocessing)

Die sinnvolle und richtige Trennung der Daten ist auch bei dieser Arbeit ein zentraler Punkt der Datenaufbereitung. Der größte Teil der Daten war nur in analoger Form als geotechnische Karten im Maßstab 1:5000 vorhanden (s. Abb. 2-11 Und 2-12).

Diese Karten werden im Englischen als „*condensed maps*“ (MORGENSTERN, 1997) bezeichnet, was andeutet, dass in ihnen viele Informationen in einer sehr hohen Dichte zusammengefasst sind. Sie enthalten einerseits topographische Informationen, wie Höhenlinien, Bachläufe oder Strassen und andererseits geologische und geotechnische Informationen wie Gesteinsart, Abrisskanten oder Ablagerungen von Massenbewegungen. Im Rahmen dieser Arbeit sind die Informationen aus den geotechnischen Karten in folgende Informationsebenen getrennt worden:

- Anstehende Gesteine (Lithologie)
- Lockergesteine
- Ablagerungen von Massenbewegungen
- Abrisskanten
- Bäche
- Quellen, Dolinen, Schwinden (Karst)
- Feuchtgebiete (Vegetation / Massenbewegungen)
- Häuser
- Straßen

Darüber hinaus sind folgende Informationsebenen in das DGM eingefügt worden:

- Höhenlinien (Höhenmodell)
- Vegetation
- Gefahrenbereiche (z.B. Rutschmassen)

Die Grundlage für das Höhenmodell des Stambachgebietes bildet ein Höhengschichtplan mit 10 m Abständen, der von der Universität München erstellt wurde. Für das Zlambachgebiet liegt ein verdichteter Hö-

henschichtplan mit 20 m Abständen vor. Zusätzlich sind alle Höhenstützpunkte und das digitale Geländemodell des Bundesamtes für Eich- und Vermessungswesen in das Modell eingeflossen.

Mit dem Topogrid-Werkzeug von Arc/Info sind verdichtete und optimierte digitale Höhenmodelle (DHM) auf diesen Grundlagen erstellt worden. Das Topogrid berücksichtigt dabei Flussläufe und Bäche, sodass ein hydrologisch korrektes digitales Höhenmodell auf Rasterbasis entsteht. Um den Nachteil der schlechteren Skalierbarkeit des Rastermodells zu minimieren, ist ein Höhenmodell in 5 m Rasterweite erstellt worden. Dieses kann auf die gewünschte Auflösung vergrößert werden.

Bei der Vegetation wurde nur die Bewaldung in Betracht gezogen. Diese wurde aus der digitalen ÖK 25 entnommen, da hier im Gegensatz zu Forstkarten auch kleinere Baumgruppen aufgeführt sind. Die tatsächliche Auflösung der Informationen ist allerdings schwer abzuschätzen. Durch Luftbildauswertung von Falschfarbenaufnahmen kann hier im Bedarfsfall noch eine Verbesserung der Datengrundlage erzielt werden, bei der dann auch eine Differenzierung der Vegetation möglich ist.

Um die Netze zu trainieren und die Qualität der Modelle zu überprüfen, müssen die Gefahrenbereiche, also die Bereiche, die von Massenbewegungen betroffen sind, in die DGM's aufgenommen werden. Darum sind die Gefahrenbereiche zusammen mit den Bearbeitern der geotechnischen Karten festgelegt und digitalisiert worden. Für das Zlambachgebiet lag zusätzlich noch eine Gefahrenkarte von RESCH (1997) vor, die nochmals überarbeitet wurde. Prinzipiell wurden dabei alle Bereiche als Gefahrenbereiche ausgewiesen, die unterhalb von Abrisskanten liegen. Als untere Begrenzung wurde die Ablagerung der Rutschmasse oder deren Erosionsbasis, also die Bäche hangabwärts, festgelegt. In Zweifelsfällen wurde anhand von Erfahrungswerten die Reichweite der Rutschung eingeschätzt und begrenzt. Aufgrund dieser Vorgehensweise ist der ganze Einflussbereich der Rutschung, also Abrisszone, Rutschungsbahn und Ablagerungsbereich, als Gefahrenbereich definiert und kartiert. Dies ist insofern sinnvoll, weil im gesamten Einflussbereich der Rutschung eine Gefährdung für Objekte durch Rutschmassen oder Bodenbewegungen besteht.

Die maximale Auflösung der digitalen Geländemodelle richtet sich hier vor allem nach der maximalen Auflösung der Höhenmodelle. Um aufgrund der schlechteren Datengrundlage im Gebiet Zlambach auf der si-

cheren Seite zu liegen, ist als maximale Auflösung eine Rasterweite bzw. Toleranz von 20 m gewählt worden. Mit geringen Fehlern wäre allerdings auch eine Rasterweite von 10 m möglich. Im Stambachgebiet ist generell eine Auflösung in einer 10 m Rasterweite möglich. Allerdings sind keine Analysen in einer Rasterweite unterhalb von 20 m durchgeführt worden, um die Ergebnisse in beiden Gebieten bei gleicher Auflösung und Qualität vergleichen zu können.

3.2.3 Untersuchungseinheiten („sample units“)

Für die Analyse müssen die Daten zunächst auf einheitliche Mustereinheiten bzw. Untersuchungseinheiten („sample units“) bezogen werden.

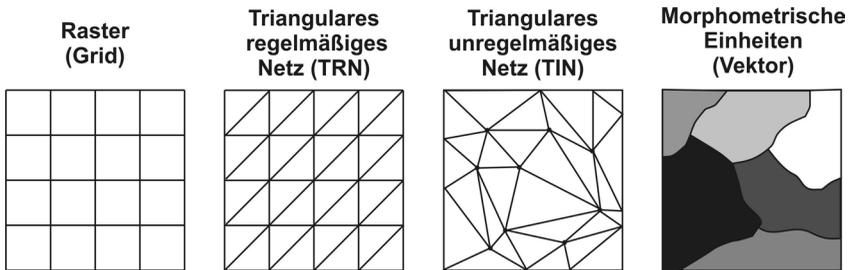


Abb. 3-5: Mögliche Formate für Untersuchungseinheiten. Das TRN und TIN sind punktgestützte Verfahren, bei denen versucht wird, die Vorteile des Raster- und Vektorformates zu verbinden.

Ein bewährtes Verfahren ist die Verwendung eines quadratischen Rasters, das Grid. Dabei wird ein quadratisches Raster über die Datenebenen gelegt und für jede Zelle die darin vorherrschenden Informationen abgerufen. Wenn die Informationen aus allen Datenebenen zusammengefasst werden, entsteht für jede Zelle ein Muster, das sie charakterisiert. Dieses Muster kann dann auf das typische Muster für Rutschungen untersucht werden.

Neben dem Grid könnten aber auch trianguläre regelmäßige Netze (TRN), trianguläre unregelmäßige Netze (TIN) oder morphometrische Einheiten wie homogene Hangbereiche (s. CHUNG et al., 1995) als Untersuchungseinheit benutzt werden (Abb. 3-6).



Abb. 3-6: Untersuchungseinheit in einem Grid. Die Merkmale bzw. Eigenschaften der Zelle werden codiert in Zeilen gespeichert. So entsteht ein für die Zelle charakteristisches Muster, das analysiert werden kann.

Da das Grid ein sehr weit verbreitetes Datenformat ist, wurde es hier als Format für die Untersuchungseinheiten gewählt. Es hat den Vorteil, dass Daten aus anderen Formaten sehr einfach umgewandelt werden können (s.a. Abb. 3-4). Die Zellen können im Rasterformat zudem einfacher miteinander verglichen werden, da sie gleich groß sind. Wichtig ist allerdings, die Raster- bzw. Zellgröße so zu wählen, dass der Inhalt einer Zelle auch den Bereich, den sie im Gelände abdeckt, richtig darstellt. Deshalb sollte eine möglichst hohe Auflösung gewählt werden, da es dann wahrscheinlicher ist, dass die Zelle auch in komplexen Geländen tatsächlich den Bereich charakterisiert (s.a. Kap 4.1.2). Die große Anzahl an Untersuchungseinheiten, die dadurch entsteht, ist bei der Analyse mit Neuronalen Netzen von Vorteil. Im Gegensatz zu manchen Regressionsverfahren und multivariablen Analysen können Neuronale Netze große Datenmengen sehr gut verarbeiten (s.a. CHUNG et al., 1995).

3.2.4 Auswahl der Merkmale

Unter Merkmale oder Features werden die Eigenschaften des Geländes verstanden, die dieses charakterisieren. Die Eigenschaften werden für jede Untersuchungseinheit bzw. Zelle ermittelt und tabellarisch gespeichert. So entsteht für jede Zelle ein Muster, das vom Neuronalen Netz analysiert wird. Diese Merkmale bilden den Eingabevektor eines Musters, der vom Neuronalen Netz klassifiziert wird.

Da das DGM im GIS ein „echtes“ Modell ist, können sowohl bestehende Informationen bzw. Merkmale aus diesem abgefragt werden, als auch „neue“ Merkmale extrahiert werden. Es können z.B. aus dem DHM des Geländemodells neben den absoluten Höhen auch die Hang-

neigung, Hanglänge, Höhenänderung und die Hangexposition ermittelt werden. Durch Verknüpfen von Abfragen können auch räumliche Beziehungen wie Entfernung einer Zelle zum nächsten Bach oder die Größe des hydrologischen Einzugsgebiets untersucht werden.

Da nicht alle ermittelbaren Geländemerkmale gleich wichtig oder unwichtig für die Erkennung von Rutschungen sind, muss eine sinnvolle Auswahl getroffen werden. Dies ist auch aus Sicht der Optimierung der Neuronalen Netze wünschenswert. Da von der Anzahl der Merkmale auch die Dimension des Eingabevektors abhängt, hat deren Anzahl auch einen direkten Einfluss auf die strukturelle Stabilität und damit auf die Generalisierungsfähigkeit des neuronalen Modells (s. Kap. 2.1.3). Wenn die Merkmale bzw. deren Anzahl das Gelände hinsichtlich der Fragestellung zu schlecht beschreiben, kann das Netz das Gelände nur ungenügend klassifizieren. Ist die Anzahl der Merkmale und freien Parameter im Modell zu hoch kommt es zu Overfitting.

Die entscheidende Frage ist somit, welche Parameter das Gelände hinsichtlich seiner Rutschungsanfälligkeit gut beschreiben bzw. welche Merkmale für die Analyse ausgewählt werden sollten. Prinzipiell kann die Auswahl nach folgenden Kriterien erfolgen:

- Erfahrungswerte
- Expertenmeinung
- statistische Analysen, z.B. Korrelationsanalysen
- Erfahrungen aus anderen Modellen oder Literatur-Recherche
- Erfahrungen aus der Entwicklung des Neuronalen Netz-Modells, z.B. eliminieren von unwichtigen Neuronen
- „trial and error“

Für die Vorauswahl sind im Wesentlichen die Merkmale verwendet worden (s Tab. 3.1), die nach gängiger Meinung rutschungsfördernd sind (CRUDEN & VARNES 1996, POPESCU 1994) und mit dem vorhandenen Datenmaterial realisierbar waren. Zusätzlich sind noch die Merkmale „absolute Höhe“, „Hanglänge“, „Abstand zu Festgesteinen“ und „Abstand zu Bächen“ eingeführt worden. Beim Vergleich von Abbildung 2-7 und 3-7 wird ersichtlich, dass die verwendeten Merkmale im Wesentlichen den Faktoren entsprechen, welche die Hangstabilität beeinflus-

sen. Allerdings muss das Modell nicht ganz so hoch parametrisiert werden, da manche Merkmale mehrere Faktoren beinhalten. So drückt die Gesteinsart auch Gesteinsfestigkeit, Durchlässigkeit, Mineralgehalt, charakteristische Klüftung, Verwitterungsverhalten und Kompetenzunterschiede in einem Parameter aus (s.a. Kap. 4.1.3).



Abb. 3-7: Merkmale die als mögliche Eingabe in das Neuronale Netz-Modell getestet wurden. Die Merkmale sind wie in Abb. 2-7 dargestellt den Gruppen zugeordnet, welche die Hangstabilität beeinflussen.

In Tabelle 3.1 ist die Entwicklung der Merkmale des Eingabevektors über die 4 Entwicklungsstufen bis zum letzten Modell dargestellt. Während in den ersten 3 Stufen vorwiegend eine adaptive Anpassung vorgenommen wurde, sind in der 4. Stufe auch Korrelationsanalysen durchgeführt worden. Mit Hilfe der Korrelationsmatrixen aller möglichen Merkmale konnte nochmals eine deutliche Optimierung der Merkmalsauswahl erzielt werden. Da manche Merkmale mehrere Parameter umfassen (siehe oben), können hoch korrelierte Merkmale weggelassen werden. Gerade die Korrelationsanalysen zeigen oft auch verborgene Beziehungen zwischen den Merkmalen und tragen dazu bei, die Komplexität des Modells besser zu kontrollieren.

3.2 Datenaufbereitung (Preprocessing)

Tab. 3.1: Merkmale des Eingabevektors und deren Veränderung über die einzelnen Entwicklungsstufen des Modells (von evo1 bis evo4) hinweg. Die helleren Merkmale sind in der jeweiligen Entwicklungsstufe hinzugefügt worden. In der dritten Evolutionsstufe ist das Merkmal „absolute Höhe“ später zusätzlich eingefügt worden.

evo1 13 Merkmale	evo2 14 Merkmale	evo3 20 / 21 Merkmale	evo4 17 Merkmale
Hangneigung	Hangneigung	Hangneigung	-
Hangexposition	N-Exposition	N-Exposition	N-Exposition
-	S-Exposition	S-Exposition	S-Exposition
absolute Höhe	-	(absolute Höhe)	absolute Höhe
Bäche	Bäche	Bäche	Bäche
Abstand zu Bächen	Abstand zu Bächen	Abstand zu Bächen	Abstand zu Bächen
Fließrichtung	Fließrichtung	Fließrichtung	-
Vegetation	Vegetation	Vegetation	Vegetation
Standstabilitätsfaktor	Standstabilitätsfaktor	Standstabilitätsfaktor	Standstabilitätsfaktor
Gesteinsart (5 Klassen)	Gesteinsart (5 Klassen)	Gesteinsart (5 Klassen)	Gesteinsart (5 Klassen)
	Abstand zu Festgestein	Abstand zu Festgestein	Abstand zu Festgestein
		absolute Höhenänderung	-
		Größe des Einzugsgebietes	Größe des Einzugsgebietes
		Hanglänge	Hanglänge
		Hangform (2 Klassen)	Hangform (1 Klasse)
		Änderung der Hangneigung	Änderung der Hangneigung

Bei den Korrelationsanalysen muss beachtet werden, dass auch die Codierung (s. Kap. 3.2.5) einen Einfluss auf die Korrelation haben kann. Deshalb sollten die Korrelationsanalysen sicherheitshalber nochmals mit den codierten Daten gemacht werden.

Die Merkmalsselektion und ihre Optimierung ist somit ein sehr wichtiger Bestandteil der Modellentwicklung. Grundsätzlich sollten Merkmale, die zu anderen hoch korreliert sind, weggelassen werden. Die optimale Anzahl der Merkmale für ein Modell muss iterativ bzw. entsprechend den

Erfahrungen mit dem Modell ermittelt werden. Um die Modelle auch interpretieren zu können sollten Merkmale, deren Einfluss überhaupt nicht erklärbar ist, unter Umständen weggelassen werden.

3.2.5 Codierung der Merkmale

Der zweite kritische Punkt im Preprocessing neben der Merkmalsauswahl ist die Codierung der Merkmale. Durch die Merkmalsselektion wird festgelegt, auf welche Eigenschaften ein Gelände untersucht werden soll. Die Codierung ist die Umsetzung dieser Eigenschaften in eine für Neuronale Netze analysierbare Form. Dabei reicht es aber nicht, die Daten einfach nur wie in Kap. 2.1.1 gefordert, in einen Zahlenraum zwischen 0 und 1 bzw. -1 und 1 umzuwandeln. Vielmehr ist es so, dass die Codierung eine Art intelligente Abfrage der Merkmale darstellt, damit die Informationen in dem Zahlenraum ausgedrückt werden können.

Es müssen also immer die richtigen „Fragen“ gestellt werden, um eine gute Codierung zu erhalten. Um z.B. das Merkmal „Exposition“ zu codieren, muss zuerst die Frage gestellt werden, welchen Einfluss die Exposition hat und welche Expositionen wichtig sind. In SCHÖGER (1988) wird diskutiert, ob in Bezug auf Sonneneinstrahlung bzw. Wasserhaushalt eine N- oder S-Exposition eher rutschungsfördernd ist. Da es für beide Möglichkeiten eine Reihe guter Argumente gibt, ist es sinnvoll, beide Möglichkeiten in Betracht zu ziehen. Umgekehrt können E- und W-Expositionen vernachlässigt werden, da sie in Bezug auf Sonneneinstrahlung und Wasserhaushalt nicht ausdrücklich rutschungsfördernd sind. Daher ist für die Codierung der Exposition die Frage wichtig, wie stark ein Hang N- oder S-exponiert ist.

Es gibt mehrere Möglichkeiten, die „Fragen“ bzw. Daten zu codieren:

1. *Normalisierung der Daten* auf den Zahlenraum zwischen 0 und 1 bzw. -1 und 1. Das ist bei Variablen sehr einfach, bei denen bekannt ist, ob ein niedriger oder hoher Wert die Hangstabilität besonders beeinflusst.
2. *Binäre Codierung der Daten* mit 1 oder 0. Dies ist dann möglich, wenn zur Datenabfrage eine Frage formuliert werden kann, die mit richtig oder falsch beantwortet werden kann.

3. *Klassifizierung der Daten.* Die Bildung von Klassen ist immer dann vorzuziehen, wenn bei Variablen nicht bekannt ist, welcher Wert bzw. Wertebereich die Hangstabilität besonders beeinflusst.

Daraus ist ersichtlich, dass bei der Codierung auch die Art der Daten eine Rolle spielt. Da z.B. die „Exposition“ in Himmelsrichtungen bzw. Grad angegeben wird, ist die Normalisierung nicht so einfach, zumal nicht klar ist, ob die S- oder N-Exposition die Hangstabilität besonders negativ beeinflusst. Eine rein binäre Codierung ist auch nicht sinnvoll, da damit die Information unterdrückt wird, dass E- und W-Hänge eher rutschungsunempfindlich sind. Es könnten aber z.B. für jeden Quadranten eine bzw. mehrere Klassen gebildet werden. Um den Eingabevektor allerdings nicht zu groß werden zu lassen, bietet sich eine Kombination von Normalisierung und Klassenbildung an. Die Exposition kann mit der Cosinusfunktion so umgewandelt werden, dass die Maxima (1) bzw. Minima (-1) der Funktion genau mit N bzw. S zusammenfallen. Um beide Richtungen gleichberechtigt analysieren zu können, werden dann die negativen und positiven Werte getrennt und auf den Bereich 0 bis 1 normalisiert. Dieses Beispiel zeigt, dass die Codierung nicht als einfache Aufgabe betrachtet werden kann, sondern mit großer Sorgfalt durchgeführt werden muß.

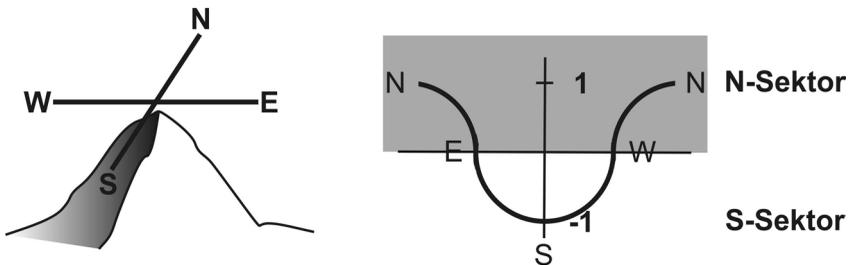


Abb. 3-8: *Codierung der Exposition durch Normalisierung mit der Cosinusfunktion. Der inverse Wert des S-Sektors und der N-Sektor werden als eigene Merkmale analysiert.*

Beim Normalisieren ist zu beachten, dass die Verteilung der Daten erhalten bleibt. Beim „Stand sicherheitsfaktor“ gibt es z.B. das Problem, dass die Grenze zwischen stabil und instabil bei 1 liegt. Das bedeutet, dass der instabile Bereich nur von 1 bis 0 geht, während der stabile Bereich von 1 bis unendlich geht. Hier können z.B. logarithmische Funktionen zur Normalisierung benutzt werden. Ebenso gibt es die Möglich-

keit wie bei der Exposition Klassen zu bilden.

Bei Merkmalen wie „Gesteinsart“ sollten am besten Klassen gebildet werden. Im Allgemeinen ist bekannt, welche Gesteine prinzipiell rutschungsanfällig sind. Allerdings ist es schwierig, diese richtig zu gewichten und festzustellen, welches Gestein am stärksten bzw. am wenigsten rutschungsanfällig ist. Besonders in den Fällen, in denen die richtige Sortierung der Daten schwierig ist, sollten Klassen gebildet werden.

Obwohl in dieser Arbeit nicht realisiert, ist die Klassenbildung z.B. auch bei Hangneigungen zu empfehlen. Es ist bekannt, dass die meisten Rutschungen in mittleren Hangneigungen über 18° und unterhalb von 45° stattfinden. Darüber und darunter gibt es fast keine Rutschungen. Bei welchen Hangneigungen genau in dem jeweiligen Untersuchungsgebiet die meisten Rutschungen auftreten, ist allerdings stark von der lokalen Geologie abhängig. Insofern können die Klassen in diesem Fall die Flexibilität des Modells erhöhen.

Die Codierungsart der Merkmale im Rahmen dieser Arbeit und die verwendeten Normalisierungsfunktionen können aus Tabelle 3.2 entnommen werden.

Tab. 3.2: *Codierungsart der Merkmale in dieser Arbeit und die Funktionen, die zur Normalisierung der Variablen verwendet wurden.*

Merkmale	Codierung	Normalisierungsfunktion
Hangneigung	Variable (0,1)	linear
N-Exposition	Variable (0,1)	cos
S-Exposition	Variable (0,1)	cos
absolute Höhe	Variable (0,1)	linear
Bäche	binär	-
Abstand zu Bächen	Variable (0,1)	linear
Fließrichtung	Variable (Klassen)	linear
Vegetation (Wald)	binär	-
Standisicherheitsfaktor	Variable (-1,1)	log
Gesteinsart	5 Klassen	-
Abstand zu Festgestein	Variable (0,1)	linear
absolute Höhenänderung	Variable (0,1)	linear
Größe des Einzugsgebietes	Variable (0,1)	linear
Hanglänge	Variable (0,1)	linear
Hangform	1 bzw. 2 Klassen	-
Änderung der Hangneigung	Variable (0,1)	linear

Um die Leistungsfähigkeit und Generalisierungsfähigkeit schon bei der Netzentwicklung überprüfen bzw. abschätzen zu können, werden die codierten Daten mit einem Zufallsgenerator in etwa gleich große Trainings- und Testmusterungen geteilt. Je nach Auflösung enthält eine Trainingsmenge zwischen 1500 und mehr als 10000 Muster.

Die codierten Merkmale werden über eine ASCII-Schnittstelle in Tabellenform aus dem GIS exportiert. Da der hier verwendete Neuronale Netz-Simulator die Daten im Format des Stuttgarter Neuronale Netz-Simulators (SNNS) einliest, sind die ASCII-Dateien mit einem Perl-Script umgewandelt worden (Abb. 3-9).

Es ist wichtig, immer wieder darauf hinzuweisen, dass die Codierung und Merkmalselektion ein ganz entscheidender Teil des Modells sind. Fehler die hier gemacht werden, können durch keine noch so gute Netzoptimierung eliminiert werden.

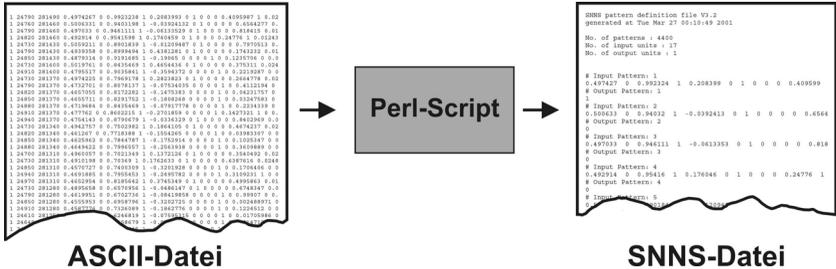


Abb. 3-9: Die tabellarischen, im ASCII-Format gespeicherten Musterdaten werden mit einem Perl-Script neu sortiert und in das SNNS-Format (ZELL, 1997) umgewandelt.

3.3 Analyse

Wie in Kapitel 2.1 dargestellt, können die Neuronale Netze lernen Muster zu erkennen. Dazu werden sie mit den im Preprocessing erzeugten Mustermengen trainiert. Damit die Netze aber später auch unbekannte Muster gut erkennen können, müssen diese optimiert und richtig eingestellt werden. Insofern findet auch während und durch die Datenanalyse eine Weiterentwicklung des Gesamtmodells statt.

3.3.1 Simulation Neuronaler Netze

Künstliche Neuronale Netze können als Software oder Hardware realisiert werden. Wie aus Abbildung 2-1 ersichtlich, besteht ein Neuronales Netz prinzipiell aus den Neuronen und den gewichteten Verbindungen (Gewichte). Um das Neuronale Netz nutzen zu können, muss die Netzwerkarchitektur mit den Gewichten entweder physisch als Hardware nachgebaut oder mit einer Software simuliert werden. In dieser Arbeit ist die Software NTtrain verwendet worden, welche am Institut für Logik, Komplexität und Deduktionssysteme an der Universität Karlsruhe (TH) entwickelt wurde.

NTtrain ist eine Kernel-Software, die über Skripte gesteuert wird. So werden die Netzarchitektur und die Aktivierungsfunktionen für die einzelnen Neuronen in einer Datei festgelegt und der Lernvorgang über ein Trainingskript gesteuert. Im Trainingskript werden der Lernalgorithmus, die Lernparameter, die Anzahl der Trainingsepochen und die Gewichtsupdates festgelegt. Neben den anderen Lernalgorithmen ist auch der hier verwendete Rprop-Algorithmus (s. Kap. 2.1.2.2) implementiert.

Es kann aber auch jede andere geeignete Simulationssoftware benutzt werden. Im Neuronale Netz-Simulator der Universität Stuttgart (SNNS) ist z.B. neben zahlreichen anderen Algorithmen auch der Rprop-Algorithmus implementiert (s.a. ZELL, 1997).

3.3.2 Entwicklung und Training der Neuronalen Netze

Zunächst muss die Architektur des Neuronalen Netzes, also die Anzahl und die Anordnung der Neuronen festgelegt werden. Die Zahl der Neuronen in der Eingabeschicht wird durch die Anzahl der Merkmale bzw.

der Dimensionalität des Eingabevektors vorgegeben. Die Größe des Ausgabevektors, also die Zahl der Ausgabeneuronen hängt davon ab, in wie viele Klassen die Daten getrennt werden sollen. Es gibt jedoch keine festen Regeln oder Strategien, um die optimale Zahl von Hiddenneuronen und Hiddenschichten festzulegen. Prinzipiell werden mit zunehmender Nichtlinearität des zu untersuchenden Problems auch mehr Hiddenneuronen und –Schichten gebraucht. Allerdings sind mehr als eine Hiddenschicht nur bei stark nichtlinearen Fragestellungen notwendig. Da der Grad der Nichtlinearität meist nicht bekannt ist, muss die optimale Anzahl an Hiddenneuronen durch iterative Anpassung gesucht werden (s.a. Kap. 2.1.3.1).

Im Kapitel 2.1.3 (Generalisierungsfähigkeit Neuronaler Netze) wird der enge Zusammenhang zwischen der Anzahl der Gewichte bzw. Neuronen und der Komplexität des Neuronalen Netz-Modells erläutert. Um gute Generalisierungsleistungen zu erhalten ist es außerordentlich wichtig, eine optimale Architektur zu finden. In dieser Arbeit wurden immer mehrere Modelle parallel entwickelt, bei denen die Zahl der Hiddenneuronen unterschiedlich war. Dies hat den Vorteil, dass schon während der Modellentwicklung ein Eindruck von der Komplexität bzw. Nichtlinearität der Fragestellung entsteht. Hier hat es sich als gute Technik erwiesen, ein lineares Netz (Netz ohne Hiddenschicht) und mehrere Netze mit einer ansteigenden Anzahl an Hiddenneuronen zu testen. Bei den ersten Tests hat sich gezeigt, dass Netze, die mehr Hiddenneuronen als die Eingabeschicht oder mehr als eine Hiddenschicht hatten, sehr stark zu Overfitting neigen. Deshalb sind diese Modelle nicht weiter untersucht worden (s. Kap. 4.1.1). Das muss aber nicht generell für Modelle zur Rutschungserkennung gelten. Wenn andere Rutschungssysteme als in den Untersuchungsgebieten analysiert werden, könnten durchaus mehr oder auch weniger Hiddenneuronen optimal sein. In KOBAYASHI (1998) wird z.B. ein Netz verwendet, dass dreimal so viele Hiddeneuronen wie Eingabeneuronen verwendet.

Da sehr komplexe Netze eine schlechte Leistung zeigten (s.o.), sind in dieser Arbeit neben dem linearen Netz nur Netze getestet worden, bei denen das Verhältnis von Eingabeneuronen zu Hiddenneuronen 3:1 bzw. 3:2 war. Der Vergleich der Ergebnisse des linearen Netzes mit denen der Netze mit Hiddenneuronen vermitteln dabei einen guten Eindruck von der Nichtlinearität des Modells.

Neben der Architektur müssen die Startgewichte, Initialisierungsschritte, Trainingsepochen und die Lernparameter für das Training der Netze eingestellt werden. Bei der Einstellung der Startgewichte ist es sinnvoll, eher niedrige Gewichte zu wählen. Hohe Gewichte können die Lernzeit stark erhöhen, da sehr viele Initialisierungsschritte benötigt werden, um die Gewichte von unwichtigen Neuronen zu reduzieren. Die Optimierung der Initialisierungsschritte bzw. Trainingsepochen muss iterativ geschehen. Dazu wird die Entwicklung des Trainings- bzw. Testfehlers betrachtet (s. a. Abb. 2-5). Wenn die Netze z.B. sehr schnell lernen, kann die Anzahl der Initialisierungsschritte reduziert werden. Der Vergleich der Fehlerentwicklung aus mehreren Epochen oder die Entwicklung des Gesamtfehlers zeigen, wie viele Epochen benötigt werden, um das Netz gut zu trainieren. Für die Einstellung der Lernparameter beim Rprop-Algorithmus gibt es ebenfalls keine festen Regeln. Generell sollte die initiale Schrittweite am Anfang nicht zu hoch gewählt werden. Die optimale Einstellung der maximalen Schrittweite und des Weight-Decay muss systematisch gesucht werden. Auch hier gilt, dass es meist besser ist, mit niedrigen Werten zu beginnen und durch iterative Anpassung eine optimale Einstellung zu suchen.

Bei der Netzentwicklung hat es sich als sinnvoll erwiesen, schrittweise bei der Optimierung der Netze vorzugehen, um ein Gefühl für die Parameter und die optimale Komplexität des Netzes zu entwickeln. Zuerst wurde eine gute Netzarchitektur gesucht, die auch dem Anspruch der strukturellen Stabilität genügt. Danach wurde versucht, durch Veränderung der Initialisierungsschritte und Lernparameter eine weitere Verbesserung zu erzielen. Die Zahl der Initialisierungsschritte bzw. Epochen und der Weight-Decay Term können dabei zur Regularisierung (s. Kap. 2.1.3.2) verwendet werden. Wie in der Generalisierung beschrieben, geht es bei diesen Maßnahmen immer darum, die Komplexität des Modells zu optimieren bzw. zu kontrollieren. Insofern kann keine der Veränderungen nur für sich alleine betrachtet werden. Wenn z.B. durch die Regularisierung keine Verbesserungen mehr erzielt werden können, muss überprüft werden, ob nicht die Architektur oder der Eingabevektor verändert werden muss, damit über strukturelle Veränderungen die Leistungsfähigkeit des Netzes verbessert werden kann.

Um schon während des Trainings einen Eindruck von der Generalisierungsfähigkeit des Neuronalen Netzes zu erhalten, wird die Leistungsfähigkeit des Netzes mit einem Testdatensatz überprüft. Der

Vergleich der Fehlerentwicklung auf der Trainings- und der Testmenge liefert einen Aufschluss darüber, ob das Modell zu Overfitting neigt (s.a. Kap. 2.1.3). Wichtig ist, dass die Trainings- und die Testmenge während des Trainings nicht vermischt werden, da sonst eine unabhängige Überprüfung der Leistungsfähigkeit des Neuronalen Netzes unmöglich ist. Deshalb ist es empfehlenswert, während der Netzentwicklung eine Validierungsmenge (s. Kreuzvalidierung in Kap. 2.1.3.2) zu verwenden. Diese wird während des Trainings und der Entwicklung des Netzes als Testmenge genutzt. Erst das fertige Modell wird an der eigentlichen Testmenge getestet. Hier wurde auf die Verwendung eines Validierungsdatensatzes verzichtet. Die gesamte Modellentwicklung und das Training der Netze wurde am Gebiet Stambach durchgeführt. Anschließend wurden die fertig entwickelten und trainierten Neuronalen Netze am Zlambachgebiet getestet. Das hatte den Vorteil, dass einerseits auch für komplexe Modelle immer genügend Trainings- und Testmuster zur Verfügung standen. Andererseits konnte so untersucht werden, wie sich die Modelle in ähnlichen aber nicht identischen Situationen verhalten.

Falls durch Einstellung der Lernparameter und Veränderung der Hiddenneuronen keine weiteren Verbesserungen zu erzielen sind, sollten auch die Codierung und die Merkmale selbst überprüft werden. Wie in Kapitel 3.2.4 erwähnt, wurden während der Modellentwicklung die Merkmale und z.T. auch die Codierung verändert, was zu erheblichen Verbesserungen des Modells führte.

3.3.3 Neuronale Netz-Modelle

Ziel dieser Arbeit ist, ein Modell zu entwickeln, das mit Neuronalen Netzen Rutschungen bzw. Rutschungsgebiete erkennen kann. Im Laufe der Modellentwicklung sind dazu verschiedene Konzepte entwickelt und untersucht worden.

Zunächst wurde ein Modell entwickelt, das die Untersuchungsgebiete in rutschungsgefährdete und -ungefährdete Bereiche trennen kann. Diese *Netze zur Rutschungserkennung* benutzen die oben beschriebenen (Tab. 3.1) Merkmale als Eingabe. Um den Einfluss von Vorwissen bzw. Expertenwissen zu untersuchen, wurden zusätzlich Netze mit dem Standsicherheitsfaktor als weiteres Merkmal getestet.

3.3 Analyse

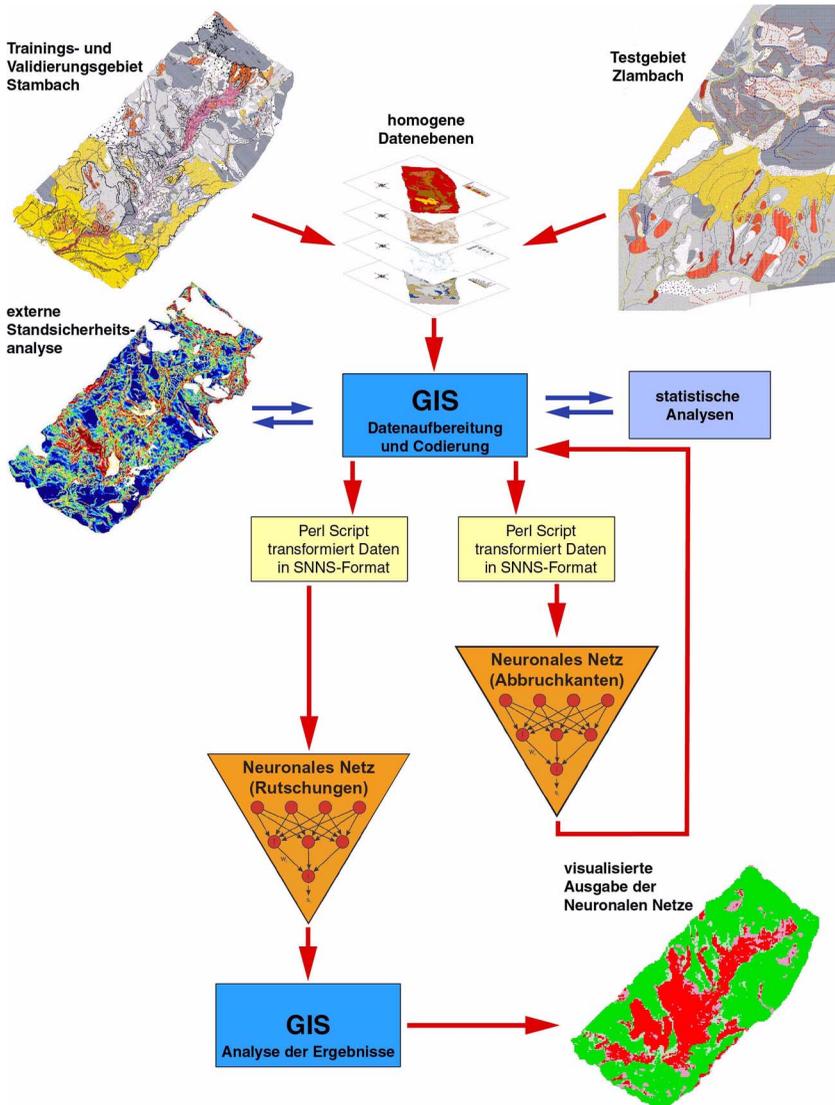


Abb. 3-10: Schematische Darstellung der Arbeitsschritte bei in „Reihe geschalteten Neuronalen Netzen“.

Im Zuge der Modellentwicklung ist die Idee entstanden, spezielle Neuronale Netze für einzelne Merkmale von Massenbewegungen zu entwickeln. Diese könnten dann als zusätzliche Eingabe für das Netz zur Rutschungserkennung benutzt werden. Das Verfahren beruht darauf, dass mit Hilfe der spezialisierten Neuronalen Netze bisher verborgene Merkmale von Rutschungen aus dem DGM ermittelt werden können. Das Merkmal "Abrisskante" ist hierfür ein gutes Beispiel. Es wird die Tatsache genutzt, dass Abrisskanten ein Element von Rutschungen sind, nämlich deren Ausgangspunkt. Mit abnehmendem Abstand zur Abrisskante erhöht sich also die Wahrscheinlichkeit, dass es sich bei der zu klassifizierenden Zelle um eine Rutschung handelt. Somit ist neben der Information, dass eine Zelle eine Abrisskante enthält auch der Abstand einer Zelle zur nächsten Abrisskante interessant. Um den Abstand einer Zelle zu der vom Neuronalen Netz erkannten Abrisskante zu ermitteln, sind allerdings Nachbarschafts- und Distanzanalysen notwendig. Deshalb muss das Ergebnis des *Netzes zur Abrisskantenerkennung* erst wieder in das GIS zurückgeladen werden, um dort analysiert und neu codiert zu werden. So ist das Modell der in *Reihe geschalteten Netze* entstanden, das eigentlich dem Prinzip der parallelen Informationsverarbeitung bei Neuronalen Netzen entgegenläuft.

Um eine weitere Verbesserung der Generalisierungsfähigkeit des Netzes zur Rutschungserkennung zu erzielen, ist der Ansatz des *Multitask Learning* (MTL) untersucht worden. Dabei wird berücksichtigt, dass die Erfahrungen aus ähnlich gelagerten Problemen oft wertvolle Informationen für die Lösung einer konkreten Aufgabenstellung enthalten. Der von CARUANA (1993, 1994) erstmals vorgestellte MTL-Ansatz bietet die Möglichkeit, zusätzliches Wissen in Neuronale Netze zu integrieren. Beim MTL-Ansatz wird ein gemeinsames Lösungsmodell bzw. ein Neuronales Netz anhand von Lernbeispielen für mehrere Aufgaben entwickelt. Da die verschiedenen Aufgaben ähnlich sind und sich bedingen sollen, haben sie einen positiven Einfluss auf die Lösung. Es geht aber immer nur darum, die Hauptaufgabe zu verbessern und nicht die Nebenaufgaben.

Das wird realisiert, indem dem neuronalen Modell für jede Aufgabe ein zusätzliches Neuron in der Ausgabeschicht hinzugefügt wird. Das Neuronale Netz wird dann mit einem entsprechenden Datensatz trainiert, der die erweiterte Ausgabe berücksichtigt (Abb. 3-11).

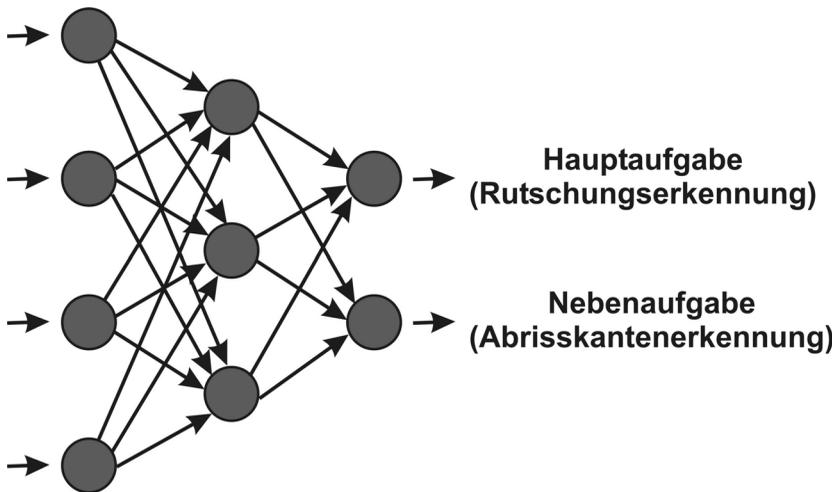


Abb. 3-11: MTL-Netz, in dem mehrere Aufgaben zusammengeführt und gleichzeitig analysiert werden. Neben der Hauptaufgabe Rutschungserkennung werden auch Informationen von der Nebenaufgabe Abrisskantenerkennung bei der Optimierung der Gewichte berücksichtigt.

Aus Abbildung 3-11 ist ersichtlich, warum der MTL-Ansatz bei Neuronalen Netzen sinnvoll ist. Während des Trainings wird der Gewichtsvektor so verändert, dass er für mehrere Lernaufgaben optimal eingestellt ist. So können in den Hiddenneuronen Merkmale gebildet werden, die für alle Aufgaben nützlich sind, also „allgemeiner“ Natur sind. Das entspricht dem eigentlichen Ziel des Trainings von Neuronalen Netzen, bei dem die verdeckten, grundlegenden Gesetzmäßigkeiten, die in einem Datensatz stecken, gesucht werden (s. Kap. 2.1).

Das Neuronale Netz „spezialisiert“ sich somit nicht so sehr auf die primäre Aufgabe. Damit reduziert sich auch die Gefahr, dass das Netz z.B. das „Rauschen“ oder sehr spezielle Eigenschaften eines Gebietes mitmodelliert und es zu Overfitting kommt.

In diesem Modell ist neben der Rutschungserkennung als zusätzliche Aufgabe die Erkennung von Abrisskanten gewählt worden. Das ist möglich, da Abrisskanten ein Teil von Rutschungen sind. Somit müssen zumindest teilweise dieselben Merkmale wie bei der Rutschungserkennung relevant sein.

3.4 Postprocessing

Im Postprocessing werden die Analyseergebnisse der Neuronalen Netze in das GIS zurückgeladen und dem DGM zur Verfügung gestellt. So können die Ergebnisse einerseits visualisiert und andererseits weiter verarbeitet oder analysiert werden.

Die Analyseergebnisse der Neuronalen Netze werden von NTtrain tabellarisch als ASCII-Datei mit Musternummer und Trefferquote gespeichert. Über die Musternummer können die Ergebnisse wieder den Untersuchungseinheiten zugeordnet und referenziert werden. So können die Ergebnisse in Rasterform im GIS als eigene Datenebene gespeichert und weiterverarbeitet werden. Die Visualisierung der Ergebnisse als Karte kann entweder in Arc/Info oder mit dem Desktop-GIS ArcView (s. Abb. 3-12) von ESRI realisiert werden.

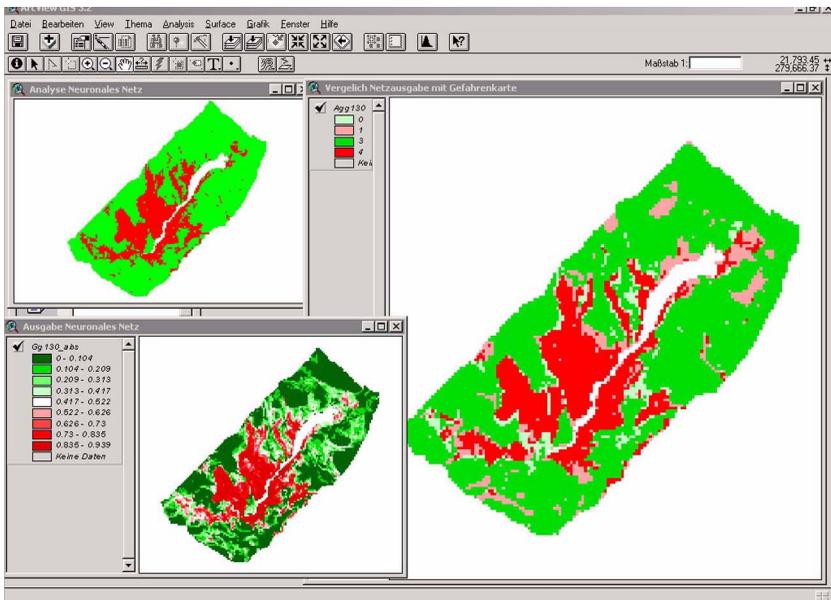


Abb. 3-12: Visualisierungsmöglichkeiten der Analyseergebnisse mit dem Desktop-GIS ArcView von ESRI.

3.4 Postprocessing

Um das Ergebnis besser analysieren zu können, wird die Gefahrenkarte durch Abfragen mit den Ergebnissen der Neuronalen Netze überlagert. So kann erkannt werden, welche Bereiche das Netz richtig erkannt hat und welche nicht. Es kann auch dargestellt werden, ob die falsch klassifizierte Zelle in der Gefahrenkarte zu einer Rutschung oder zu einem stabilen Bereich gehört.

Um die Ergebnisse homogener zu machen und zu optimieren, können Nachbarschaftsanalysen durchgeführt werden. Bei hohen Auflösungen ist es z.B. unwahrscheinlich, dass mitten in einer Rutschung eine einzelne stabile Zelle auftritt. Erst wenn mehrere Zellen stabil sind, handelt es sich um einen stabilen Bereich bzw. Grat, der von Rutschungen umflossen wird. Auch nachweislich falsche Analyseergebnisse können so korrigiert werden.

Da hier nur Massenbewegungen im Lockergestein erkannt werden sollen, können Rutschungen im Festgestein ignoriert werden. Solche Fehler können durch einfache Überprüfungen eliminiert werden.

Falls im Preprocessing bereits Aufgaben untersucht und aus der Analyse herausgenommen wurden, können diese im Postprocessing wieder hinzugefügt werden. So könnten z.B. die Festgesteinsbereiche aus der Analyse herausgenommen werden. Das würde das Neuronale Netz entlasten, da es sich besser auf seine eigentliche Aufgabe einstellen kann. Diese Bereiche können dann im Postprocessing wieder der Ergebnisebene hinzugefügt werden.

4 ERGEBNISSE

Im Folgenden werden die Ergebnisse und Fähigkeiten der trainierten Neuronalen Netze dargestellt. Dabei wird getrennt auf die drei entwickelten und getesteten neuronalen Modelle eingegangen:

- einfaches Neuronales Netz zur Rutschungserkennung
- in Reihe geschaltete Neuronale Netze zur Rutschungserkennung
- MTL-Ansatz zur Rutschungserkennung

Die Ergebnisse werden anhand der Klassifikationsleistung gegenüber den zuvor erstellten Gefahrenkarten für die Untersuchungsgebiete (s. Abb. 4-1) überprüft und analysiert.

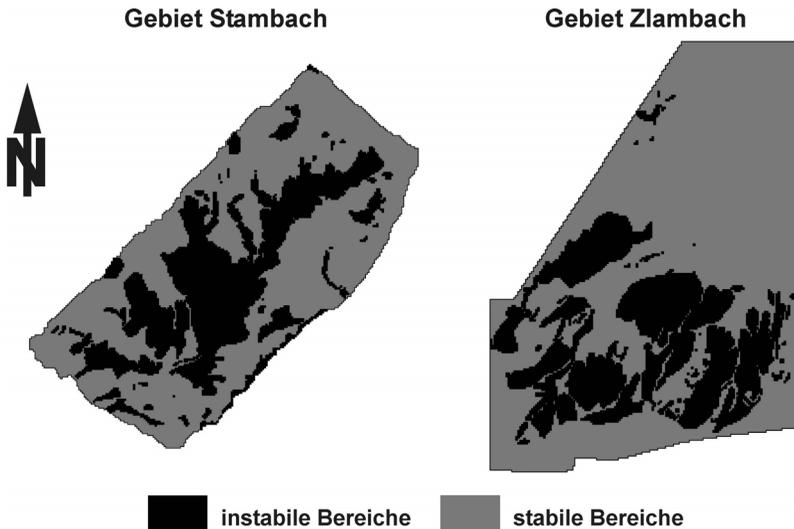


Abb. 4-1: Lage der instabilen Hangbereiche (Rutschungsbereiche aus der geotechnischen Kartierung) in den Untersuchungsgebieten (unskalierte Darstellung).

4.1 Ergebnisse der Netze zur Rutschungserkennung

An den "einfachen" Netzen zur Rutschungserkennung wurde im Wesentlichen die Modell- und Merkmalsentwicklung vorgenommen und

4.1 Ergebnisse der Netze zur Rutschungserkennung

vorangetrieben. Aus diesem Grund liegen nur für diese Netze Ergebnisse über alle Entwicklungsstufen bis zum endgültigen Modell vor. Die später vorgestellten Modelle sind entstanden, um Schwierigkeiten, die bei der Entwicklung des ersten Modells auftraten, zu reduzieren oder um neue Ideen zu integrieren. Insofern sind diese Weiterentwicklungen oder Abwandlungen des ersten Modells erst in der 3. oder 4. Entwicklungsstufe entstanden.

4.1.1 Einfluss der Merkmale und der Netzwerkarchitektur auf die Klassifikationsleistung

Um die Komplexität des neuronalen Modells zu kontrollieren, und eine gute Netzwerkarchitektur zu finden, sind über die ganze Entwicklung hinweg Netze mit einer unterschiedlichen Anzahl an Hiddenneuronen getestet worden. Dabei hat sich schon zu einem frühen Zeitpunkt gezeigt, dass bei Netzen mit mehr als einer Hiddenschicht bzw. mit mehr Hidden- als Eingabeneuronen keine befriedigende Verbesserung der Klassifikationsleistung erzielt wird.

Tab. 4.1: Veränderung der Klassifikationsleistung bei Netzen der 3. Entwicklungsstufe durch Veränderung der Netzarchitektur (bei gleichen Lernparametern im Stambachgebiet).

Architektur	Erkennungsrate Training in %	Erkennungsrate Test in %
20-1	76,8	75,8
20-6-1	81,8	79,0
20-15-1	83,5	78,1
20-30-1	83,6	76,3
20-15-15-1	82,5	74,1

Wie das Beispiel aus Tabelle 4.1 zeigt, nimmt die Klassifikationsleistung bereits bei mehr als 15 Hiddenneuronen deutlich ab. Aus dem Vergleich der Erkennungsrate im Training und im Test wird ersichtlich, dass eine Verbesserung im Training zu keiner weiteren Verbesserung im Test führt. Die hohe Parametrisierung dieser Modelle führt also zu einem Overfitting-Effekt. Aus diesem Grund sind keine Netze mit Archi-

turen weiter untersucht worden, bei denen die Anzahl der Hiddenneuronen die der Eingabeneuronen übersteigt.

Um dennoch einen Eindruck von der nötigen Komplexität des neuronalen Modells zu erhalten, sind neben dem linearen Vergleichsmodell weiterhin Netze mit 2/3 und 1/3 weniger Hidden- als Eingabeneuronen getestet worden (s. Tab. 4.2) Das ermöglicht in der Auswertung, neben der Einschätzung der Komplexität, auch eine Einschätzung der Nichtlinearität des untersuchten Problems.

Tab. 4.2: Veränderung Erkennungsrate im Trainingsgebiet Stambach (ohne Schutzströme) in Abhängigkeit von Merkmalen (s. Tab. 3.1) bzw. Netzwerkarchitektur. Die Zahl in Klammern gibt das ungefähre Verhältnis von Eingabeneuronen zu Hiddenneuronen an (Untersuchungsraster 30 m).

Netz	Merkmale in Entwicklungsstufe	evo1 13	evo2 14	evo3/1 20	evo3/2 21	evo4 17
Linear (0)	Architektur	13-1	14-1	20-1	21-1	17-1
	Erkennungsrate [%]	77,4 %	77,3 %	75,8 %	80,7 %	81,3 %
Ann2 (3:1)	Architektur	13-4-1	14-5-1	20-6-1	21-6-1	17-5-1
	Erkennungsrate [%]	74,8 %	77,7 %	79 %	83,1 %	83,9 %
Ann3 (3:2)	Architektur	13-8-1	14-9-1	20-15-1	21-15-1	17-11-1
	Erkennungsrate [%]	73,5 %	79,4 %	79,6 %	82,3 %	83,7 %

Außer einer geeigneten Netzarchitektur spielen auch die Größe und die Zusammensetzung des Eingabevektors eine wichtige Rolle. Dieser wurde über 4 Entwicklungsstufen (evo1 bis evo4) hinweg optimiert (s. a. Kap. 3.2.4). Aus Tabelle 4.2 ist ersichtlich, dass durch eine Anpassung der Eingabemerkmale eine z.T. erhebliche Verbesserung der Klassifikationsleistung erzielt werden konnte. Die einzelnen Merkmale und deren Veränderung sind in Tabelle 3.1 dargestellt. Interessant ist, dass in den ersten 3 Entwicklungsstufen (evo1 bis 3 in Tab. 4.2) allein

4.1 Ergebnisse der Netze zur Rutschungserkennung

durch eine bessere Codierung und neue Merkmale eine deutliche Verbesserung der Erkennungsrate erzielt werden konnte.

Besonders interessant ist der Sprung innerhalb der 3. Entwicklungsstufe um bis zu 4 % von evo3/1 zu evo3/2. Hier ist nur die absolute Höhe der untersuchten Zelle als zusätzliches Merkmal eingefügt worden. Das ist insofern bemerkenswert, als dieses Merkmal in der 2. Entwicklungsstufe gelöscht wurde, da es nicht relevant erschien. In der dritten Stufe ist es dann als inverse Höhe wieder eingefügt worden. Das bedeutet, dass die Höhe so codiert ist, dass die tiefsten Zellen den Wert 1 erhalten und die höchsten den Wert 0. Ein ähnlicher Effekt ist beim Schritt von der 1. zur 2. Entwicklungsstufe zu beobachten. Hier ist die Codierung für die Exposition (zuvor Kreisfunktion) verändert (s.a. Kap. 3.2.5) und das neue Merkmal „Abstand zu Festgestein“ eingeführt worden.

Tab. 4.3: Vergleich der Erkennungsrate von Netzen, die im Trainingsgebiet Stambach (ohne Schuttströme) trainiert wurden.

Architektur	21-1	21-6-1	21-15-1
Stambach	80,7 %	83,1 %	82,4 %
Zlambach	74,2 %	73,3 %	66,1 %

Auffällig ist, dass ab der Entwicklungsstufe evo3/2 mehr Hiddenneuronen nicht wie in den vorhergehenden Stufen zu einer Verbesserung der Klassifikationsleistung führen. Eine Erklärung hierfür ist, dass ein geeigneter, leicht abbildbarer Eingabevektor gefunden wurde. Zuvor waren viele Hiddenneuronen notwendig, um aus den Eingabemerkmalen neue sinnvolle "Hiddenmerkmale" zu bilden. Nur so konnte das Netz die Klassifikationsaufgabe optimal lösen. Bei dem neuen Eingabevektor reichen auch weniger Hiddenneuronen, um diesen sinnvoll abzubilden. Eine höhere Anzahl an Hiddenneuronen führt hier bereits zum Overfitting-Effekt.

In der 4. Entwicklungsstufe wird versucht, mit einem kleineren, aber optimierten Eingabevektor die Klassifikationsleistung nochmals zu verbessern. Das erscheint möglich, da in der 3. Stufe bereits die weniger komplexen neuronalen Modelle besser abschneiden. Somit lag die Ver-

mutung nahe, dass nicht alle Eingabemerkmale relevant sind. Diese Vermutung wurde durch erste Untersuchungen am Testgebiet Zlambach gestützt, da dort die linearen Neuronalen Netze die beste Klassifikationsleistung zeigten (s. Tab. 4.3). Das deutet oft auf eine zu hohe Parametrisierung des Modells hin. Aus diesem Grund sind die Trainingsdatensätze mit Korrelationsanalysen untersucht worden, um Merkmale auszusortieren, die zur Ausgabe (Rutschung nein/ja) wenig korreliert oder wenig sinnvoll sind. Auch eng zueinander korrelierte Merkmale sind nochmals ausgesondert worden.

Aus Tabelle 4.4 ist ersichtlich, dass z.B. die Hangneigung und die absolute Höhenänderung eng korreliert sind. Da auch die Änderung der Hangneigung mit über 0,8 zu diesen Merkmalen korreliert ist, sind die Hangneigung und die absolute Höhenänderung aussortiert worden. Dies ist möglich, da beide mit den Rutschungen fast nicht korreliert sind. Die Fließrichtung wurde aussortiert, weil diese mit der Ausgabe wenig korreliert ist und durch die Exposition zumindest teilweise repräsentiert wird. Als viertes Merkmal wurde die konvexe Hangform als Merkmal eliminiert, da diese einfach invers mit der konkaven Hangform korreliert ist.

Tab. 4.4: Kreuzkorrelation von besonders hoch korrelierten Merkmalen.

	Hangneigung	absolute Höhenänderung	Fließrichtung	Rutschung
Hangneigung	1	0,983	-0,084	0,096
absolute Höhenänderung	0,983	1	-0,088	0,071
Fließrichtung	-0,084	-0,088	1	0,089
Rutschung	0,096	0,071	0,089	1

Durch die Reduktion der Eingabemerkmale konnte einerseits die Klassifikationsleistung verbessert und andererseits der Rechenaufwand reduziert werden.

Die Ergebnisse belegen, dass die Merkmalsselektion bzw. die richtige Codierung des Eingabevektors einen wesentlichen Einfluss auf die Sta-

4.1 Ergebnisse der Netze zur Rutschungserkennung

bilität und Leistungsfähigkeit der Neuronalen Netze haben. In dem in Tabelle 4.2 dargestellten Fall konnte bei identisch trainierten Netzen eine Verbesserung der Klassifikationsleistung um bis zu 10,2 % erzielt werden.

4.1.2 Einfluss der Größe der Untersuchungseinheiten (Zellen) und Anzahl der Muster auf die Klassifikationsleistung

Bei den Untersuchungen der Gebiete in unterschiedlichen Auflösungen konnten z.T. erhebliche Unterschiede in den Klassifikationsleistungen der Netze festgestellt werden (s. Tab. 4.5). Hochaufgelöste Datensätze konnten fast immer besser klassifiziert werden als niedriger aufgelöste. Besonders die Datensätze mit einer 50 m Auflösung fallen gegenüber den Datensätzen mit 30 und 20 m Auflösung ab. Das liegt aber nicht an der geringeren Anzahl an Trainingsmustern. Auch bei ähnlicher Musterzahl schneiden die höher aufgelösten Datensätze noch immer besser ab (Tab. 4.5).

Tab. 4.5: Klassifikationsleistung der besten Netze zur Rutschungserkennung (ohne Schuttströme) im Stambachgebiet bei unterschiedlichen Rasterweiten.

Rasterweite	Musterzahl	17-1	17-5-1	17-11-1
20 m	10042	81,7 %	84,2 %	84,6 %
30 m	4492	81,3 %	83,9 %	83,7 %
50 m	1872	81,3 %	83,2 %	82,8 %

Wie bereits in Kapitel 3.2.3 dargestellt, muss die Größe der Untersuchungseinheiten so gewählt werden, dass der Wert der Zelle auch den Geländebereich richtig darstellt. Da bei der Rasterung der Daten im Allgemeinen das Mittelwert- oder Majoritätsprinzip angewandt wird, kann eine niedrige Auflösung zu einer Art „Glättung“ des Geländes führen.

Interessant ist, dass die 17-11-1 Netze die Datensätze in 20 m Auflösung am besten klassifizieren können (Tab. 4.5). Sonst tritt, wie auch oben beschrieben meist der gegenteilige Effekt ein und die 17-5-1 Netze schneiden besser ab. Insofern ist nicht nur die richtige Auswahl der

Merkmale wichtig, sondern auch die richtige Auflösung. Nur bei einer optimal gewählten Auflösung werden die Merkmale auch richtig differenziert dargestellt und können gut klassifiziert werden.

Tab. 4.6: Klassifikationsleistung der besten Netze zur Rutschungserkennung (ohne Schuttströme) im Stambachgebiet mit reduzierten Trainingsdatensätzen bei unterschiedlichen Rasterweiten.

Rasterweite	Musterzahl	17-1	17-5-1	17-11-1
20 m	3996	82 %	84,9 %	85,2 %
30 m	1773	82, %	84,6 %	84,8 %
50 m	656	79,3 %	80 %	80 %

Wie bei allen datenbasierenden Verfahren kann mit Neuronalen Netzen nur dargestellt werden, was durch die Datensätze repräsentiert wird. Das bedeutet, dass eine ausreichende Anzahl an Beispielen für alle Klassen, also Rutschungen und stabile Bereiche, vorhanden sein muss. Allerdings scheint es auch einen Zusammenhang zwischen einer zu großen Anzahl an Mustern und der Klassifikationsleistung zu geben. Mit einem Zufallsgenerator wurden die Trainingsmuster um 3/5 reduziert und die Neuronalen Netze dann mit diesen reduzierten Datensätzen trainiert. Dabei hat sich gezeigt, dass bei den höheren Auflösungen die Klassifikationsleistung der so trainierten Netze nicht abnimmt, sondern sogar zunimmt (Tab. 4.6). Vermutlich tritt hier eine Art Regularisierung durch die Musteranzahl ein. Die Netze erlernen so vermutlich die grundlegenden Zusammenhänge, ohne sich auf die Details der einzelnen Rutschungen im Gebiet zu stark zu optimieren. Bei den Datensätzen in der 50 m Auflösung gelingt dies jedoch nicht mehr. Hier nimmt die Klassifikationsleistung ab, weil zu wenige und zu ähnliche Musterbeispiele vorhanden sind.

4.1.3 Untersuchung der Eignung des Standsicherheitsfaktors als zusätzliches Eingabemerkmal

Um den Einfluss des Standsicherheitsfaktors auf die Ergebnisse der Analyse zu untersuchen, sind Neuronale Netze sowohl mit (DNet), als

4.1 Ergebnisse der Netze zur Rutschungserkennung

auch ohne Standsicherheitsfaktor (NNet) als Eingabemerkmale untersucht worden (Tab. 4.7). Dabei hat sich gezeigt, dass der Einfluss des Standsicherheitsfaktors auf das Ergebnis begrenzt ist. Bei den Netzen mit 11 Hiddenneuronen schneiden die Netze, die ohne den Standsicherheitsfaktor (NNet) als Eingabemerkmale trainiert wurden, sogar besser ab.

Tab. 4.7: Vergleich der Erkennungsrate von Netzen ohne und mit Standsicherheitsfaktor als zusätzliches Merkmal im Gebiet Stambach (20 m Raster).

Architektur	17-1	17-5-1	17-11-1
mit Standsicherheitsfaktor (DNet)	81,7 %	84,2 %	84,6 %
Architektur	16-1	16-5-1	16-11-1
ohne Standsicherheitsfaktor (NNet)	82 %	84,3 %	85,3 %

Eine mögliche Erklärung dafür ist, dass diese Netze den Standsicherheitsfaktor gar nicht als zusätzliches Merkmal brauchen, da sie in den Hiddenschichten einen eigenen "Standsicherheitsfaktor" bilden.

Der Standsicherheitsfaktor wird für den ebenen Fall über das Hanggleichgewicht ermittelt (Gleichung 4.1).

$$F = \frac{\sum \text{haltende Kräfte}}{\sum \text{treibende Kräfte}} \quad (4.1)$$

Da der größere Teil der Rutschungen (Gleitungen) ebene flache Blattanbrüche sind bzw. die Rotationsrutschungen in translative Gleitungen übergehen, ist hier die Annahme eines Ebenen Bruchs als Hauptbewegungsursache zulässig. Nach CRUDEN & VARNES (1996) ist der ebene Fall auch für Gleitungen mit langer Gleitbahn als Näherung zulässig, selbst wenn die Gleitbahn gebogen ist.

Beim ebenen Fall wird der Standsicherheitsfaktor F ermittelt, indem die haltenden den treibenden Kräften gegenübergestellt werden. Im Rahmen dieser Arbeit wurde der Standsicherheitsfaktor nach der unten an-

gegebenen Gleichung (4.2) ermittelt. (s.a. GRAHAM, 1984)

$$F = \frac{c' + (\gamma - m\gamma_w) * z * \cos^2 \beta * \tan \varphi'}{\gamma * z * \sin \beta * \cos \beta} \quad (4.2)$$

c'	= effektive Kohäsion
γ	= Wichte des Bodens
m	= z_w/z
γ_w	= Wichte des Wassers
z	= Tiefe der Bewegungsfläche
z_w	= Höhe Bergwasser über z
β	= Hangneigung
φ	= effektiver Scherwinkel

Die Materialparameter sind den in Kapitel 2.3.3.1 angegebenen Arbeiten entnommen worden (s.a. Tab. 2.3). Es wurde vollständige Wassersättigung des Bodens und als Tiefe der Scherbahn 1 m angenommen. Als grobe Näherung ist dieser Wert akzeptabel, da die meisten Rutschungen in den Untersuchungsgebieten etwa in diesem Mächtigkeitbereich liegen, wie die Kartierungen zeigen.

Aus Gleichung (4.2) ist ersichtlich, dass der Wert des Standsicherheitsfaktors in den einzelnen Gesteinseinheiten nur von den konstanten Materialparametern (Scherwinkel, Kohäsion, Wichte) und der variablen Hangneigung abhängt. Daraus resultiert, dass eine Änderung der Hangneigung auch zu einer Änderung des Standsicherheitsfaktors führt. Trotz der einfachen Berechnung des Standsicherheitsfaktors spiegelt sich das auch in den Musterdatensätzen wider. So ist die Änderung der Hangneigung mit dem Faktor 0,6 zum Standsicherheitsfaktor korreliert. Da die Materialparameter gesteinspezifisch sind, lässt sich vermuten, dass das Neuronale Netz aus der Änderung der Hangneigung und der Gesteinsart eine Art Standsicherheitsfaktor bilden kann.

4.1.4 Darstellung und geologische Interpretation der Ergebnisse im Trainings- und Validierungsgebiet Stambach

Um die Ergebnisse der Neuronalen Netze auch geologisch interpretieren zu können, sind sie georeferenziert worden. So können die Ergebnisse mit den Gefahrenkarten und den geotechnischen Karten verglichen werden. Die Ergebnisse werden anhand der Resultate der be-

4.1 Ergebnisse der Netze zur Rutschungserkennung

sten Netze der 4. Entwicklungsstufe dargestellt (Tab. 4.8), die mit Datensätzen in 20 m Auflösung trainiert wurden.

Anfangs wurden die Schutt- bzw. Schlammströme im Gebiet Stambach aus den Trainingsdatensätzen herausgenommen, da die Netze nur Massenbewegungen mit gleitenden Bewegungsmechanismen erkennen sollten. Das hat den Vorteil, dass die Netze sich besser auf eine Aufgabe "konzentrieren" können und nicht zusätzlich die Fließbewegungen mitmodellieren müssen. Um diesen Vorteil abschätzen zu können, sind ab der 4. Entwicklungsstufe auch Netze mit vollständigen Datensätzen d.h. inklusive Schuttströme des Gebietes Stambach trainiert worden (s. Tab. 4.8)

Tab. 4.8: Erkennungsrate von Netzen, die das Gebiet Stambach einmal ohne und einmal mit Schuttstrom erkennen mussten. Die Ergebnisse sind für die Netze mit (DNet) und ohne Standsicherheitsfaktor (NNet) als Merkmal dargestellt.

DNet	Architektur	17-1	17-5-1	17-11-1
	ohne Schuttstrom	81,7 %	84,2 %	84,6 %
	mit Schuttstrom	81,9 %	84,2 %	84,8 %
NNet	Architektur	17-1	17-5-1	17-11-1
	ohne Schuttstrom	82 %	84,3 %	85,3 %
	mit Schuttstrom	81,7 %	84,5 %	85,5 %

Die Ergebnisse aus Tabelle 4.8 zeigen, dass die Netze unabhängig von ihrer Architektur das Stambachgebiet mit und ohne Schuttstrom praktisch gleich gut analysieren können. Vermutlich unterscheiden sich zumindest im Untersuchungsgebiet die Instabilitäten innerhalb großer Schuttströme nicht so stark von größeren Rutschungen wie ursprünglich angenommen. Innerhalb des großen Stambachschtstroms treten z.B. auch größere Abrissysteme auf, durch die der Schuttstrom gegliedert wird (Abb. 4-2). Weiterhin gehen bei den Massenbewegungen in den Untersuchungsgebieten oft gleitende in fließende Bewegungen über (s.a. Kap. 2.3.3). So ist es möglich, dass die Netze bereits an diesen Beispielen lernen, fließende Massenbewegungen zu erkennen.

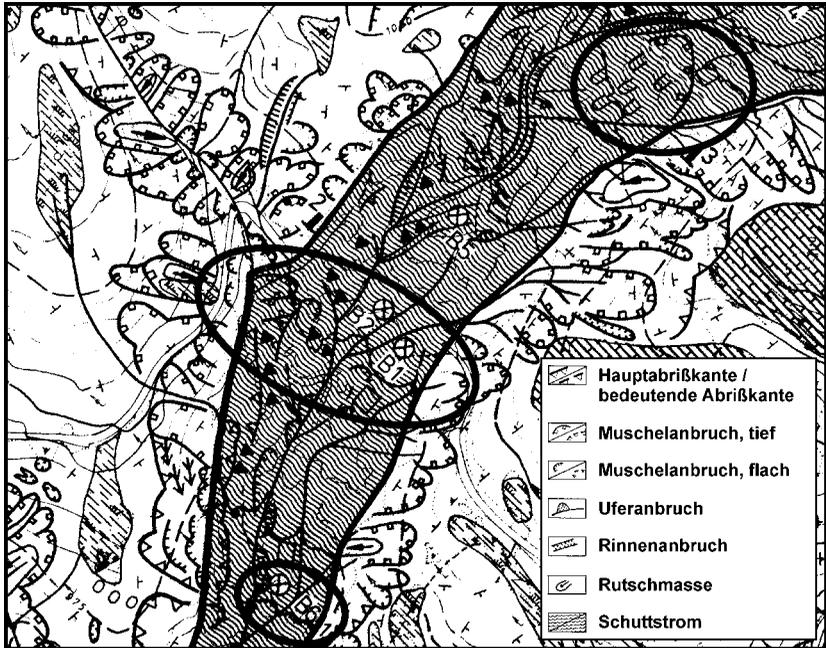


Abb. 4-2: Große Abrissssysteme innerhalb des Stambachschuttstroms.

In Abbildung 4-3 ist die Auswertung der Rutschungsanalyse durch das Neuronale Netz mit dem Standsicherheitsfaktor (DNet) für das Stambachgebiet zu sehen. Es ist zu erkennen, dass das Neuronale Netz die wesentlichen Rutschungsstrukturen bzw. Rutschungsgebiete (vgl. Abb. 2-14 und 2-15) gut erkennen kann. In den Randbereichen der großen Rutschkessel ist die richtige Klassifikation der Zellen allerdings nicht immer optimal.

Werden die Ergebnisse wie in Abb. 4-4 direkt mit der ursprünglichen geotechnischen Karte (ROHN, 1991) verglichen, sind sie insgesamt überzeugend. Die Hauptabrissskanten werden immer mit einer Unsicherheit von 1 bis 2 Zellen (20 – 40 m) nachgezeichnet. Diese Genauigkeit ist für die Raumplanung mehr als ausreichend.

Zudem ist es natürlich, dass gerade an den Übergangsbereichen Modellschwächen auftreten. Hier kommt auch im Gelände häufig die Frage auf, ob ein Bereich noch stabil oder schon instabil ist. Zudem kön-

4.1 Ergebnisse der Netze zur Rutschungserkennung

nen aufgrund der Grenzsituation auch kleinere Fehler in den Datensätzen bereits einen großen Einfluss auf das Ergebnis haben.

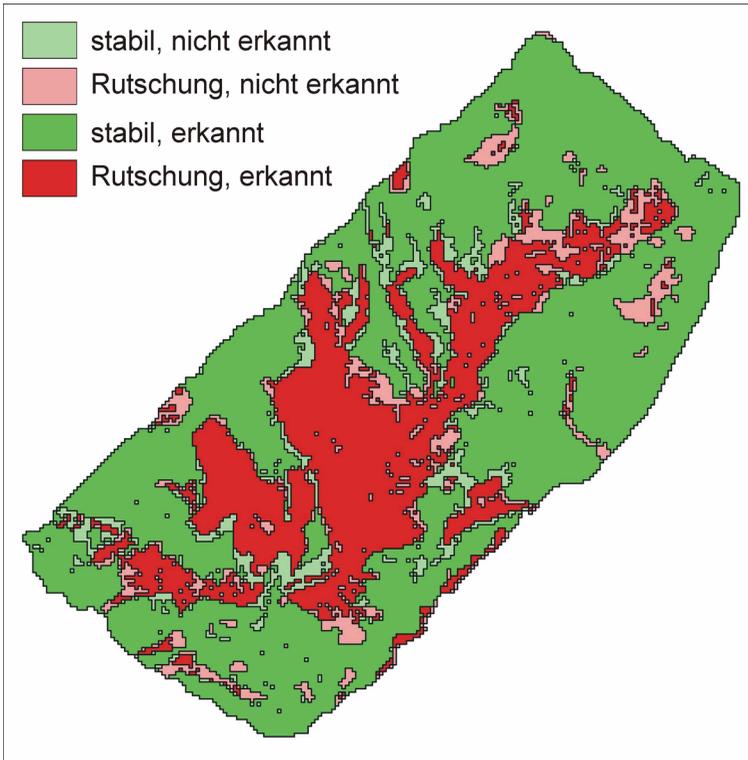


Abb. 4-3: Rutschungsanalyse für das Trainings- und Validierungsgebiet Stambach in 20 m Auflösung mit dem DNet (Netz mit Standsicherheitsfaktor).

Dass die beiden Grate im Zentrum der Abbildung 4-4 als instabil klassifiziert wurden, kann damit erklärt werden, dass sich diese mit der Verlagerung der Hauptabrisskante auch künftig verändern werden und jetzt nur eine Momentaufnahme darstellen. Wichtig ist, dass die Netze anscheinend gelernt haben, dass in den Kalkeinheiten keine Massenbewegungen der untersuchten Typen auftreten können.

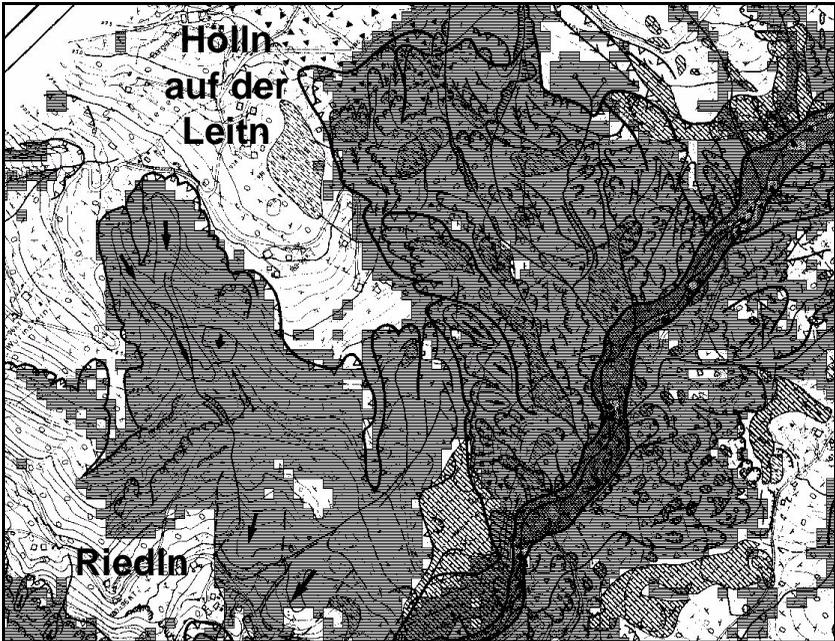


Abb. 4-4: Rutschungskessel bei Riedln bzw. Hölln auf der Leitn. Die dunkel schraffierten Bereiche sind von dem Neuronalen Netz als Rutschungsbereiche erkannt worden. (Legende geotechnische Karte siehe Abb. 4-2).

Kleinere Rutschkessel wie bei Rotmoos (s. Abb. 4-5) bzw. größere Einzelrutschungen wie die nördlich der Rossmoosalm (s. Abb. 2-11 bzw. 2-14) werden allerdings fast nicht erkannt. Hier ist es wahrscheinlich, dass diese Rutschungsmuster deutlicher von den sonst vorherrschenden Massenbewegungen in Zusammenhang mit Wildbachsystemen abweichen.

Die Rutschung nördlich der Rossmoosalm besteht z.B. aus mehreren Abrisskanten die ca. 50 bis 100m von der Zwerchwand entfernt sind. Oberhalb des Abrissbereiches sind größere Felssturzmassen abgeschlossen. Hier wäre es möglich, dass es durch undrainierte Belastung lokal zu Rutschungen kommt. Es sind auch hier ausgedehnte Kriechbewegungen zu erkennen. Da diese beiden Bewegungstypen sonst im Gebiet deutlich unterrepräsentiert sind, lässt sich vermuten,

dass das Netz diese Typen aus diesem Grund nicht ausreichend lernen konnte.

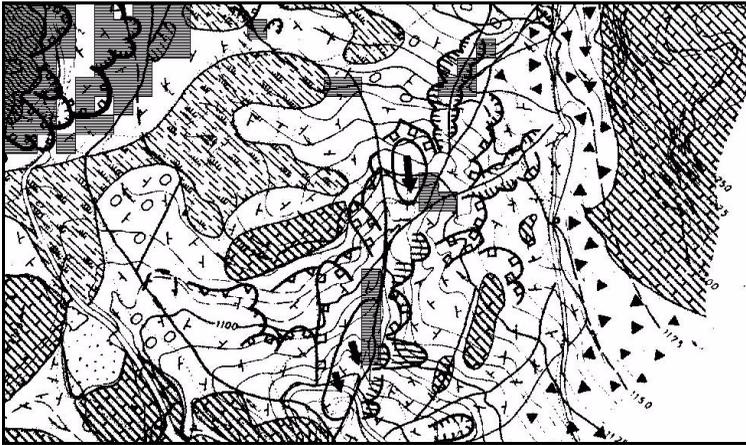


Abb. 4-5: Rutschungssystem bei Rotmoos, das praktisch nicht erkannt wurde. Nur die dunkel schraffierten Bereiche sind vom Netz als Rutschung erkannt worden. (Legende geotechnische Karte siehe Abb. 4-2).

Das Beispiel bei Rotmoos zeigt eine Schwäche des Modells. Wie in Abbildung 4-5 zu erkennen, treten hier zahlreiche Rutschungen im Quellgebiet und Zusammenfluss des Schwarzenbachs auf. Es handelt sich also um Massenbewegungen in Zusammenhang mit der Eintiefung des Baches. Da die übrigen Rutschkessel auf dieselben grundlegenden Prozesse zurückzuführen sind, weicht dieses Ergebnis deutlich von dem erwarteten ab. Eine mögliche Erklärung ist, dass dieser Rutschungskessel erst am Beginn seiner Entwicklung steht und deshalb morphologisch noch nicht so ausgeprägt ist.

Ähnliches ist auch bei den jungen, sich entwickelnden Wildbachsystemen zu beobachten. Während die ausgeprägteren und voll entwickelten Systeme gut erkannt werden, werden die jungen, sich entwickelnden Systeme nicht erkannt (s. Abb. 4-6). Das kann damit zusammenhängen, dass die "reiferen" Wildbachsysteme nördlich des Stambachs bei der Rossmoosalm (Abb. 4-6 rechts) morphologisch ausgeprägter sind. Hier haben sich schon ausgreifende Strukturen gebildet und anstelle von Uferanbrüchen treten bereits tiefergreifende Muschelabrü-

che auf. So bilden sich tiefere, breitere Täler mit ausgeprägten steileren Hangflanken. Die jungen Systeme südlich des Stambachs, z.B. am Schwarzbachloch (Abb. 4-6 links), sind noch nicht so stark eingetieft und ausgeprägt, so dass sie im DHM nicht so deutlich hervortreten. Außerdem sind die Hangflanken nicht so steil und hoch.

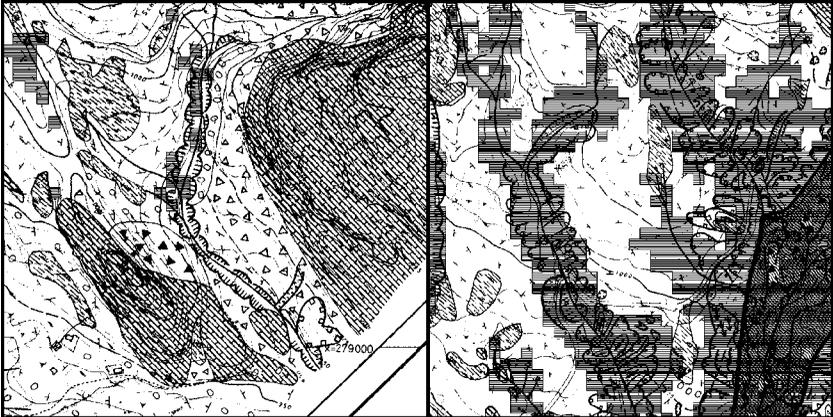


Abb. 4-6: Vergleich der Erkennung von Rutschungen in unterschiedlich "reifen" Wildbachsystemen. Links ist das sehr junge System am Schwarzenbachloch und rechts die ausgeprägten reifen Systeme südlich der Rossmoosalm zu erkennen. (schraffierte Bereiche sind als Rutschung erkannt worden).

Interessant ist, dass die Rutschungen an den direkten Einhängen des Trauntals gut erkannt werden (Abb. 4-7). Gerade hier wäre zu erwarten, dass aufgrund der abweichenden Rutschungsursachen und der geringeren Musterzahl eine schlechte Klassifikationsleistung erzielt wird.

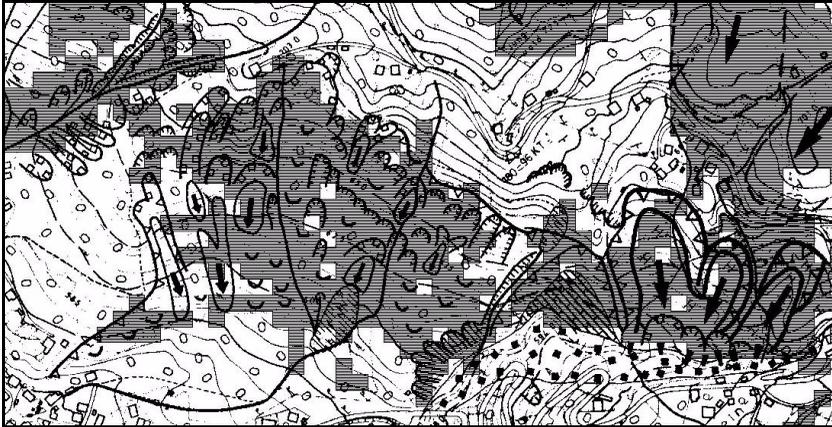


Abb. 4-7: Rutschungssysteme an den steileren direkten Einhängen des Trauntals. Die schraffierten Bereiche sind als Rutschungen erkannt worden (Legende s. Abb. 4-2).

Wie aus Abbildung 4-7 ersichtlich, werden die Rutschungsbereiche insgesamt jedoch gut erkannt. Sogar Kriechbereiche werden teilweise als instabile Bereiche erkannt. Das zeigt, dass die Netze anscheinend grundlegende Gesetzmäßigkeiten erlernt haben.

Insgesamt ist die Klassifikationsleistung dieses neuronalen Modells (DNet) im Stambachgebiet positiv zu bewerten. Bis auf die oben beschriebenen Schwächen kann das Modell die wichtigen Rutschungsstrukturen detailliert darstellen.

4.1.5 Vergleich und geologische Interpretation der Ergebnisse im Testgebiet Zlambach

Bei der Analyse der Ergebnisse der im Stambachgebiet trainierten Neuronalen Netze im Zlambachgebiet fällt schon optisch auf, dass das Ergebnis nicht mehr so homogen ist (Abb. 4-8).

Die schlechtere Klassifikationsleistung spiegelt sich auch in den Erkennungsraten wider. Zwar sind die Ergebnisse mit einer Erkennungsrate von 70-72 % aus geologischer Sicht noch akzeptabel, aber der Abfall um durchschnittlich 12 % ist doch erheblich.

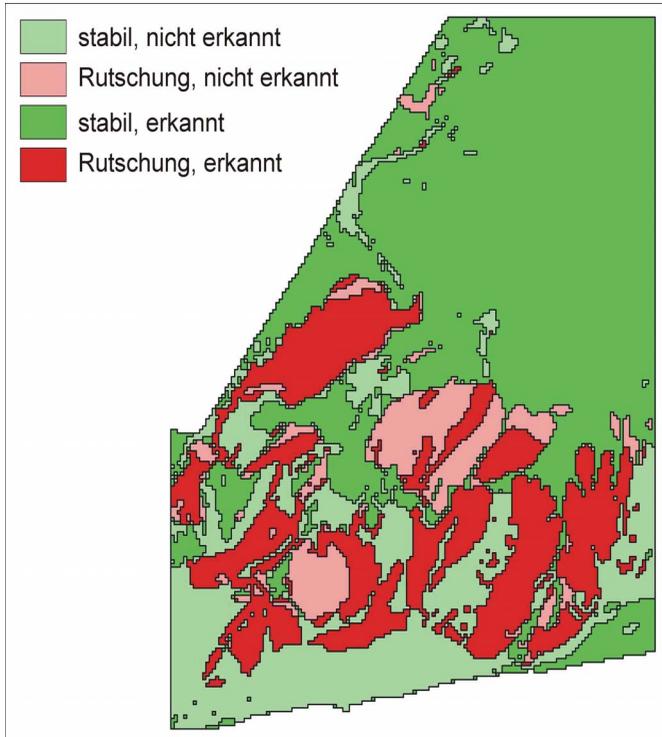


Abb. 4-8: Rutschungsanalyse für das Testgebiet Zlambach in 20 m Auflösung mit dem DNet (Netz mit Standsicherheitsfaktor).

Bei der Auswertung der Ergebnisse in Abbildung 4-8 fällt auf, dass die Netze das gesamte Einzugsgebiet des Grossen Zlambach als instabil klassifizieren. In der Gefahreneinschätzung sind diese Bereiche aber meist als stabil ausgewiesen.

4.1 Ergebnisse der Netze zur Rutschungserkennung

Tab. 4.9: Erkennungsrate von Netzen im Gebiet Zlambach, die im Stambachgebiet ohne und mit Schuttstrom trainiert wurden. Die Ergebnisse sind für die Netze mit (DNet) und ohne (NNet) Standsicherheitsfaktor als Merkmal dargestellt.

DNet	Architektur	17-1	17-5-1	17-11-1
	ohne Schuttstrom	71,7 %	72,9 %	72,6 %
	mit Schuttstrom	70,8 %	70,6 %	69,4 %
NNet	Architektur	17-1	17-5-1	17-11-1
	ohne Schuttstrom	70,5 %	72,6 %	70,6 %
	mit Schuttstrom	72,1 %	72,8 %	71,4 %

Die Abbildung 4-9 zeigt allerdings, dass die wesentlichen Rutschungsstrukturen vom Netz aus geologischer Sicht dennoch richtig erkannt werden. Die Genauigkeit ist zwar nicht mehr ganz so gut wie im Stambachgebiet, aber für die Raumplanung durchaus ausreichend. Selbst stabile Grate werden von dem Netz erkannt. Auch die Schuttströme können von den Netzen wieder erkannt werden. Allerdings werden kleinere Rutschungen am Rand der großen Rutschkessel nicht so gut erkannt wie im Stambachgebiet.

Die Netze haben also im Rahmen des Trainings im Stambachgebiet durchaus grundlegende Fähigkeiten entwickelt, die auch in ähnlichen Gebieten bei vergleichbaren Prozessen zu einem befriedigenden Ergebnis führen können.



Abb. 4-9: Rutschungskessel bei der Leislingalm. Die dunkel schraffierten Bereiche sind von dem Neuronalen Netz als Rutschungsbereiche erkannt worden. (Legende geotechnische Karte s. Abb. 4-2).

Dennoch ist das starke Abfallen der Erkennungsrate um bis zu 12 % auffällig. Zur Klärung ist die Gefahrenkarte nochmals überprüft worden. Dabei hat sich gezeigt, dass südliche Teile des Geländes nur geologisch und nicht geotechnisch aufgenommen worden sind.

Deshalb wurde eine erweiterte Gefahrenkarte unter Berücksichtigung der alten Gefahrenkarte von RESCH (1997) und der Geotechnischen Karte von RHÖNAU (2001) erstellt. Da die Ergebnisse erst sehr spät vorlagen, konnten nicht mehr alle Netze mit der erweiterten Gefahrenkarte getestet werden. Deshalb werden im Folgenden weiterhin auch die alten Ergebnisse angegeben, die als Mindestwerte angesehen werden können. Für die abgebildeten Netze wird aber auch das neue Ergebnis mit der neuen Erkennungsrate dargestellt (Abb. 4-10).

4.1 Ergebnisse der Netze zur Rutschungserkennung

Das revidierte Ergebnis in Abbildung 4-10 zeigt nun auch, dass die Netze die wesentlichen Rutschungsstrukturen richtig erkannt haben. Das gilt sowohl für die Rutschungskessel am Kleinen Zlambach als auch für die Rutschungen am Grossen Zlambach. Die Erkennungsrate erhöht sich von 70,6 % auf 82,8 %, was in etwa dem früher festgestellten Abfall der Klassifikationsleistung entspricht.

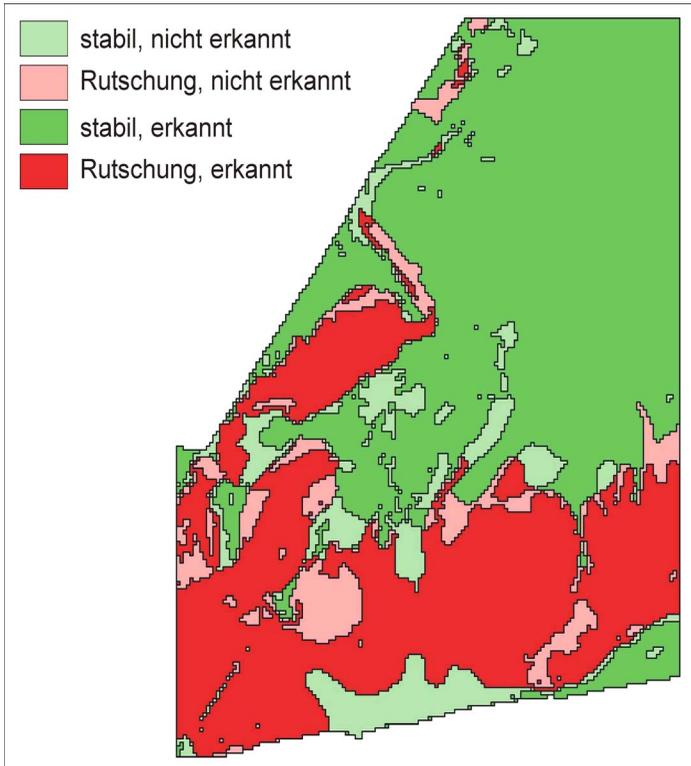


Abb. 4-10: Revidierte Rutschungsanalyse für das Testgebiet Zlambach in 20 m Auflösung auf der Grundlage der erweiterten Gefahrenkarte mit DNet (gleiches Netz wie in Abb. 4-8). Die Erkennungsrate erhöht sich von 70,6 % auf 82,8 %.

Allerdings erkennen die Netze nicht, dass in den südlich des Grossen Zlambach anstehenden Hallstätter Kalken keine Rutschungen auftreten können (vgl. Abb. 4-10). Die Netze haben im Gebiet Zlambach anscheinend generell größere Schwierigkeiten zu erkennen, dass die hier untersuchten Massenbewegungen nicht im Festgestein auftreten können.

Es ist interessant festzustellen, dass Netze mit sehr ähnlichen Klassifikationsleistungen manchmal doch für die Fragestellung sehr unterschiedliche Ergebnisse erzeugen. So erkennen die Netze ohne Stand sicherheitsfaktor als Eingabemerkmale (NNet) bei praktisch identischer Erkennungsrate die Hallstätter Kalke südlich des Stambach als stabile Bereiche. Sie erkennen dafür einige Bereiche von Hallstätter Kalken am Raschberg nicht korrekt.

Bemerkenswert ist noch, dass im Zlambachgebiet die Netze mit der 17-6-1 bzw. 16-6-1 Architektur die beste Erkennungsrate haben. Im Stambachgebiet sind jedoch die komplexeren Netze mit der 17-11-1 bzw. 16-11-1 Architektur besser (s. Tab. 4.8 und Tab 4.9). Eine Erklärung hierfür könnte sein, dass die Netze mit höherer Komplexität das kompliziertere Umfeld und die stärker differenzierten Rutschungen im Stambachgebiet besser erkennen können. In dem etwas einfacheren Gebiet Zlambach sind diese stärker optimierten Netze weniger geeignet als die einfacheren, da diese anscheinend eher grundlegende Strukturen erkennen. Bei den komplexen Netzen kommt es zum Overfitting-Effekt.

4.1.6 Nachbarschaftsanalysen zur Verbesserung der Ergebnisse

Wie in Kapitel 3.4 dargestellt, kann das Ergebnis der Analyse im Post-processing durch Nachbarschaftsanalysen und intelligente Abfragen gegebenenfalls noch optimiert werden.

Im ersten Schritt wird über eine Nachbarschaftsanalyse geklärt, ob der Wert einer Zelle stark von dem der umgebenden Zellen abweicht. Mit der MAJORITYFILTER-Funktion in Arc/Info kann abgefragt werden, ob die Mehrheit der umgebenden Zellen denselben Wert aufweisen wie die untersuchte Zelle. Falls dies der Fall ist, bleibt der Wert der Zelle unverändert. Sonst wird der Wert der Mehrheit der umgebenden Zellen angepasst. So können einzelne stabile Zellen inmitten von Rutschungen bzw. eine einzelne Rutschungszelle innerhalb eines großen stabilen Bereiches erkannt werden. Da diese einzelnen Zellen inmitten ei-

4.1 Ergebnisse der Netze zur Rutschungserkennung

nes großen Bereiches unwahrscheinlich sind, werden diese entsprechend ihrer Umgebung angepasst.

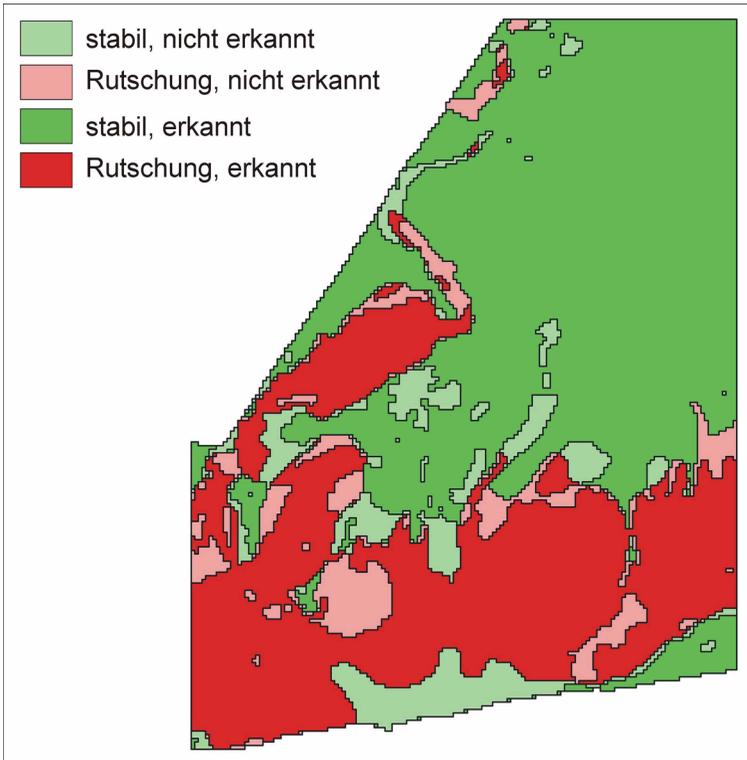


Abb. 4-11: Ergebnis der mit Nachbarschaftsanalysen optimierten Rutschungsanalyse des DNet aus Abbildung 4-10. Die Erkennungsrate erhöht sich durch die Optimierung von 82,8 auf 83,3 %.

Bei diesem Verfahren besteht allerdings die Gefahr, dass z.B. eine kleine Rutschung eliminiert wird. Deshalb muss im Einzelfall entschieden werden, ob es sinnvoll ist, dieses Verfahren anzuwenden. Insbesondere, da es vor allem zu einer "Glättung" des Ergebnisses führt. Die Verbesserung lag in den untersuchten Fällen bei durchschnittlich 0,5 %.

Eine weitere Methode das Ergebnis zu optimieren, sind intelligente Abfragen. Wie bereits dargelegt, können z.B. die untersuchten Massenbewegungen nicht im Festgestein auftreten. Insofern sind instabile Bereiche im Festgestein falsch klassifiziert. Durch Abfragen kann die erkannte Gefahr mit der Gesteinsart verglichen werden und gegebenenfalls verändert werden.

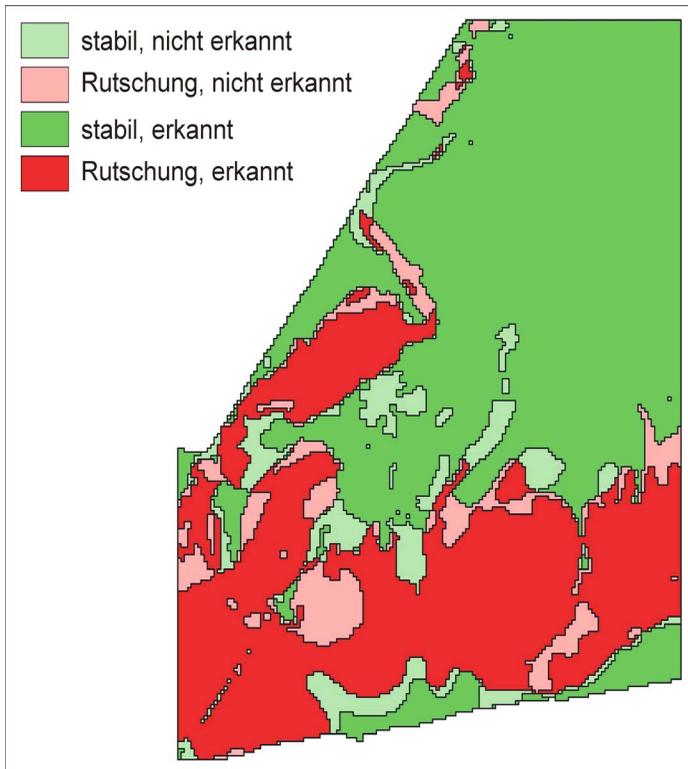


Abb. 4-12: Ergebnis der im Postprocessing durch Abfragen optimierten Rutschungsanalyse des DNet aus Abbildung 4-10. Die Erkennungsrate erhöht sich durch die Optimierung von 82,8 auf 84,5 %.

Durch eine Kombination von Nachbarschaftsanalyse und der oben dargestellten Abfrage konnten die Ergebnisse der Analyse nochmals um bis zu 2,1% verbessert werden.

4.1.7 Diskussion

Die neuronalen Modelle können die beiden Gebiete ähnlich gut analysieren. Dabei ist es nur bedingt relevant, ob die Netze den Standsicherheitsfaktor als Eingabemerkmale haben oder nicht. Auch ob der Schuttstrom im Training mitgelernt werden kann, beeinflusst das Ergebnis nur marginal. Einen erheblichen Einfluss hat allerdings die Größe der Untersuchungseinheiten.

Die besten Ergebnisse in beiden Gebieten erzielen die Netze ohne Standsicherheitsfaktor mit der 16-5-1 Architektur. Der Unterschied zu Netzen mit einer 16-11-1 Architektur liegt aber nur im Bereich von 1 bis 3 %. In der Auswertung für die Raumplanung sind diese Unterschiede jedoch fast nicht mehr feststellbar.

Beim Training hat sich gezeigt, dass die Netze sehr schnell eine gute Konfiguration finden. Meist reicht eine Trainingsepoche mit 500 Iterationsschritten bereits aus, um ein gutes Ergebnis zu erzielen. Durch Optimierung der Regularisierung (s.a. Kap. 4.4) z.B. mit dem Weight-Decay und einer weiteren Verbesserung der Architektur könnten noch bessere und stabilere Ergebnisse erzielt werden.

4.2 Ergebnisse der in Reihe geschalteten Neuronalen Netze

Bei den in Reihe geschalteten Netzen wird die Idee untersucht, mit einem zusätzlichen Neuronalen Netz die Abriss- bzw. Abbruchkanten, also den Ausgangspunkt von Rutschungen zu finden (s.a. Kap. 2.2). Die so erkannten Abrisskanten und deren Abstand zur untersuchten Zelle werden dann einem weiteren Neuronalen Netz als zusätzliche Eingabemerkmale für die Rutschungserkennung zur Verfügung gestellt.

Ursprünglich wurden die in Reihe geschalteten Netze (RNet) entwickelt, da in der 3. Entwicklungsstufe durch reine Optimierung mit den vorhandenen Netzen keine Fortschritte mehr erzielt werden konnten. Erst die Reduzierung des Eingabevektors in der 4. Entwicklungsstufe führte auch bei den Netzen zur Rutschungserkennung (NNet und DNet) wieder zu deutlichen Verbesserungen. Da die in Reihe geschalteten Netze jedoch bereits in der 3. Entwicklungsstufe im Stambachgebiet eine deutliche Verbesserung der Klassifikationsleistung um bis zu 3,3 % gegenüber den entsprechenden normalen Netzen gezeigt haben, wurde dieser Ansatz weiterverfolgt.

Im Folgenden werden die Netze zur Abbruchkantenerkennung vorgestellt. Anschließend werden die Fähigkeiten der in Reihe geschalteten Netze dargestellt und diskutiert. Da der Einfluss der Größe der Untersuchungseinheiten, der Merkmale und des Standsicherheitsfaktors bereits im vorhergehenden Kapitel diskutiert wurde, wird darauf in diesem Kapitel nicht mehr eingegangen.

4.2.1 Neuronale Netze zur Abbruchkantenerkennung (KNet)

Da die Netze zur Abbruchkantenerkennung ein Nebenprodukt der Entwicklung und ursprünglich nur ein Versuch waren, sind diese relativ einfach gehalten. Es wurden die Netze zur Rutschungserkennung aus Kap. 4.1 verwendet und auf die Ausgabe Abrisskante trainiert.

Die Ergebnisse in Tabelle 4.10 zeigen, dass diese einfachen Netze die Aufgabe auf den ersten Blick ganz gut lösen können. In Abbildung 4-13 ist jedoch erkennbar, dass nur große Strukturen erkannt werden. Es werden nur 34 % der Zellen mit Abrisskanten richtig erkannt. Umgekehrt werden aber 94 % der Zellen, in denen keine Abrisskanten liegen

4.2 Ergebnisse der in Reihe geschalteten Neuronalen Netze

richtig erkannt. Das bedeutet, dass das Netz einerseits die stabilen Bereiche außerhalb der großen Rutschungskessel gut erkennt und trotzdem noch ungefähr erkennt, wo die großen Abriss-Systeme liegen.

Tab. 4.10: Erkennungsraten der Netze zur Abbruchkantenerkennung in den beiden Untersuchungsgebieten für Netze mit (KDNet) und ohne Standsicherheitsfaktor (KNNet) bei einer 20 m Auflösung.

KDNet	Architektur	17-1	17-5-1	17-11-1
	Stambach	78,9%	80,6 %	81 %
	Zlambach	79,3 %	86,4%	84,1 %
KNNet	Architektur	16-1	16-5-1	16-11-1
	Stambach	79,2 %	80,4 %	80,6 %
	Zlambach	76,5 %	86 %	85,3 %

Da die Netze zur Abbruchkantenerkennung v.a. dafür genutzt werden, die neuen Merkmale „Abbruchkante“ und „Abstand zur Abbruchkante“ zu ermitteln, ist die exakte Reproduktion der Lage der Abrisskanten nicht ganz so wichtig. Es genügt, wenn zumindest der Bereich, in dem die Abrisskanten liegen könnten, erkannt wird. Über den Abstand zu diesem Bereich entsteht eine weitere wichtige Information für die Rutschungserkennung. Liegen Zellen in der Nähe von Abbruchkanten ist es wahrscheinlich, dass es sich um Zellen mit Rutschungen handelt.

Ein weiterer wichtiger Punkt ist, dass Zellen ohne Abrisskanten selten falsch erkannt werden. Hingegen liegen falsch erkannte Stellen meist in der Nachbarschaft von Zellen mit Abrisskanten. Das bedeutet, dass die Information "Abstand zur Abrisskante" als Mindestabstand gesehen werden kann.

Obwohl die Erkennungsrate im Zlambachgebiet sogar höher ist als im Stambachgebiet, handelt es sich hier nur um eine scheinbar gute Leistung. Da im Zlambachgebiet 87 % der Zellen keine Abbruchkanten enthalten, würde die Erkennungsrate sogar noch höher liegen, falls alle Zellen einfach als stabil ohne Abbruchkante klassifiziert würden.

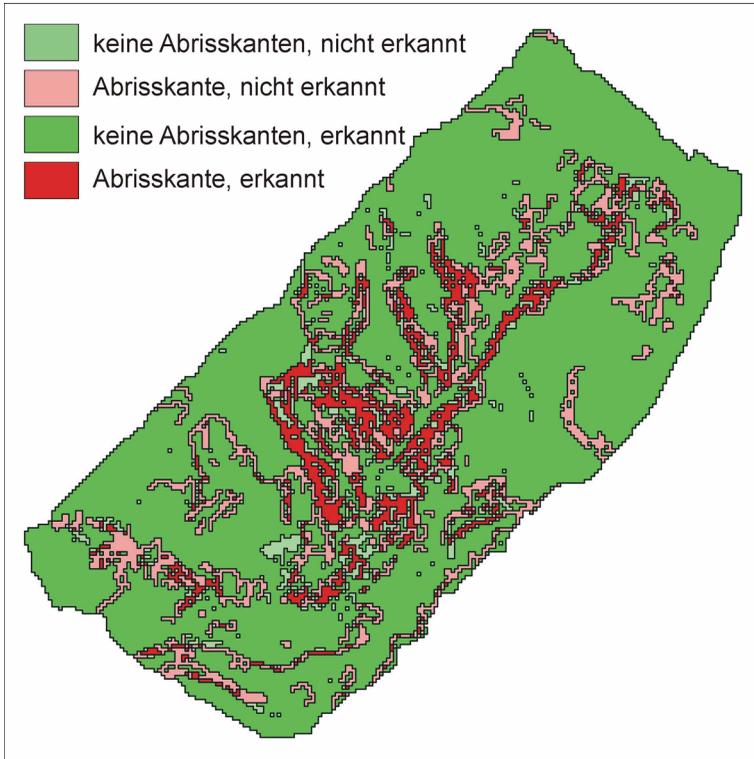


Abb. 4-13: Analyse der Abrisskantenerkennung mit dem Neuronalen Netz mit Standsicherheitsfaktor (KNet).

Dennoch werden wie im Stambachgebiet die Bereiche ohne Abrisskanten weitgehend richtig erkannt (92 %). Aus Abbildung 4-14 ist ersichtlich, dass zumindest teilweise größere Strukturen erkannt werden oder Zellen in der Nähe als Abrisskanten klassifiziert werden. Insofern ist auch hier der „Abstand zu Abrisskanten“ wahrscheinlich die wichtigere Information.

Eine mögliche Erklärung für das schlechtere Abschneiden im Zlam-bachgebiet ist, dass Abrisskanten hier vermehrt bzw. nach anderen Gesichtspunkten in der geotechnischen Karte weggelassen wurden.

4.2 Ergebnisse der in Reihe geschalteten Neuronalen Netze

Insofern könnten an den Stellen, an denen das Modell Abrisskanten erkennt, auch im Gelände Abrisskanten liegen.

Ein Punkt ist die generelle Schwierigkeit, die im Verhältnis zur Zellgröße relativ kleinen Strukturen von Abrisskanten auch an der richtigen Stelle zu finden. Deshalb werden in beiden Gebieten oft benachbarte Zellen als Abrisskanten erkannt (s. Abb. 4-13 und 4-14).

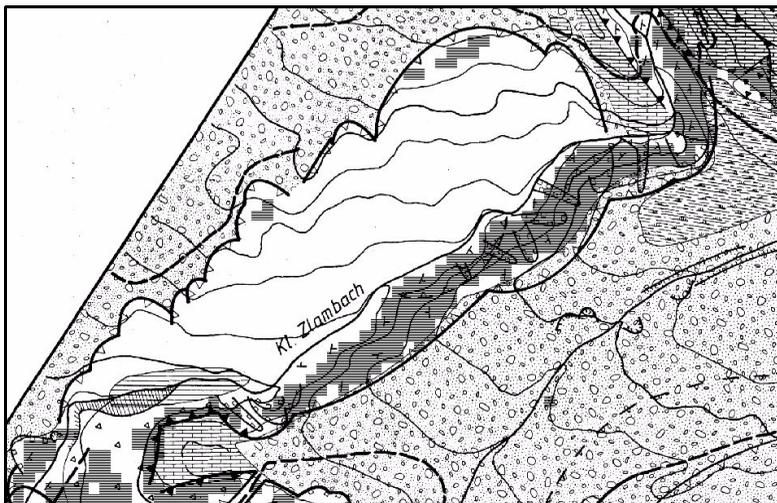


Abb. 4-14: Abrisskantenerkennung am großen Rutschkessel des Kleinen Zlambach. Die schraffierten Bereiche sind vom Neuronalen Netz als Zellen mit Abrisskanten erkannt worden.

Es sollte auch berücksichtigt werden, dass die Netze zur Abrisskantenerkennung relativ einfach sind und nicht speziell weiterentwickelt wurden. Es ist denkbar, dass Modelle mit teilweise anderen Merkmalen und besseren Geländemodellen eine höhere Klassifikationsleistung entwickeln.

4.2.2 Ergebnisse der in Reihe geschalteten Netze zur Rutschungserkennung im Trainingsgebiet Stambach

Wie oben bereits erwähnt, werden bei den in Reihe geschalteten Netzen die zuvor ermittelte Lage von Abrisskanten und der Abstand zu Abrisskanten den Netzen als zusätzliche Eingabemerkmale zur Verfügung

gestellt. Ansonsten entsprechen die Netze im Wesentlichen den in Kapitel 4.1 vorgestellten Netzen. Wie im Folgenden dargestellt, erfüllen die Neuronalen Netze mit dem Standsicherheitsfaktor (RDNet) als Merkmal und der 19-12-1 Architektur die Aufgabe am besten, daher werden die Ergebnisse an diesen diskutiert. Trotzdem werden zum Vergleich die Erkennungsraten beider Netze in den Tabellen angegeben.

Die Klassifikationsleistung der besten in Reihe geschalteten Netze (Tab. 4.11) entspricht bzw. übertrifft geringfügig die der in Kapitel 4.1 dargestellten einfachen Neuronalen Netze zur Rutschungserkennung (vgl. Tab. 4.8).

Tab. 4.11: Erkennungsrate von in Reihe geschalteten Netzen im Gebiet Stambach. Die Ergebnisse sind für die Netze mit (RDNet) und ohne Standsicherheitsfaktor (RNNet) dargestellt.

RDNet	Architektur	19-1	19-6-1	19-12-1
	Erkennungsrate	81,1%	84,7 %	85,9 %
RNNet	Architektur	18-1	18-6-1	18-12-1
	Erkennungsrate	81,3 %	85 %	85,5 %

Die in Reihe geschalteten Netze erkennen wie die vorher beschriebenen Modelle alle wichtigen Rutschungssysteme korrekt. Es wird sowohl die Lage als auch der ungefähre Umfang der großen Rutschkessel richtig dargestellt (Abb. 4-15). Die Rutschungen am Trauntal werden allerdings nicht ganz so gut erkannt.

Es fällt auf, dass die stabilen Bereiche insgesamt etwas homogener dargestellt werden als bei den einfachen Modellen (vgl. Abb. 4-3 und Abb. 4-15). So erkennt das RDNet 91,6 % der stabilen Zellen richtig, das DNet jedoch "nur" 89,9 %. Die Unsicherheitsbereiche an den Rändern der großen Rutschkessel sind bei dem RDNet auch etwas kleiner (Abb. 4-16).

4.2 Ergebnisse der in Reihe geschalteten Neuronalen Netze

Die Analyse des RDNet ist insgesamt etwas differenzierter. So werden auch kleinere, stabile Schollen wie am nördlichen Rand des Rutschkes-sels bei Hölln auf der Leitn zumindest teilweise richtig erkannt (s. Abb. 4-16).

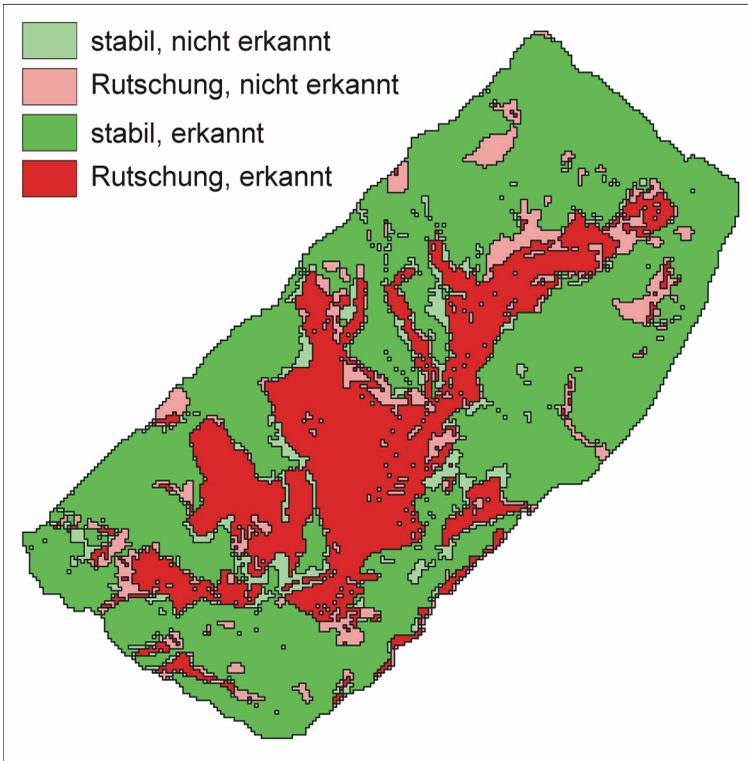


Abb. 4-15: Rutschungsanalyse für das Trainings- und Validierungsgebiet Stambach in 20 m Auflösung mit dem RDNet (in Reihe geschaltete Netze mit Standsicherheitsfaktor). Die Erkennungsrate liegt bei 85,8 %.

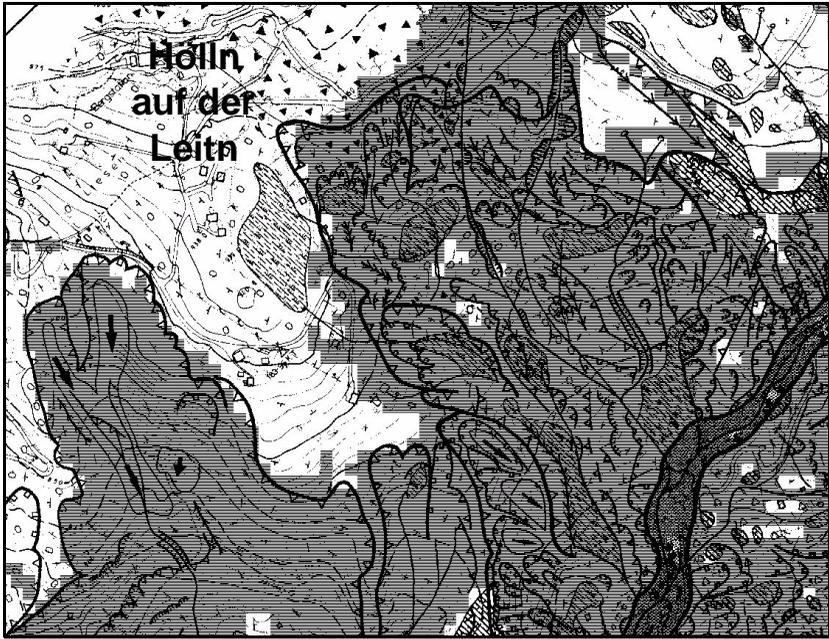


Abb. 4-16: Als instabil erkannte Bereiche (schraffiert) in den großen Rutschkesseln bei Hölln auf der Leitha.

Im oberen, nördlichen Teil des Schuttstroms ist die Klassifikationsleistung etwas schlechter als in den vorherigen Modellen (vgl. Abb. 4-3 und 4-15). Während die zentralen Bereiche des Schuttstroms dort gut erkannt werden, werden die instabilen Flanken nur teilweise erkannt.

Eine entscheidende Verbesserung ist bei den sich entwickelnden „jungen“ Wildbachsystemen erzielt worden. So wird das sich gerade entwickelnde System bei Solbach, nördlich von St. Agatha, ganz gut erkannt (Abb. 4-17). Dieses ist von den anderen Modellen überhaupt nicht erkannt worden. Auch die Fortsetzungen der Wildbachsysteme bei der Rossmoosalm werden nicht mehr generell als instabil angesehen, sondern nur die Bereiche in denen auch auf der geotechnischen Karte Abrisskanten eingetragen sind. Aus dieser besseren Differenzierungsfähigkeit des Modells resultieren die Unterschiede und etwas besseren Ergebnisse gegenüber den einfachen Modellen aus Kap. 4.1.

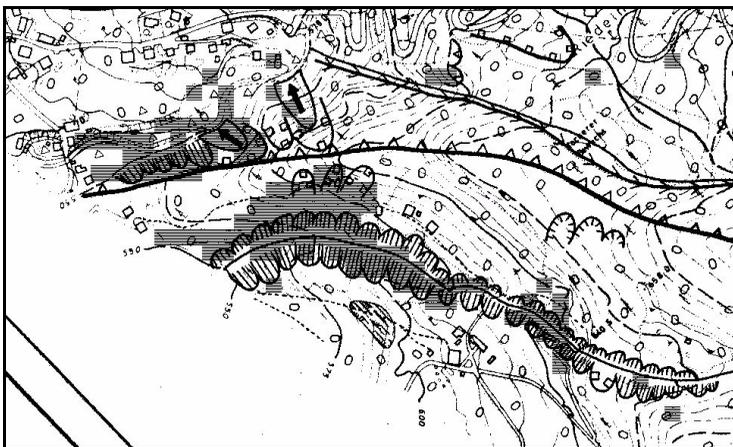


Abb. 4-17: Als instabil erkannte Bereiche (schraffiert) an einem „jungen“ noch nicht so deutlich ausgebildeten Wildbach bei Solbach nördlich von St. Agatha.

Allerdings werden nicht alle „jungen“ Wildbachsysteme und Rutschkessel besser erkannt. Der in Abbildung 4-6 links dargestellte Wildbach wird auch von diesem Modell nicht erkannt. Auch der in Abbildung 4-5 erkennbare junge Rutschkessel wird nicht richtig erkannt. Es kann also nicht von einer generellen Verbesserung gesprochen werden, sondern es entwickeln sich nur spezielle Fähigkeiten weiter. Kleinere singuläre Rutschungen, die zumindest teilweise von den einfachen Netzen erkannt wurden, werden von den in Reihe geschalteten Netzen schlechter erkannt.

Die Einführung der beiden neuen Merkmale scheint im Stambachgebiet dazu zu führen, dass die Bereiche, in denen viele Abrisskanten liegen, besser erkannt werden. Insofern werden die aktiveren Bereiche besser erkannt. Gerade in den Randbereichen der großen Rutschungssysteme führt dies zu einer Verbesserung des Ergebnisses. Umgekehrt werden die stabilen Bereiche besser und homogener erkannt, da die Abrisskanten hier weit entfernt sind. Dennoch hilft die Information „Abstand zu Abrisskanten“ aber vermutlich vorwiegend, die stabilen Bereiche besser zu erkennen.

4.2.3 Ergebnisse der in Reihe geschalteten Netze zur Rutschungserkennung im Testgebiet Zlambach

Im Zlambachgebiet sind die Erkennungsraten der in Reihe geschalteten Neuronalen Netze bezogen auf die alte Gefahrenkarte etwas geringer als bei den entsprechenden einfachen Netzen aus Kapitel 4.1.5.

Tab. 4.12: Erkennungsrate von in Reihe geschalteten Netzen im Gebiet Zlambach für die alte Gefahrenkarte. Die Ergebnisse sind für die Netze mit (RDNet) und ohne Standsicherheitsfaktor (RNNet) dargestellt.

RDNet	Architektur	19-1	19-6-1	19-12-1
	Erkennungsrate	71,4 %	71,4%	71,8 %
RNNet	Architektur	18-1	18-6-1	18-12-1
	Erkennungsrate	71,8 %	72,1 %	71,8 %

Wie zuvor fällt beim Vergleich der geotechnischen Karte mit den Ergebnissen der Neuronalen Netze die gute Übereinstimmung mit den großen Rutschungskesseln auf. Diese ist sogar noch besser als bei den Netzen aus Kapitel 4.1. Auch hier gilt wie im Stambachgebiet, dass die Randbereiche der Kessel besser erkannt und differenzierter dargestellt werden. Der Rutschkessel am Kleinen Zlambach wird z.B. noch etwas besser und komplett erkannt (Abb. 4-18). Hier wird der ganze Kessel erkannt und der Rand wird exakt abgebildet. Auch die Rutschkessel bei der Leislingalm werden ähnlich gut erkannt.

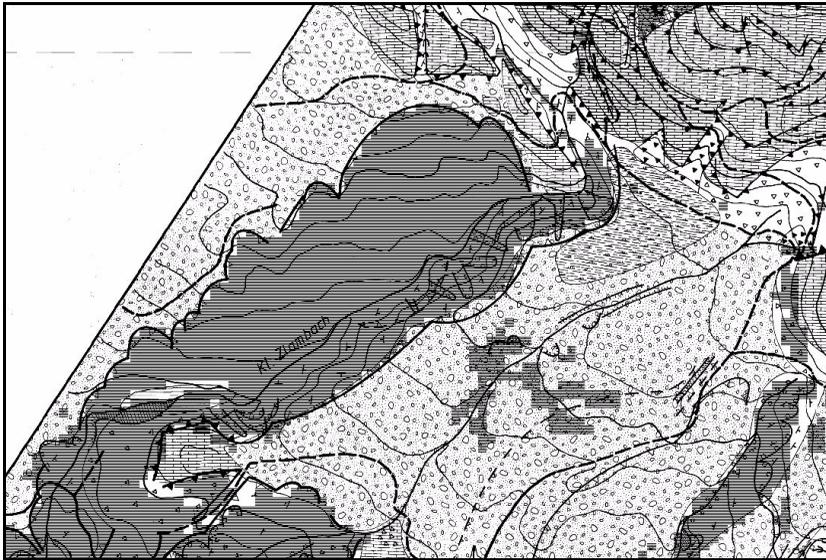


Abb. 4-18: Rutschungskessel am Kleinen Zlambach. Die Schraffur zeigt den vom Netz als instabil erkannten Bereich.

Entsprechend sind auch die Ergebnisse der in Reihe geschalteten Netze mit der erweiterten Gefahrenkarte (s. Kap. 4.1.5) verglichen worden. In Abbildung 4-19 ist das Ergebnis der Analyse dargestellt. Es zeigt, dass die Netze die großen Rutschkessel sehr gut erkennen. Unsicherheiten treten wie zuvor v.a. am Rand der stabilen bzw. instabilen Bereiche auf. Insofern ist das Ergebnis für die Raumplanung akzeptabel.

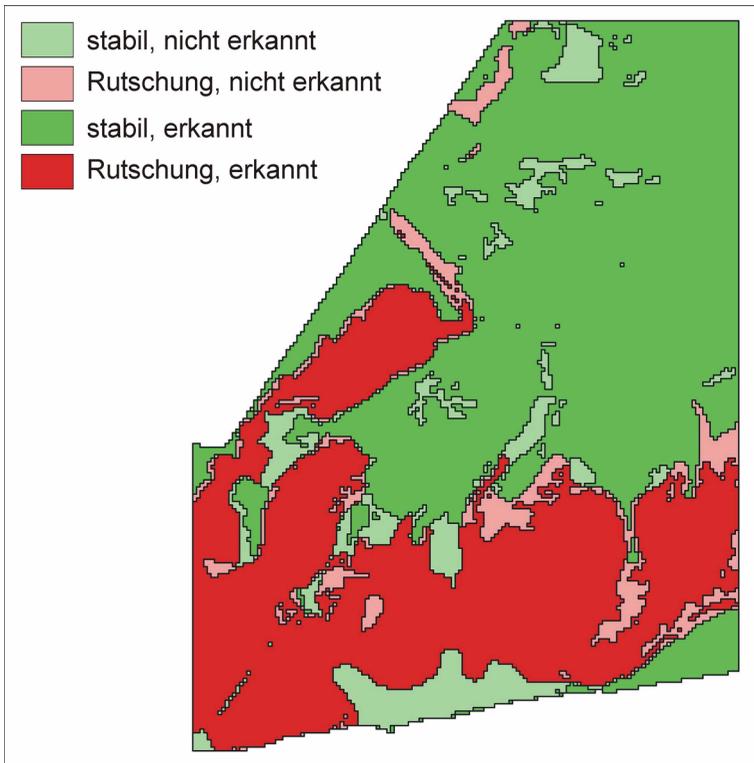


Abb. 4-19: Revidierte Rutschungsanalyse für das Testgebiet Zlambach auf Grundlage der erweiterten Gefahrenkarte mit RDN_{et}. Die Erkennungsrate erhöht sich von 71,2 % auf 85,4 %.

Allerdings werden auch Bereiche von stark zerrütteten Kalken und Dolomiten am Raschberg als instabile Bereiche erkannt. Zwar kommt es in diesen Bereichen zu Massenbewegungen, allerdings handelt es sich um Felsgleitungen bzw. Staffelbrüche. Insofern ist diese Klassifikation als Massenbewegung im Lockergestein falsch. Vermutlich ergibt sich aus der dortigen sehr steilen Morphologie ein ähnliches Bild wie bei Rutschkesseln. Das wäre eine mögliche Erklärung für die falsche Klassifikation. Im Vergleich mit den entsprechenden Netzen aus Kapitel 4.1.5 erkennen diese Netze dennoch die stabilen Bereiche besser. Es bestätigen sich somit die im Stambachgebiet gemachten Beobachtungen.

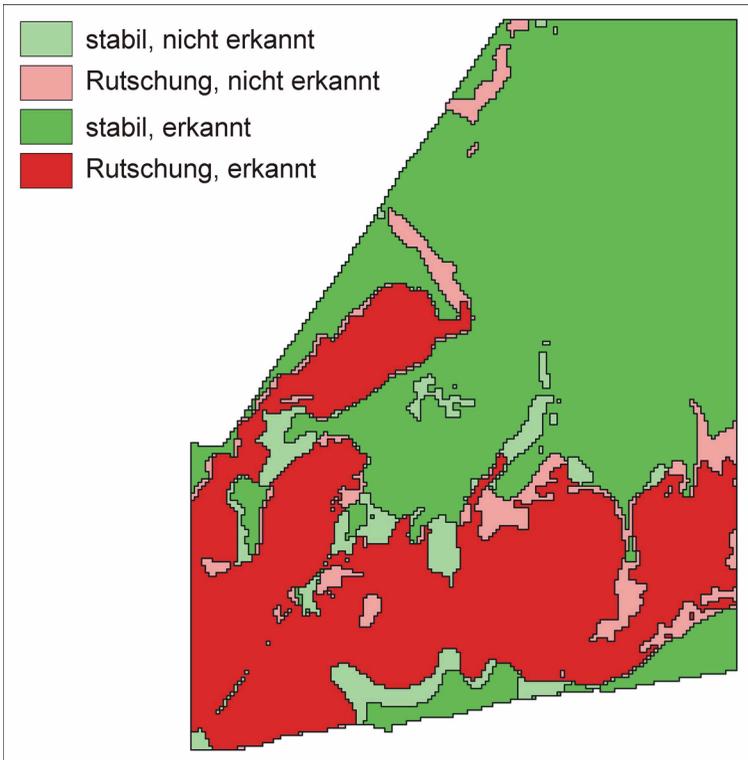


Abb. 4-20: Ergebnis der im Postprocessing optimierten Rutschungsanalyse des RDNet. Die Erkennungsrate erhöht sich dadurch von 85,4 % auf 88,8 %.

Trotz der verhältnismäßig guten Klassifikationsleistung der Netze konnte auch hier mit dem in Kapitel 4.1.6 beschriebenen Postprocessing eine Verbesserung um mehr als 3 % auf 88,8 % erzielt werden (s. Abb. 4-20).

4.2.4 Diskussion

Beim Vergleich der Tabellen 4.11 und 4.12 fällt auf, dass hier das Netz mit Standsicherheitsfaktor und 12 Hiddenneuronen als bestes Modell

vorgestellt wird, obwohl andere Modelle die gleiche oder sogar bessere Erkennungsraten zeigen. Abbildung 4-21 zeigt allerdings, dass das Modell bezogen auf die erweiterte Gefahrenkarte die beste Erkennungsrate zeigt. Es werden die Gefahrenbereiche am homogensten und umfassendsten dargestellt.

Allerdings muss auch erwähnt werden, dass bei den hier vorgestellten in Reihe geschalteten Netzen die linearen Modelle, also ohne Hiddenneuronen, im Zlambachgebiet fast genauso gut sind wie die komplexeren Modelle. Im Stambachgebiet schneiden sie aber deutlich schlechter ab. Da ein optimales Netz in beiden Gebieten möglichst gleich gut sein sollte, ist das lineare Modell insgesamt gesehen also nicht das beste Modell. Allerdings müsste noch untersucht werden, warum das lineare Modell im Zlambachgebiet so gut abschneidet und ob es nicht möglich ist, mit einer veränderten Architektur bzw. mit veränderten Merkmalen auch bei den komplexeren Modellen bessere Ergebnisse zu erzielen (s.a. Kap. 4.1.1).

Interessant ist, dass die in Reihe geschalteten Netze eine gute bzw. sogar bessere Klassifikationsleistung erzielen als die einfachen Netze aus Kapitel 4.1, obwohl die Eingabe aus dem Netz zur Abbruchkantenerkennung nicht so gut ist. Das gilt besonders für das Zlambachgebiet, in dem die Leistung der Netze zur Abbruchkantenerkennung eigentlich unbefriedigend ist. Vermutlich trägt vor allem das Merkmal „Abstand zu Abbruchkanten“ zur Verbesserung des Ergebnisses bei. Dieses Merkmal hat als Gradient den Vorteil, dass es auch für die Erkennung stabiler Bereiche sinnvoll ist. So kann nicht nur aus der Nähe einer Abrisskante auf eine Rutschung, sondern aus der Entfernung auch auf einen stabilen Bereich geschlossen werden.

Die Versuche haben gezeigt, dass es nicht sinnvoll ist, sich nur auf die Erkennungsrate als einziges Bewertungskriterium zu verlassen. So zeigen die in Abbildung 4-21 dargestellten Netze bezogen auf die alte Gefahrenkarte fast die gleichen Ergebnisse mit einer Varianz von 2%. Erst die Überprüfung mit der geotechnischen Karte hat gezeigt, dass die Ergebnisse in Bezug auf die Rutschungserkennung sehr unterschiedlich sind. So entwickeln manche Netze, deren Gesamtperformance nicht so gut ist, spezielle Fähigkeiten. Die Netze ohne Standsicherheitsfaktor (RNNet) erkennen z.B. die stabilen Felsbereiche besser als die Netze mit Standsicherheitsfaktor. Die Netze mit mehr Hiddenneuronen erken-

4.2 Ergebnisse der in Reihe geschalteten Neuronalen Netze

nen Rutschkessel besser als die mit weniger. Dafür erkennen die Netze mit weniger Hiddenneuronen die stabilen Felspartien nicht so gut.

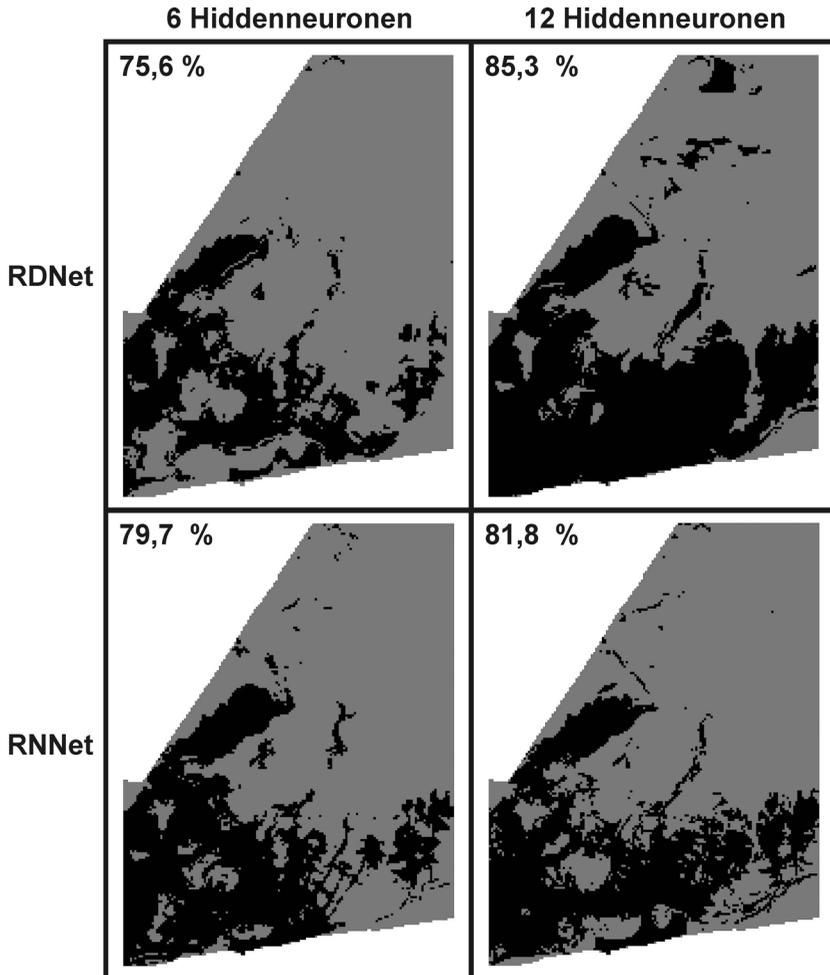


Abb. 4-21: Vergleich der Ergebnisse von Netzen mit (RNet) und ohne Standsicherheitsfaktor (RNNet) sowie unterschiedlicher Anzahl an Hiddenneuronen im Zlambachgebiet (Legende s. Abb. 4-1).

Da je nach Aufgabenstellung bestimmte Fähigkeiten bevorzugt werden, ist die spätere Interpretation der Ergebnisse und Überprüfung anhand der geotechnischen Karte immer sinnvoll. Dies ist um so wichtiger, da durch das Postprocessing die Ergebnisse weiter verarbeitet werden. Zum Beispiel wird der Vorteil der besseren Erkennung von stabilen Bereichen von den Netzen ohne Standsicherheitsfaktor hinfällig, da im Postprocessing die Felsbereiche sowieso als stabil klassifiziert werden.

Zusammenfassend lässt sich sagen, dass bei den in Reihe geschalteten Netzen diejenigen mit 12 Hiddenneuronen am besten geeignet sind, um die Rutschungsbereiche in beiden Gebieten zu erkennen. Allerdings kann nicht gesagt werden, ob die Netze mit Standsicherheitsfaktor generell am besten für diese Aufgabe geeignet sind. Das hängt auch von der Art und der Verteilung der Massenbewegungen ab.

Hier könnte eventuell der in Kapitel 2.1.3 beschriebene Komitee-Ansatz weiterhelfen. Dabei würden die Ergebnisse der verschiedenen Modelle über Mittelwertbildung oder Majoritätsentscheidungen verbunden und nur das Gesamtergebnis betrachtet. Außerdem könnten Tests an Gebieten, in denen mehr bzw. weniger Rutschgebiete auftreten helfen, die Fähigkeiten der einzelnen Netze besser einzuschätzen.

4.3 Ergebnisse der nach dem MTL-Ansatz trainierten Neuronalen Netze zur Rutschungserkennung (MTLNet)

Beim MTL-Ansatz (Multitask Learning) wird berücksichtigt, dass bei ähnlichen Problemen oft dieselben Informationen wichtig sind. Durch das gemeinsame Lernen werden diese Informationen gestärkt und weniger wichtige Informationen geschwächt. Das hat den Vorteil, dass dieses Verfahren ähnlich der Regularisierung der Komplexität des Modells entgegenwirkt.

Hier ist das Merkmal Abrisskante als weitere Ausgabe gewählt worden. Da Abrisskanten immer auch dem Abrissbereich und somit dem Ursprungsbereich von Rutschungen entsprechen, können die Netze so eventuell die Randbereiche von Rutschungen besser erkennen. Außerdem können sich die Netze dann nicht mehr so stark auf die Spezialfälle im Trainingsgebiet Stambach konzentrieren.

Die hier entwickelten Netze entsprechen in Architektur und Eingabemerkmale den einfachen Netzen aus Kapitel 4.1. Sie sind lediglich um die zweite Ausgabe Abrisskanten erweitert worden. Die Ergebnisse werden an den Netzen mit Standsicherheitsfaktor (DMTLNet) und 11 Hiddenneuronen dargestellt.

4.3.1 Ergebnisse im Trainings- und Validierungsgebiet Stambach

Die MTL-Netze erreichen im Stambachgebiet ungefähr die gleiche Klassifikationsleistung (Tab. 4.13) wie die in den vorangegangenen Kapiteln beschriebenen Netze. Allerdings fällt auf, dass die Veränderung der Klassifikationsleistung hier zwischen den Netzen mit 5 Hiddenneuronen und denen mit 11 deutlich größer ausfällt.

Hier scheint die höhere Anzahl an Hiddenneuronen notwendig zu sein, um beide Aufgaben erfüllen zu können. Zusätzlich sind noch Untersuchungen an Netzen mit 17 bzw. 22 Hiddenneuronen durchgeführt worden. Dabei hat sich gezeigt, dass mehr Hiddenneuronen zu keiner Verbesserung des Ergebnisses führen. Allerdings führten sie auch nicht zu einer Verschlechterung wie bei den einfachen Netzen zur Rutschungserkennung (vgl. Kap. 4.1.1). Insofern scheint es durch den MTL-Ansatz tatsächlich zu einer Art Regularisierung zu kommen.

Tab. 4.13: Erkennungsrate der mit MTL trainierten Netze im Gebiet Stambach. Die Ergebnisse sind für die Netze mit (DMTLNet) und ohne Standsicherheitsfaktor (NMTLNet) dargestellt.

DMTLNet	Architektur	17-2	17-5-2	17-11-2
	Erkennungsrate	81,6%	82,8 %	85 %
NMTLNet	Architektur	16-2	16-5-2	16-11-2
	Erkennungsrate	81,1 %	82,2 %	84,3 %

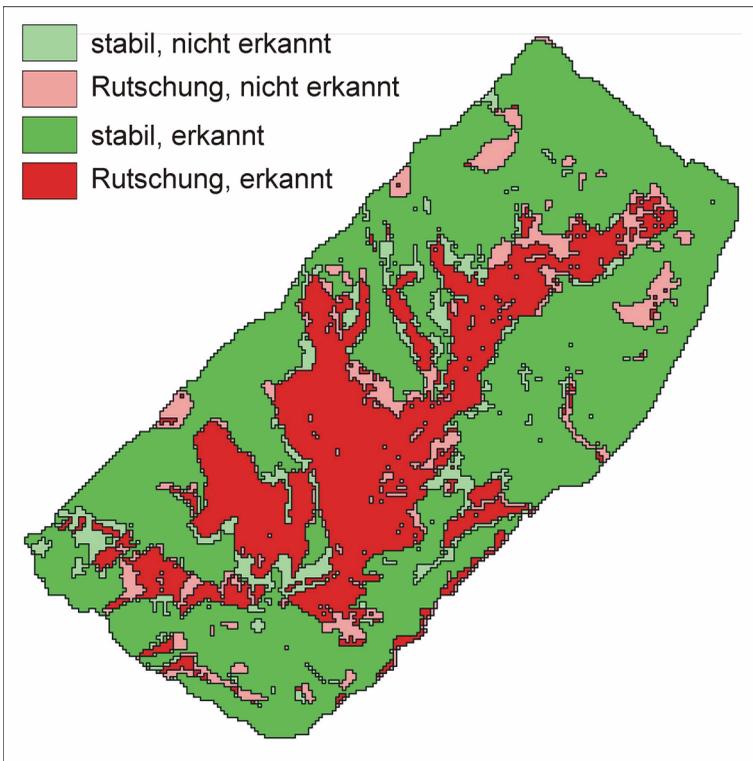


Abb. 4-22: Auswertung der Klassifikation des Trainingsgebietes Stambach mit dem MTL Netz mit Standsicherheitsfaktor (DMTL-Net).

4.3 Ergebnisse der nach dem MTL-Ansatz trainierten Neuronalen Netze

Abbildung 4-22 zeigt, dass das Netz alle wichtigen Rutschungsstrukturen erkennen und auch relativ detailliert wiedergeben kann. Es werden sowohl die Rutschungen am Trauntal gut wiedergegeben als auch die Wildbachsysteme gut erkannt. Die jungen Wildbachsysteme und Rutschkessel werden besser erkannt als bei den einfachen Netzen.

Hinsichtlich ihrer Klassifikationsleistung entsprechen die MTL-Netze im Wesentlichen den in Reihe geschalteten Netzen. Wie bei den anderen Modellen erhöht sich die Erkennungsrate auch im Postprocessing nur noch um weniger als 1%, was bedeutet, dass die Festgesteinsbereiche im Stambachgebiet gut erkannt werden.

4.3.2 Ergebnisse im Testgebiet Zlambach

Das MTL-Netz zeigt auch im Zlambachgebiet eine gute Leistungsfähigkeit. Bezogen auf die alte Gefahrenkarte entsprechen die Klassifikationsleistungen (Tab. 4.14) ungefähr denen der einfachen und in Reihe geschalteten Netze.

Tab. 4.14: Erkennungsrate der mit MTL trainierten Netze im Gebiet Zlambach. Die Ergebnisse sind für die Netze mit (DMTLNet) und ohne Standsicherheitsfaktor (NMTLNet) dargestellt, bezogen auf die alte Gefahrenkarte.

DMTLNet	Architektur	17-2	17-5-2	17-11-2
	Erkennungsrate	70,4%	72,2 %	72,8 %
NMTLNet	Architektur	16-2	16-5-2	16-11-2
	Erkennungsrate	63,2 %	77,5 %	68,9 %

Allerdings scheint das Netz mit der 16-5-2 Architektur ohne Standsicherheitsfaktor sich besonders gut auf die alte Gefahrenkarte (vgl. Tab. 4.14) einzustellen. Beim Vergleich mit der geotechnischen Karte fällt allerdings auf, dass das Netz nicht alle wichtigen Rutschungsstrukturen erkennt und im Vergleich mit der erweiterten Gefahrenkarte deutlich auf 71,6 % Erkennungsrate abfällt .

Wie bei den in Reihe geschalteten Netzen zeigen auch die MTL-Netze mit 11 Neuronen (Ana3) und dem Standsicherheitsfaktor (DMTLNet) insgesamt die beste Leistung (s. Abb. 4-23)

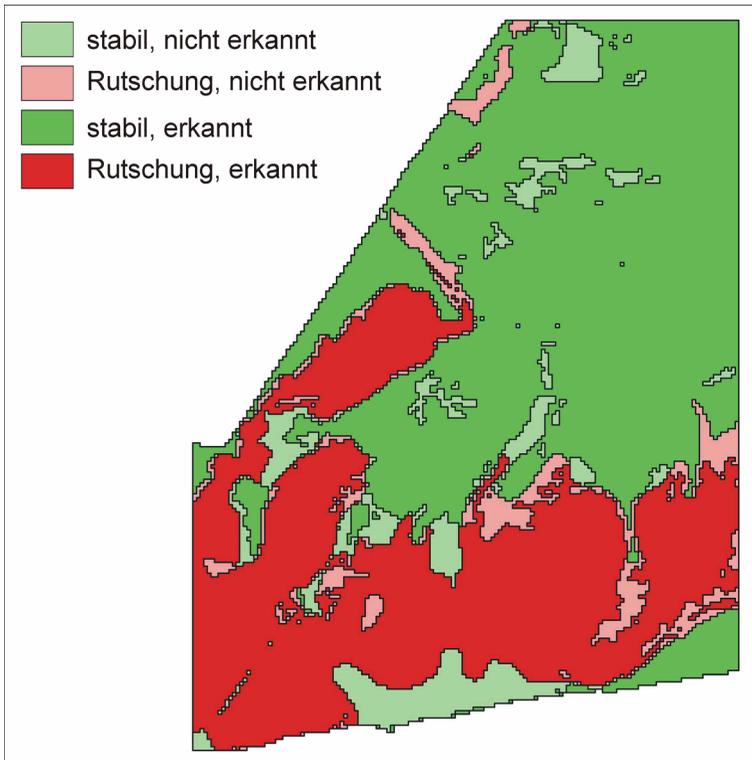


Abb. 4-23: Revidierte Rutschungsanalyse für das Testgebiet Zlambach auf Grundlage der ergänzten Gefahrenkarte mit DMTLNet. Die Erkennungsrate erhöht sich von 72,8%% auf 86,7 %.

Abbildung 4-23 zeigt beim Vergleich mit der revidierten Gefahrenkarte, dass alle wichtigen Rutschungsstrukturen erkannt werden. Allerdings zeigt das Netz Tendenzen, an den Rändern der Rutschkessel auch die stabilen Randbereiche als instabil zu klassifizieren. Die Hallstätter Kalke südlich des Stambach werden auch bei diesem Modell falsch als instabile Bereiche klassifiziert.

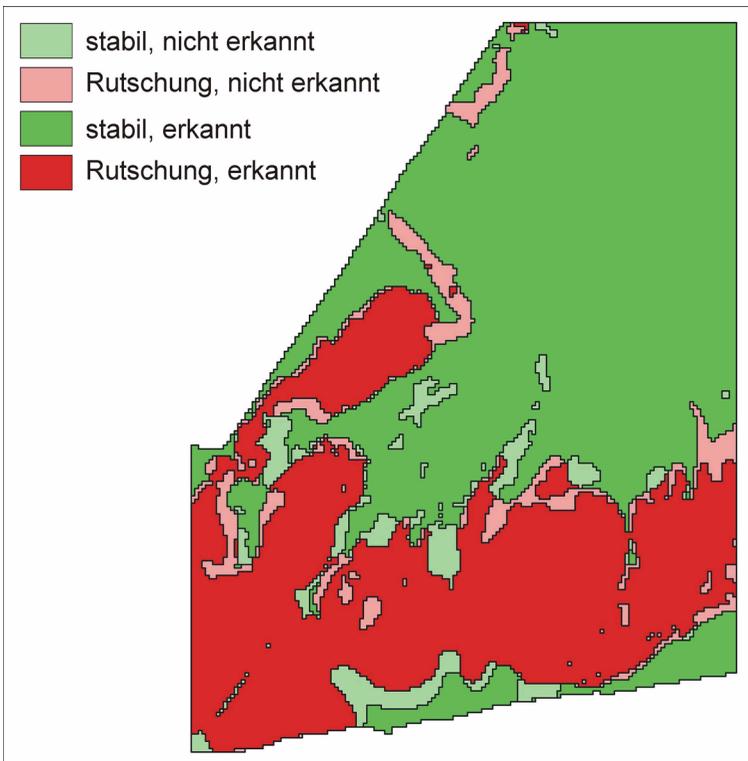


Abb. 4-24: Ergebnis der im Postprocessing optimierten Rutschungsanalyse des DMTLNet. Die Erkennungsrate erhöht sich dadurch von 86,7 % auf 89,1 %.

Die Fehler in den Festgesteinsbereichen können allerdings im Postprocessing korrigiert werden. So kann die Erkennungsrate des Modells auf 89,1 % erhöht werden (s.a. Abb. 4-24).

4.3.3 Diskussion

Die nach dem MTL-Ansatz trainierten Netze zeigen aus geologischer Sicht eine gute Klassifikationsleistung. Die wichtigen Strukturen werden alle erkannt.

Allerdings erkennen die MTL Netze das Zlambachgebiet deutlich besser als das Stambachgebiet. Das würde auf einen Overfitting-Effekt auf den Testdaten hinweisen. Das Ergebnis kann aber auch so interpretiert werden, dass durch den MTL-Ansatz die Komplexität des Modells sinnvoll begrenzt wurde. Das Trainingsgebiet Stambach ist wie in Kapitel 2.3.3 dargestellt, aus geotechnischer Sicht etwas komplexer. Im Stambachgebiet gibt es mehr verschiedenartige Massenbewegungen und die Massenbewegungssysteme sind in verschiedenen Stadien ausgebildet. Im Testgebiet Zlambach sind die Massenbewegungen und die Systeme wesentlich homogener. Die Rutschungskessel entsprechen fast alle dem Typ des aktiven Kessels bei Hölln auf der Leitrn im Stambachgebiet. Es besteht also die Möglichkeit, dass das Netz im Stambachgebiet die grundlegenden Prozesse sehr gut gelernt hat. Im einfacheren Zlambachgebiet können deshalb die Massenbewegungen besser erkannt werden.

Der erwünschte Effekt der Begrenzung der Komplexität des neuronalen Modells wurde zumindest insofern erfüllt, dass die Netze sehr viel besser als die zuvor vorgestellten Modelle mit einer hohen Anzahl an Hiddenneuronen, also freien Parametern, zurechtkommen. Ob die MTL-Netze generell dem Overfitting-Effekt gut entgegenwirken, kann jedoch nicht abschließend geklärt werden. Dafür sind weitere Untersuchungen notwendig.

4.4 Untersuchungen zur Regularisierung

Abschließend wurde untersucht, wie sich Regularisierung durch Early Stopping oder den Weight-Decay auswirkt. Diese Untersuchungen wurden mit den Netzen zur Rutschungserkennung mit dem Standsicherheitsfaktor (DNet) mit einem reduzierten Datensatz in 30 m Auflösung gemacht. Das ist möglich, da diese Konfiguration zwar etwas schlechtere Ergebnisse erzeugt, diese größtmäßig allerdings ungefähr denen bei 20 m Auflösung entsprechen und deutlich schneller durchführbar sind.

Die bisher vorgestellten Netze wurden alle mit 500 Iterationsschritten („runs“), einer Anfangsschrittweite von 0,001, einer maximalen Schrittweite von 1 und einem Weight-Decay von 0,02 trainiert. Sie wurden maximal mit 10 Trainingsepochen trainiert. Allerdings hat sich gezeigt, dass selten mehr als 4 erforderlich sind, um ein gutes Ergebnis zu erzielen. Bei mehr Trainingsepochen „verlernen“ die Netze oft zuvor erlangte Fähigkeiten wieder und die Klassifikationsleistung beginnt zu oszillieren.

Da die Netze mit dem Rprop-Algorithmus sehr schnell lernen, wurden Versuche mit Early-Stopping gemacht um festzustellen, ob hiermit eine bessere Generalisierungsfähigkeit erlangt werden kann (s.a. Kap. 2.1.3.2). Bei den Versuchen hat sich gezeigt, dass eine geringfügige Verbesserung um bis zu 1 % erzielt werden kann, wenn die Anzahl der Iterationsschritte auf 300 reduziert wird. Bei weniger Iterationsschritten bleibt die Klassifikationsleistung gleich und unter 150 nimmt die Leistung ab. Problematisch ist beim Early-Stopping, dass die Einstellung immer in Bezug auf die Trainings- bzw. Validierungsmenge vorgenommen wird. Es ist also nicht so einfach herauszufinden, ob der erlangte Vorteil nur in den untersuchten Gebieten gilt. Die hier erreichten geringen Verbesserungen liegen auch in Bereichen, die schon im Postprocessing oder durch Veränderung der Datenauflösung erreicht werden (s. Kap. 4.1.2 und 4.1.6).

Interessanter sind die Ergebnisse von Netzen, die mit unterschiedlichen Weight-Decay Termen durchgeführt wurden. Hier hat sich gezeigt, dass bei einer Erhöhung des Weight-Decay von 0,02 auf 0,05 die Netze sehr schnell lernen und die Schwankungsbreite zwischen guten

und schlechten Netzen abnimmt. So kann auch mit weniger Trainings-epochen ein sehr gutes Ergebnis erzielt werden und die Schwankung des Fehlers nimmt um die Hälfte ab. Allerdings wird das Problem damit nicht völlig gelöst, sondern nur reduziert. Da die Einstellung des Weight-Decay nicht ganz einfach ist und iterativ erfolgt, könnten weitere Versuche sicherlich noch zu einem optimierten Ergebnis führen. Die maximale Klassifikationsleistung der mit einem Weight-Decay von 0,05 trainierten Netze entspricht etwa dem, der mit 0,02 trainierten Netze.

Vorzugsweise sollte die Optimierung des Weight-Decay gegenüber dem Early-Stopping benutzt werden, da es sich um eine echte, generell wirkende Regularisierung handelt.

5 ZUSAMMENFASSUNG UND AUSBLICK

5.1 Zusammenfassung

Die Ergebnisse der vorliegenden Arbeit zeigen, dass es möglich ist, mit Neuronalen Netzen nicht nur einzelne Rutschungen, sondern ganze Rutschungsbereiche auch in einem komplexen geologischen Umfeld zu erkennen. Die hier entwickelten Modelle eignen sich besonders für die Erkennung von Massenbewegungen in Zusammenhang mit Wildbachsystemen und großen Rutschkesseln, die sich durch Tiefen- bzw. rückschreitende Erosion bilden. Bemerkenswert ist v.a. ihre Fähigkeit, den ganzen Bewegungs- bzw. Einflussbereich der Massenbewegungen zu erkennen. Sie erkennen sowohl den Abrissbereich als auch die Gleitbahn und die Rutschmasse als Rutschungsbereich. Unerheblich dabei ist, ob es sich vorwiegend um Rotations- bzw. Translationsgleitungen oder Fließbewegungen handelt.

Bei allen Modellen hat sich gezeigt, dass die Optimierung des Eingabektors ein entscheidender Punkt bei der Modellentwicklung ist. Allein durch eine Veränderung der Eingabemerkmale (Merkmalsselektion) und eine gute Codierung kann die Leistungsfähigkeit der neuronalen Modelle entscheidend beeinflusst werden.

Durch Merkmalsselektion werden auch die Fähigkeiten der Neuronalen Netze und das Analyseziel entscheidend gesteuert. Die verwendeten Merkmale wie "Abstand zu Bächen", "Exposition" oder "Hangform" sind v.a. geeignet, Massenbewegungen zu erkennen, die durch Erosionsprozesse gesteuert werden. Aus diesem Grund sind die hier entwickelten Modelle z.B. nicht geeignet zur Erkennung erdbebeninduzierter Rutschungen. Dafür müssten eigene Modelle entwickelt werden, die z.B. tektonische Elemente stärker als Eingabemerkmale berücksichtigen wie z.B. "Abstand zu aktiven Störungszonen".

Wie bei allen datenbasierenden Verfahren ist es wichtig, dass die Trainingsmuster die untersuchten Prozesse darstellen können. Da der überwiegende Teil der untersuchten Massenbewegungen in Zusammenhang mit übersteilten Hängen und Wildbacherosion steht, werden vorwiegend die diesen Massenbewegungen zugrundeliegenden Prozesse gelernt. Außerdem spielt die Qualität der Datensätze eine große Rolle. Schlechte Höhenmodelle machen es nahezu unmöglich, aus die-

sen wichtige Informationen wie Hangneigungsänderung oder Geländeform in ausreichender Genauigkeit zu ermitteln.

Die Untersuchungen an den drei Modellen haben gezeigt, dass mit verschiedenen Ansätzen durchaus ähnliche Ergebnisse erzielt werden können. Im Detail zeigt sich aber, dass jedes Modell darüber hinaus besondere Stärken oder Schwächen entwickelt.

“Einfache” Neuronale Netze zur Rutschungserkennung zeigen eine durchgehend gute Erkennungsrate von über 82 %. Sie sind sicherlich die am wenigsten spezialisierten Netze, weshalb sie auch unterrepräsentierte Massenbewegungen zumindest ansatzweise erkennen können. Allerdings zeigen sie Schwächen bei der Erkennung junger Wildbachsysteme und kleinerer nicht so stark ausgebildeter Rutschkessel. Außerdem erkennen sie die stabilen Hangbereiche nicht so gut wie die anderen Modelle.

“In Reihe geschaltete” Netze können beide Untersuchungsgebiete nahezu gleich gut abbilden. Die besten Netze erkennen ca. 85 % der untersuchten Zellen richtig. Gegenüber den anderen Modellen liegt ihre Stärke in der Fähigkeit, die stabilen Bereiche am besten zu erkennen. Allerdings neigen sie dazu, sich auf die Massenbewegung im Trainingsgebiet zu spezialisieren. Im Gegensatz zu den anderen Netzen können sie zum Teil auch junge, wenig ausgeprägte Wildbachsysteme erkennen. Unterrepräsentierte Massenbewegungen erkennen sie jedoch fast überhaupt nicht.

Die MTL-Netze bilden in gewisser Weise den Mittelweg zwischen den beiden oben genannten Modellen. Sie erkennen sowohl die stabilen Bereiche sehr gut als auch die meisten Rutschungsbereiche. Die Tendenz zur Spezialisierung des Modells ist nicht ganz so hoch wie bei den in Reihe geschalteten Netzen. Insofern bietet der MTL-Ansatz eine sinnvolle Möglichkeit, die Modellkomplexität zu reduzieren und die Generalisierungsfähigkeit zu optimieren. Die Klassifikationsleistung der besten Netze in beiden Gebieten liegt hier bei über 85 %.

Der Standsicherheitsfaktor als zusätzliches Eingabemerkmal führt zu keinem einheitlichen Ergebnis. Während er bei dem einfachen Modell das Ergebnis etwas verschlechtert, führt er bei den in Reihe geschalteten Netzen und den MTL-Netzen zu einer leichten Verbesserung. Dies

weist darauf hin, dass bei diesen komplexeren Modellen mehr Informationen zu einer besseren Trennbarkeit führen. Bei dem einfachen Modell wird jedoch durch die zusätzliche Eingabe das Optimum der Komplexität überschritten (s.a. Bias-Varianz Dilemma Kap. 2.1.3). Insofern sollten bei jedem Modell die Eingabemerkmale überprüft und individuell ausgewählt werden. Durch zusätzliche Merkmale wie bei den in Reihe geschalteten Netzen oder erweiterte Aufgaben bei den MTL-Netzen können einzelne Merkmale durchaus einen anderen Einfluss erhalten.

Die Untersuchungen haben gezeigt, dass durch Nachbarschaftsanalysen und gezielte Abfragen das Ergebnis der Analyse durch die Neuronalen Netze noch um 2-3 % verbessert werden kann. Allerdings muss dabei beachtet werden, dass das Ergebnis dadurch auch verfälscht werden kann. Die Nachbarschaftsanalyse führt vorwiegend zu einer Glättung des Ergebnisses. Dadurch können Detailinformationen verloren gehen.

Eine Überprüfung ob Massenbewegungstypen, die nur im Lockergestein möglich sind, für Festgesteinsareale angenommen wurden, ist generell sinnvoll. Allerdings bleibt dabei unberücksichtigt, dass die Neuronalen Netze möglicherweise auch Fähigkeiten entwickelt haben, bestimmte Massenbewegungen im Festgestein zu erkennen. Gerade flache Anbrüche in stark zerlegten Felsbereichen oder flache Massenbewegungen in geringmächtigem Lockergestein über Fels könnten so unerkant bleiben. Daher sollte hier genau abgewogen werden, wo die Vorteile der angewandten Methode liegen und die Ergebnisse auch entsprechend interpretiert werden.

Zusammenfassend kann gesagt werden, dass alle drei Modelle geeignet sind, Massenbewegungen im Lockergestein zu erkennen. Insofern können die Modelle als unterschiedliche Strategien verstanden werden, um die Aufgabe "Rutschungserkennung im Lockergestein" zu lösen. Allerdings hat jedes Modell besondere Stärken und Schwächen. Daher sollte je nach Untersuchungsziel und gewünschtem Ergebnis das entsprechende Modell gewählt werden. Bei den vorliegenden Untersuchungen hat das MTL-Netz mit dem geringsten Entwicklungsaufwand das insgesamt beste Ergebnis erzielt.

Ein direkter Vergleich mit Methoden aus dem Bereich des Maschinellen Lernens oder der Statistik ist ohne detaillierte Vergleichsuntersuch-

ungen unter gleichen Rahmenbedingungen nicht einfach. Dennoch kann festgestellt werden, dass mit dem vereinfachten Modell zur Berechnung des Standsicherheitsfaktors für den ebenen Fall über das Hanggleichgewicht (s. Kap. 4.1.3) nur 65 % der Zellen im Gebiet Stambach richtig erkannt werden können. Allerdings gibt es hier auch ausgereifere Modelle, die durch Verknüpfung mit einem probabilistischen Ansatz (ALÉN, 1998) deutlich besser Ergebnisse erwarten lassen. Bei ersten Untersuchungen mit logistischen oder linearen Regressionsmodellen sind im Trainingsgebiet Stambach stets schlechtere Ergebnisse erzielt worden. Bei dem Zusammenspiel von Geologie und Morphologie in Bezug auf Massenbewegungen sind die Zusammenhänge nicht so offensichtlich bzw. deutlich komplexer als sie gemeinhin erscheinen. Gerade dann ist es aber bei Regressionsmodellen schwierig, diese optimal einzustellen und zu validieren. Insofern dürften die neuronalen Modelle den Regressionsmodellen unter gleichen Bedingungen zumindest ebenbürtig, wenn nicht überlegen sein.

5.2 Ausblick

Es wurden mehrere Verfahren für die Entwicklung und die Optimierung Neuronaler Netze zur Rutschungserkennung vorgestellt und diskutiert. Diese Modelle können allerdings nur als Ansätze zu umfassenden und leistungsfähigen Modellen zur Rutschungserkennung gesehen werden. Ihre spezielle Fähigkeit Wildbachsysteme und grosse Rutschungskessel zu erkennen, sollte in weiteren Gebieten untersucht werden.

Zukünftige Verbesserungen und Weiterentwicklungen der Modelle sollten unter Einbeziehung weiterer mathematischer Verfahren auf eine weitgehende Systematisierung und Automatisierung des Verfahrens zielen.

In der Datenaufbereitung kann durch vorhergehende automatische Validierung und weitere Anreicherung der Daten sicherlich noch eine Verbesserung erzielt werden. So könnten Fernerkundungsverfahren verwendet werden um z.B. Vegetation, tektonische Struktur oder Hydrologie schärfer zu erfassen und in das geologische Modell einzubinden. Durch Interpolationsverfahren z.B. Krigging könnten nur lokal verfügbare Informationen in die Fläche extrapoliert werden (s. KIENZLE, 2002). Aber auch lokale Verfahren wie Entscheidungsbäume ("Tree Imputation") oder Assoziationsanalysen sollten untersucht werden, um ein möglichst dichtes homogenes geologisches Modell als Datenbasis zu erzeugen.

Neben der Verbesserung der Datenbasis kann durch einen gezielten Einsatz von Techniken aus dem Datamining bei der Merkmalsselektion, eine höhere Automatisierung und Systematisierung erreicht werden. Auch standardisierte Entscheidungsbaumverfahren vermitteln oft einen raschen Eindruck über wichtige trennende Merkmale. Interessant ist der bei den in Reihe geschalteten Netzen zu erkennende Ansatz der Codierung von Merkmalen mit Neuronalen Netzen.

Wie bereits angedeutet, ist der Komitee-Ansatz bei neuronalen Modellen ein vielversprechendes Verfahren, dessen Möglichkeiten auch hier unbedingt untersucht werden sollten (s.a. RAGG, 2000).

Die in der Einleitung erwähnten Support Vektor Machines (SCHÖLKOPF & SMOLA, 2001) sind ein weiteres Thema, das zur besseren Abgrenzung noch untersucht werden sollte.

Ein in dieser Arbeit wenig untersuchter Aspekt ist die weitergehende Auswertung der Ausgabe der Neuronalen Netze. Die Ausgabe wurde hier immer nur als Stufenfunktion interpretiert, bei der es nur stabil von instabil abzugrenzen gilt. Sie könnte aber z.B. auch in differenzierten Wahrscheinlichkeits- oder Gefährdungsklassen ausgegeben werden. Mit diesen Methoden kann gerade bei grossen Datenmengen oft ein wesentlich differenzierteres und besseres Ergebnis erzielt werden.

6 LITERATURVERZEICHNIS

- ALÉN, C. (1998): On Probability in Geotechnics - Random calculation models exemplified on slope stability analysis and ground-superstructure interaction.- Diss. Dep. Geotechnical Engineering Chalmers University of Technology, 242 S., 113 Abb., 35 Tab., 18 Anh.; Göteborg
- ALEOTTI, P. & CHOWDHURY, R. (1999): Landslide hazard assessment: summary review and new perspectives.- Bull. Eng. Geol. Env., **58**: 21 - 44; Berlin (Springer).
- BISHOP, C. M. (1995): Neural Networks for Pattern Recognition.- 482 S., 151 Abb., 5 Anh.; New York (Oxford).
- BRAUN, H. (1997): Neuronale Netze. Optimierung durch Lernen und Evolution.- 279 S., 64 Abb., 17 Tab.; Berlin (Springer).
- CARRARA, A., CARDINALI, M., GUZZETTI, F. & REICHENBACH, P. (1995): GIS Technology in Mapping Landslide Hazard.- In: CARRARA, A. & GUZZETTI, F. [Hrsg.], Geographical Information Systems in Assessing Natural Hazards, S. 135 - 175, 7 Abb., 16 Tab.; Dordrecht (Kluwer).
- CARUANA, R. (1993): Multitask connectionist learning.- Proceedings of the 1993 Connectionist Models Summer School: 372 -379, 4 Abb., Hillsdale (Erlbaum).
- CARUANA, R. (1994): Learning Many Related Tasks at the Same Time With Backpropagation.- In: TESAURO, G. TOURETZKY, D. S. & LEEN, T. K. [Hrsg.], Advances in Neural Information Processing Systems 7, S. 657 - 664, 1 Abb., 2 Tab., Cambridge (MIT Press).
- CHUNG, C.-J., FABBRI, A. G. & WESTEN, C. VAN (1995): Multivariate Regression Analysis for Landslide Hazard Zonation.- In: CARRARA, A. & GUZZETTI, F. [Hrsg.], Geographical Information Systems in Assessing Natural Hazards, S. 107 - 133, 8 Abb., 3 Tab., 1 Anh.; Dordrecht (Kluwer).
- CRUDEN, D. & FELL, R. [Hrsg.] (1987): Landslide Risk Assessment.- 371 S., 123 Abb., 38 Tab.; Rotterdam (Balkema).

-
- CRUDEN, D. & VARNES, D. J. (1996): Landslide types and processes.- In: TURNER, A. K. & SCHUSTER, R. L. [Hrsg.], Landslides - Investigation and Mitigation, Transp. Res. Board, Nat. Acad. Sci. Spec. Report **247**, S. 36 - 75; Washington D.C..
- CZURDA, K., FERNANDEZ-STEGER, T. M. & ROEHL, K. E. (2001): Geotechnik Sonderband zur 13. Nat. Tagung für Ingenieurgeologie Karlsruhe 2001.- 258 S.; Essen (VGE).
- DIKAU, R., BRUNSDEN, D., SCHROTT, L. & IBSEN, M-L. (1996): Landslide Recognition.- 251 S., 148 Abb., 29 Tab., 3 Anh.; Chichester (John Wiley & Sons).
- EINSTEIN, H. H. (1997): Landslide risk - Systematic approaches to assesment and management.- In: CRUDEN, D. & FELL, R. [Hrsg.], Landslide Risk Assessment, S. 25 - 50, 10 Abb.; Rotterdam (Balkema).
- EISBACHER, G. H. (1996): Einführung in die Tektonik.- 374 S., 329 Abb.; Stuttgart (Enke).
- FERNANDEZ-STEGER, T. M. & CZURDA, K. (2001): Erkennung von Rutschungen mit Neuronalen Netzen.- In: CZURDA et al. [Hrsg.], Geotechnik Sonderband zur 13. Nat. Tagung für Ingenieurgeologie Karlsruhe 2001, S. 61 - 66, 11 Abb. 1 Tab.; Essen (VGE).
- FERNANDEZ-STEGER, T. M., ROHN, J. & CZURDA, K. (2002): Identification of Landslide Areas with Neural Networks for Hazard Analysis.- In: RYBAR, J. et al. [Hrsg.], Landslides, S. 163 - 168, 6 Abb., 5 Tab.; Rotterdam (Balkema).
- FAUPL, P. & WAGREICH, M. (2000): Late Jurassic to Eocene Paleogeography and Geodynamic Evolution of the Eastern Alps.- Mittl. Österr. Geol. Ges., **92**: 79 - 94, 4 Abb., 1 Tab.; Wien.
- GAWLICK, H-J., FRISCH, W., VECSEI, A., STEIGER, T. & BÖHM, F. (1999): The change from rifting to thrusting in the Northern Calcareous Alps as recorded in Jurassic sediments.- Geologische Rundschau, **87** (4): 644 - 657, 10 Abb.; Berlin (Springer).
- GEMAN, S., BIENENSTOCK, E. & DOURSAT, R. (1992): Neural networks and the bias/variance dilemma.- Neural Computation, **4** (1): 1 - 58; Cambridge (MIT Press).

- GRAHAM, J. (1984): Methods of stability analysis.- In: BRUNSDEN, D. and PRIOR, D.B. [Hrsg.], Slope Instability, S. 171 - 215; New York (Wiley & Sons).
- GUTJAHR, S. (1999): Optimierung Neuronaler Netze mit der Bayes'schen Methode.- Diss. Fak. Informatik Univ. Karlsruhe, 158 S., 46 Abb., 30 Tab., 1 Anh.; Karlsruhe.
- HEINE, K. (1999): Beschreibung von Deformationsprozessen durch Voltera- und Fuzzy-Modelle sowie Neuronale Netze.- Deutsche Geodätische Kommission, Reihe C, **516**: 110 S., 37 Abb., 23 Tab.; München (Bay. Akad. Wiss.).
- HÖCHERL, A. (1991): Geologische und Ingenieurgeologische Untersuchungen im Einzugsgebiet des Michelbaches zwischen Bad Goisern und Altaussee (Oberösterreich / Steiermark).- Unveröff. Diplomarb., Lehrstuhl f. Geol. und Min. Univ. Erlangen - Nürnberg, 129 S.; Erlangen.
- HUSEN, D. VAN (1977): Zur Fazies und Stratigraphie jungpleistozäner Ablagerungen im Trauntal.- Jb. Geol. B.-A., **120**: 1 - 131; Wien.
- IDNDR (1997): Report on Early Warning Capabilities for Geological Hazards.- 37 S.; Genf (United Nations).
- IFRC (1999): World Disaster Report 1999.- 198 S., 18 Tab.; Genf (International Federation of Red Cross and Red Crescent Society).
- IFRC (2001): World Disaster Report 2001.- 244 S., 22 Tab.; Genf (International Federation of Red Cross and Red Crescent Society).
- KIENZLE, A. (2002): Seismische Mikrozonierung von Bukarest - eine GIS-gestützte statistische Analyse der Erdbebengefährdung.- Diss. Fak. Bio- u. Geowissenschaften Univ. Karlsruhe, 176 S., 105 Abb., 13 Tab., 2 Anh.; Karlsruhe
- KOBAYASHI, T., FURUTA, H., TATEKAWA, I., HIROKANE, M. & TANAKA, S. (1998): Data mining and analysis for landslide risk using neural networks.- In: ATTOH-OKINE, N. O. [Hrsg.], Artificial intelligence and mathematical methods in pavement and geo-mechanical systems, S. 93 - 97; 3 Abb., 4 Tab.; Rotterdam (Balkema).

-
- KOBER, L. (1927): Zur Geologie des Salzkammergutes. – Anz. Akad. Wiss. Wien, Mathem. Naturwiss. Kl. Abt.1: 1-2; Wien.
- LANG, H. D., RABIEN, A., STRUVE, W. & WIEGELE, E. (1976): Richtlinien für die Verfasser geowissenschaftlicher Veröffentlichungen.- 35 S.; Hannover (Schweizerbart).
- MANDL, G. W. (2000): The Alpine sector of the Tethyan shelf - Examples of Triassic to Jurassic sedimentation and deformation from the Northern Calcareous Alps.- Mittl. Österr. Geol. Ges., **92**: 61 - 77, 8Abb.; Wien.
- MEDWENITSCH, W. (1951a): Bericht über die Exkursion in die Hallstätterzone von Ischl-Aussee-Hallstatt und in das Becken von Gosau vom 11. – 15.4.50; Mitt. Ges. Geol. Bergbaustud. Österr., **2** (2): 22 – 29; Wien.
- MEDWENITSCH, W. (1951b): Bericht über die Exkursion in die Hallstätterzone von Ischl-Aussee-Hallstatt und in das Becken von Gosau vom 11. – 15.4.50; Mitt. Ges. Geol. Bergbaustud. Österr.,**2** (2): 39; Wien.
- MEDWENITSCH, W. (1957): Die Geologie der Salzlagerstätten Bad Ischl und Alt-Aussee (Salzkammergut). Mitt. Geol. Ges., **50**: 133 – 199, 4 Taf.; Wien.
- MORGENSTERN, N. R. (1997): Towards landslide risk assessment in practice.- In: CRUDEN, D. & FELL, R. [Hrsg.], Landslide Risk Assessment, S. 15 - 23, 3 Abb.; Rotterdam (Balkema).
- OPENSHAW, S. & OPENSHAW, C. (1997): Artificial Intelligence in Geography.- 329 S., 44 Abb., 44 Tab., 6 Anh.; Chichester (John Wiley & Sons)
- PATTERSON, D. (1997): Künstliche Neuronale Netze- Das Lehrbuch.- 2 Aufl; 506 S., 192 Abb., 7 Tab.; München (Prentice Hall)
- PLÖCHINGER, B. (1983): Erläuterungen zu Blatt 95 St. Wolfgang im Salzkammergut.- 74 S.; Wien (Geol. B. A.).
- PLÖCHINGER, B. (1983): Salzburger Kalkalpen.- Sammlung Geologischer Führer, **73**; 144 S., 34 Abb.; Berlin (Geb. Bornträger).
- POISEL, R. & EPPENSTEINER, W. (1989): Gang und Gehwerk einer Massenbewegung Teil 2: Massenbewegungen am Rand des Systems " Hart auf Weich".- Felsbau **7** (1): 16 – 20, 11 Abb.; Essen (VGE)

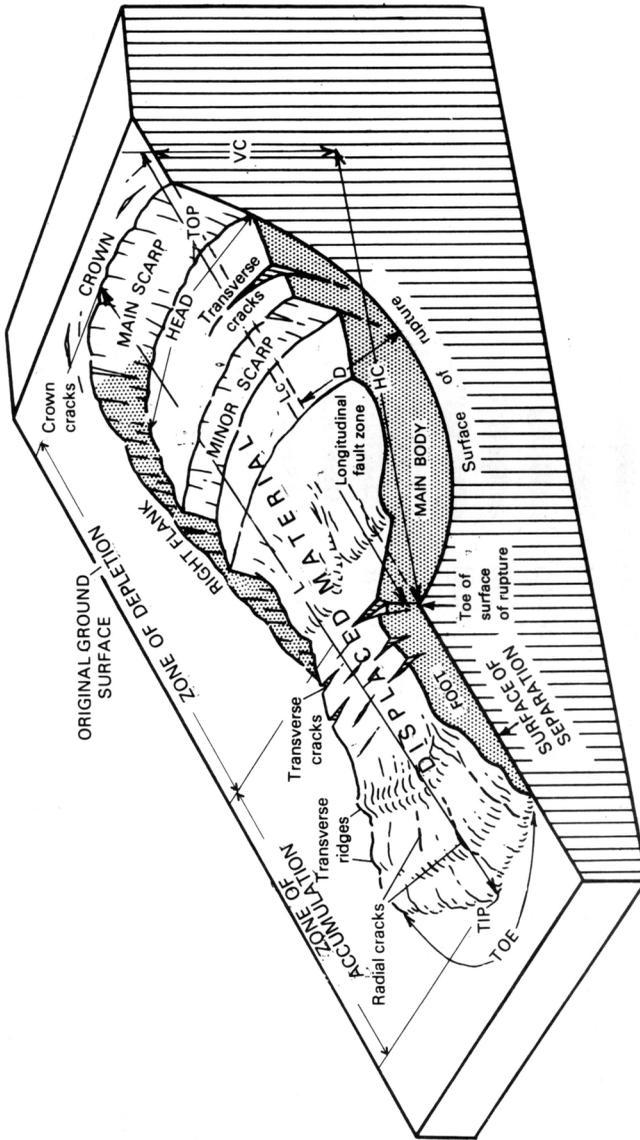
- POPESCU, M. E. (1994): A Suggested Method for Reporting Landslide Causes.- Bulletin of the IAEG, **50**: 71 - 74, 2 Abb., 2 Tab.; Paris.
- RAGG, T. (2000): Problemlösung durch Komitees neuronaler Netze.- Diss. Fak. Informatik Univ. Karlsruhe, 192 S., 94 Abb., 11 Tab., 2 Anh.; Karlsruhe.
- RESCH, M. (1997): Geologische und Ingenieurgeologische Untersuchungen der Talzuschub-Systeme am Hohen Raschberg bei Bad Goisern (Oberösterreich).- Unveröff. Diplomarb., Lehrstuhl f. Angew. Geol. Univ. Karlsruhe, 124 S., 49 Abb., 2 Tab., 2 Kt., 5 Taf., 4 Anl.; Karlsruhe.
- RHÖNAU, C. (2001): Zusammenstellung der geologischen und geotechnischen Karte der Hallstätterzone von Bad Ischl – Altaussee mit ARC / Info (GIS).- Unveröff. Diplomarb. Lehrstuhl f. Angew. Geol. Univ. Karlsruhe, 104 S., 79 Abb., 10 Tab., 3 Kt.; Karlsruhe.
- RIEDMILLER, M & BRAUN, H (1992): Rprop: A fast adaptive learning algorithm.- In: GLENBE, E. [Hrsg.], International Symposium on Computer and Information Science VII, S. 279 - 286; Antalya.
- RIEDMILLER, M. (1993): Untersuchungen zur Konvergenz und Generalisierungsfähigkeit von überwachten Lernverfahren mit dem SNNS.- In: ZELL, A. [Hrsg.], Workshop SNNS 93, Univ. Stuttgart, Fak. Informatik, S. 107 - 116, 12 Abb.; Stuttgart
- RIEDMILLER, M. (1994): Advanced supervised learning in multi-layer perceptrons - from backpropagation to adaptive learning algorithms.- Int. Journal of Computer Standards and Interfaces, **16**: 265 - 278, 7 Abb., 5 Tab.; Oxford (Pergamon)
- ROHN, J. (1991): Geotechnische Untersuchungen an einer Großhangbewegung in Bad Goisern (Oberösterreich).- Schr. Angew. Geol. Karlsruhe, **14**: 193 S, 88 Abb., 8 Tab., 1 Anl.; Karlsruhe.
- ROHN, J., CZURDA, K., ZVELEBIL, J. & ZIKA, P.(1996): A steep wall with toppling rockpillars on a clayey subsoil.- In: CHACON, J. et al. [Hrsg.], Landslides, S. 181 - 188, 4 Abb.; Rotterdam (Balkema).

-
- ROHN, J., RESCH, M., SCHNEIDER, H., FERNANDEZ-STEEGER, T. M. & CZURDA, K. (2002): Large scale lateral spreading and related mass movements in the Northern Calcareous Alps.- IAEG Bulletin, 7 S., 5 Abb.; Paris. [angenommen]
- ROHN, J. & FERNANDEZ-STEEGER, T. M. (2000): Massenbewegungen nach Starkniederschlägen.- *Rheticus*, **22** (2): 151 - 157, 4 Abb.; Feldkirch.
- SCHÄFFER, G. (1976): Einführung zur Geologischen Karte der Republik Österreich, Blatt 96 Bad Ischl.- In: GATTINGER, T. et al. [Hrsg.], Arb. Tag. Geol. B.-A.; Wien.
- SCHIFFMANN, W., JOOST, W. & WERNER, R. (1993): Optimization of the backpropagation algorithm for training multilayer perceptrons.- Technical Report, Univ. of Koblenz, Inst. of Physics, 36 S., 18 Abb., 1 Tab.; Koblenz.
- SCHÖLKOPF, B. & SMOLA, A. J. (2001): Learning with Kernels.- 644 S., 138 Abb.; Cambridge (MIT Press).
- SCHOGER, H. (1988): Analyse von Hangbewegungen anlässlich von Starkniederschlägen am Beispiel des Voldertals / Tirol.- Diss. Univ. Erlangen-Nürnberg, 236 S.; Erlangen
- SCHUSTER, R. L. (1996): Socioeconomic Significance of Landslides.- In: TURNER, A. K. & SCHUSTER, R. L. [Hrsg.], Landslides - Investigation and Mitigation.- Transp. Res. Board, Nat. Acad. Sci. Spec. Report **247**, S. 12 - 35; Washington D.C..
- SPENGLER, E. (1956): Versuch einer Rekonstruktion des Ablagerungsraumes der Decken der Nördlichen Kalkalpen – Teil II: Der Mittelabschnitt der Kalkalpen.- *Jb. Geol. B.-A.*, **99** (1): 1 – 74, 5 Abb., 1 Taf.; Wien.
- STEPHENSON, D. B. (2000): Use of the “Odds Ratio” for Diagnosing Forecast Skill.- *Weather and Forecasting*, **15** (2): 221 – 232; Boston (AMS).
- TOLLMANN, A. (1960): Die Hallstätterzone des östlichen Salzkammergutes und ihr Rahmen.- *Jb. Geol. B.-A.*, **103**: 37 - 131; Wien.
- TOLLMANN, A. (1981): Oberjurassische Gleittektonik als Hauptdeformationsprozeß der Hallstätter Region und neue Daten zur Gesamttektonik der Nördlichen Kalkalpen in den Ostalpen.- *Mittl. Österr. Geol. Ges.*, **74/75**: 167 - 195; Wien.

- VARNES, D.J. (1978): Slope movement types and processes.- In: SCHUSTER, R. L. & KRIZEK, R. J. [Hrsg.], Landslides - Analysis and Control.- Transp. Res. Board, Nat. Acad. Sci. Spec. Report **176**, S. 11 - 33; Washington D.C..
- XIANG, W. (1997): Der Einfluß der Kationenbelegung auf die bodenmechanischen Eigenschaften von Tonen am Beispiel einer ostalpinen Großhangbewegung.- Schr. Angew. Geol. Karlsruhe, **48**: 190 S., 96 Abb., 27 Tab.; Karlsruhe.
- ZELL, A. (1997): Simulation neuronaler Netze.- 2 unv. Aufl.; 624 S., 229 Abb., 36 Tab.; München (Oldenburg)



ANHANG A



Blockbild einer komplexen zusammengesetzten Massenbewegung, die sich aus einer Rotationsrutschung und einem Schuttstrom zusammensetzt. (VARNES, 1978)

Englische Original Tabelle von Massenbewegungs Typen aus DIKAU et al. (1999).

Type	Rock	Debris	Soil
Fall	rockfall	debris fall	soil fall
Topple	rock topple	debris topple	soil topple
Slide (rotational)	single (slump) multiple successive	single multiple successive	single multiple successive
Slide (translational) Non-rotational	block slide	block slide	slab slide
Planar	rockslide	debris slide	mudslide
Lateral spreading	rock spreading	debris spread	soil (debris) spreading
Flow	rock flow (Sackung)	debris flow	soil flow
Complex (with run-out or change of behaviour downslope, note that nearly all forms develop complex behaviour)	e.g. rock avalanche	e.g. flow slide	e.g. slump-earthflow

Note: A *compound* landslide is one that consists of more than one type, e.g. a rotational–translational slide. This should be distinguished from a complex slide where one form of failure develops into a second form of movement, i.e. a change of behaviour downslope by the same material.