



MASTERARBEIT | MASTER'S THESIS

Titel | Title

Entwicklung eines freien und quelloffenen Python-Skripts zur
Berechnung eines Naturgefahrenindex für beliebige
Untersuchungsgebiete auf Basis von Fernerkundungsdaten der
Google Earth Engine

verfasst von | submitted by
Germaine Pötgen

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

Wien | Vienna, 2024

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

UA 066 856

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

Masterstudium Kartographie und Geoinformation

Betreut von | Supervisor:

Ass.-Prof. Mag. Dr. Andreas Riedl

Inhaltsverzeichnis

Abbildungen	V
Tabellen	VI
Formeln	VI
Codeblöcke	VII
Abkürzungen	VIII
Kurzfassung	IX
Abstract	IX
1 Einleitung	1
1.1 Problemstellung und Motivation	1
1.2 Forschungsziel	2
1.3 Methodische Vorgehensweise	3
2 Theoretische Grundlagen und Forschungsstand	5
2.1 Begriffe und Konzepte bezüglich Naturgefahren	5
2.2 Aktuelle Auswirkungen von Naturgefahren	11
2.3 Abgrenzung von Gefahren-, Expositions-, Vulnerabilitäts- und Risikoanalysen	13
2.4 Methodologische Ansätze im Bereich der (Multi-)Risikoanalysen	15
2.4.1 Qualitative Methoden	16
2.4.2. Semi-quantitative Methoden	18
2.4.3 Quantitative Methoden	19
2.4.4 Multi-Risikoanalysen unter Berücksichtigung von Wechselwirkungen	21
2.4.5 Stärken und Schwächen bestehender Methoden	24
2.5 Forschungsstand zu Gefahren-, Expositions- und Risikoanalysen	28
3 Multi-Risk-Tools	32
3.1 Verfügbare Open Source Tools zur Gefahren- und (Multi-)Risikoanalyse	32
3.2 Vorteile und Limitationen bisheriger Tools	38
4 Entwicklung des Gefahrenindex-Skripts	42
4.1 Technische Rahmenbedingungen und Entwicklungswerkzeuge	42
4.1.1 Die Google-Earth-Engine API	42
4.1.2 Auswahl der Programmiersprache und Entwicklungsumgebung	44
4.2 Beschreibung des Gefahrenindex	45
4.3 Variablen des Gefahrenindex	47
4.3.1. Durchschnittlicher PDSI	50
4.3.2 Niederschlag: Veränderung der jährlichen Akkumulation	51
4.3.3 Niederschlag: Interannueller Variationskoeffizient	53
4.3.4 Niederschlag: Maximale monatliche Anomalie im März/April/Mai (P_{Max})	54
4.3.5 Temperatur: Jährliche maximale Oberflächentemperatur (TXx)	55
4.3.6 Temperatur: Langfristige Anomalie (ΔT)	56

4.3.7 Spezifische Luftfeuchtigkeit (Q).....	58
4.3.8 Abflussakkumulation	59
4.3.9 Friktion	61
4.3.10 Hangneigung.....	62
4.3.11 Bodenfeuchte (Oberfläche).....	63
5 Aufbau und Anwendung des Gefahrenindex-Skripts	65
5.1 Aufbau des Skripts und exemplarische Vorstellung von Codeausschnitten	65
5.2 Beispielhafte Anwendung und Ergebnisse	74
6 Herausforderungen und Error-Handling	79
6.1 Skalierungs-Fehlermeldungen	79
6.2 Fehler bezüglich Datensätzen	81
6.3 Weitere Fehlermeldungen.....	82
7 Anleitung zur Nutzung des Gefahrenindex-Skripts	83
8 Schlussbetrachtung.....	85
8.1 Diskussion	85
8.2 Limitationen	87
8.3 Fazit mit Ausblick für zukünftige Forschung	89
8.4 Datenverfügbarkeit	91
Literaturverzeichnis	92
Anhang	101
Anhang A: Skripte zu Berechnung des Gefahrenindex	101
Anhang A.1 natural_hazard_index.ipynb.....	101
Anhang A.2: __init__.py	105
Anhang A.3: pdsi_average.py	105
Anhang A.4: precipitation_ann_change.py	108
Anhang A.5: precipitation_coefficient_variation.py	111
Anhang A.6: precipitation_anomaly.py	113
Anhang A.7: surface_temperature_max.py	117
Anhang A.8: temperature_anomaly.py	120
Anhang A.9: specific_humidity.py	122
Anhang A.10: flow_accumulation.py.....	125
Anhang A.11: friction.py	127
Anhang A.12: slope.py	129
Anhang A.13: surface_soil_moisture.py	131

Abbildungen

Abb. 1: Einflussgrößen von Risiko.....	8
Abb. 2: Multidimensionalität der Vulnerabilität.	9
Abb. 3: Auswirkungen von Katastrophen 1980-1999 vs. 2000-2019 mit logarithmischer Skalierung.	12
Abb. 4: Anzahl der Katastrophenereignisse nach Typ: 1980-1999 vs. 2000-2019.	13
Abb. 5: Von der Einzelrisiko- zur Multi-Risikoanalyse.	16
Abb. 6: Schweizer Intensitäts-Wahrscheinlichkeits-Matrix.	17
Abb. 7: Risikokurven für die Stadt Köln (Referenzjahr: 2000).	20
Abb. 8: Interaktionsmatrix zur Identifizierung der Wechselwirkungen zwischen Gefahren.	22
Abb. 9: Schematische Darstellung eines Event Trees.	23
Abb. 10: Schematische Darstellung der Modell-Pipeline von RiskScape.	33
Abb. 11: Schematische Darstellung der Methodik des Hazus Flood Models.	35
Abb. 12: Interaktive WebMap des National Risk Index der USA.	36
Abb. 13: Kernmodule von CAPRA.	37
Abb. 14: Die grafische Benutzeroberfläche von CAPRA-GIS.	38
Abb. 15: Schematische Darstellung der verschiedenen Analyselevel von Hazus.	41
Abb. 16: Vereinfachte Darstellung der Google Earth Engine Systemarchitektur.	43
Abb. 17: Schematische Darstellung der Berechnung des Gefahrenindex.	47
Abb. 18: Durchschnittlicher PDSI 2000-2020. Niedrigere Werte zeigen dabei Trockenheit, höhere Feuchtigkeit an.	51
Abb. 19: Veränderung der jährlichen Niederschlagsakkumulation in mm.	53
Abb. 20: Interannueller Variationskoeffizient des Niederschlags.	54
Abb. 21: Maximale monatliche Niederschlagsanomalie im März/April/Mai (P_{Max}) in mm.	55
Abb. 22: Jährliche maximale Oberflächentemperatur (TXx) in Kelvin.	56
Abb. 23: Langfristige Temperaturanomalie (ΔT) in Kelvin.	57
Abb. 24: Spezifische Luftfeuchtigkeit (Q) als Massenanteil.	59
Abb. 25: Schematische Darstellung der Bestimmung der Abflussakkumulation.	60
Abb. 26: Abflussakkumulation (Anzahl Pixel).	60
Abb. 27: Hangneigung in Grad.	63
Abb. 28: Bodenfeuchte an der Oberfläche in mm.	64
Abb. 29: Aufbau des Gefahrenindex-Skripts (N = Niederschlag, T = Temperatur).	66
Abb. 30: Gefahrenindexwerte in Grenzregionen.	74
Abb. 31: Gefahrenindexwerte als Sextile bei der Anwendung des erstellten Gefahrenindex-Skripts auf das Untersuchungsgebiet von Owen et al. (2023).	76

Abb. 32: Die Gefahrenindexwerte für Österreich als Fishnet mit horizontalen und vertikalen Intervallen von 0,1 Grad. Die Variable Friktion ist nicht integriert, da beim dahinterliegenden Datensatz zum Zeitpunkt der Erstellung der Grafik ein Fehler vorlag.	77
Abb. 33: Die Gefahrenindexwerte als Sextile für Österreich als Fishnet mit horizontalen und vertikalen Intervallen von 0,1 Grad. Die Variable Friktion ist nicht integriert, da beim dahinterliegenden Datensatz zum Zeitpunkt der Erstellung der Grafik ein Fehler vorlag.	77
Abb. 34: Beispieldarstellung eines Fishnets über Österreich mit $h_interval = 0.3$ und $v_interval = 0.3$	81
Abb. 35: Visualisierung eines Untersuchungsgebiets des Gefahrenindex.	83

Tabellen

Tabelle 1: Klassifikation von Naturgefahren.....	6
Tabelle 2: Beispiel zur qualitativen und quantitativen Definition der Eintrittswahrscheinlichkeit eines Ereignisses.	19
Tabelle 3: Beispiel für die qualitative und quantitative Definition der Schwere des Ereignisses als Verhältnis der Verluste zum nationalen BIP.	19
Tabelle 4: Vor- und Nachteile verschiedener Methoden zur Gefahren- und Risikobewertung.	25
Tabelle 5: Vor- und Nachteile Multi-Layer- vs. Multi-Risikoanalyse.	27
Tabelle 6: Übersicht über die Gefahren-Variablen und dazugehörige Informationen.....	49
Tabelle 7: $h_interval$ und $v_interval$ -Werte für ausgewählte Normalisierungsgrundlagen.	84

Formeln

Formel 1: R (Risiko) als Funktion (f_C) der Folgen des Gefahrenereignisses (H), das sich auf exponierte Elemente auswirkt (E). Folgen ergeben sich aus der Vulnerabilität (V) gegenüber des Gefahrenereignisses (i).	32
Formel 2: Vereinfachte Gleichung zur Berechnung des Risikos des National Risk Index.	35
Formel 3: Normalisierung der Gefahren-Variablen.	46
Formel 4: Umgekehrte Normalisierung der Gefahren-Variablen.	46
Formel 5: Berechnung des Gefahrenindex.	46

Formel 6: Berechnung der Variable Niederschlag: Veränderung der jährlichen Akkumulation.....	52
Formel 7: Berechnung des interannuellen Variationskoeffizienten des Niederschlags. σ steht dabei für die Standardabweichung der jährlichen Niederschlagssumme, $\bar{x}$ für den Mittelwert des jährlichen Niederschlags.....	53
Formel 8: Berechnung der Temperaturanomalie.....	57

Codeblöcke

Codeblock 1: Definieren des Untersuchungsgebiets als neue GEE-Geometrie.....	67
Codeblock 2: Definieren des Untersuchungsgebiets mittels Hochladen einer GeoJSON-Datei.	67
Codeblock 3: Definieren des Untersuchungsgebiets mittels Hochladen einer Shapefile-Datei.	67
Codeblock 4: Definieren der Normalisierungsgrundlage und Erstellen des Fishnets.	68
Codeblock 5: Berechnung der minimalen und maximalen Variablenwerte innerhalb der Normalisierungsreferenz. Beispielfhaft dargestellt für drei der elf Variablen.	69
Codeblock 6: Berechnung der normalisierten Variablenwerte für jedes Untersuchungsgebiet. Beispielfhaft dargestellt für drei der elf Variablen.....	69
Codeblock 7: Berechnung der Gefahrenindexwerte und Erstellen einer Ergebnisdatei im csv-Format.	70
Codeblock 8: Funktion zum Laden und Aufbereiten der Datensätze. Hier beispielfhaft für den Datensatz TerraClimate zur Berechnung des mittleren PDSI.....	71
Codeblock 9: Funktion zur Berechnung der minimalen und maximalen Variablenwerte innerhalb der übergebenen Normalisierungsreferenz. Hier beispielfhaft für die Variable des mittleren PDSI.	72
Codeblock 10: Funktion zur Berechnung des mittleren Variablenwerts innerhalb des übergebenen Untersuchungsgebiets. Hier beispielfhaft für die Variable des mittleren PDSI.	73
Codeblock 11: Anwendung der Funktionen zur Berechnung der Variablenwerte auf alle Fishnet-Zellen. Hier beispielfhaft für die Variable des mittleren PDSI.	75

Abkürzungen

C3S	Copernicus Climate Change Service
CAPRA	Comprehensive Approach to Probabilistic Risk Assessment
CRED	Centre for Research on the Epidemiology of Disasters
DHM	Digitales Höhenmodell
ECMWF	Europäische Zentrum für mittelfristige Wettervorhersage
EM-DAT	Emergency Events Database
GEE	Google Earth Engine
GIS	Geographisches Informationssystem
LSM	Land Surface Model
NCEP	National Centers for Environmental Prediction
PDSI	Palmer Drought Severity Index
SD	Standardabweichung (standard deviation)
SMAP	Soil Moisture Active Passive
UNDRR	United Nations Office for Disaster Risk Reduction
USGS	United States Geological Survey
WHO	World Health Organization
WMO	World Meteorological Organization

Kurzfassung

Naturgefahrenanalysen sind eine wesentliche Komponente zur Unterstützung der Entscheidungsfindung in der Katastrophenvorsorge. Angesichts der zunehmenden Herausforderungen durch den Klimawandel und dem damit verbundenen vermehrten Auftreten multipler Gefahren, ist es von entscheidender Bedeutung, freie und standardisierte Software für die Naturgefahrenanalyse zur Verfügung zu stellen, um einer möglichst breiten Nutzer*innenbasis die Möglichkeit zur Bewertung dieser Gefahren zu geben. Dementsprechend wird im Zuge dieser Arbeit, aufbauend auf einer ausführlichen Literaturrecherche, ein Python-Skript zur Ermittlung des Gefahrenindex für jeden beliebigen Ort nach Owen et al. (2023) erstellt und frei zur Verfügung gestellt. Dieses Skript beruht auf Fernerkundungsdaten des Google Earth Engine Katalogs mit globaler Datenkonsistenz und zeichnet sich durch eine zuverlässige, schnelle und unkomplizierte Anwendung aus. Eine beispielhafte Nutzung des erstellten Skripts im Rahmen dieser Arbeit und die Analyse der daraus gewonnenen Ergebnisse, unterstreichen dabei die Anwendbarkeit des Skripts und bestätigen die Plausibilität der gewählten Methode.

Abstract

Natural hazard analyses are a key component in supporting decision-making regarding disaster risk reduction. Given the increasing challenges posed by climate change and the associated increased occurrence of multiple hazards, it is crucial to provide free and standardized software for natural hazard analysis in order to give the broadest possible user base the opportunity to assess these hazards. Accordingly, in the course of this work, based on a detailed literature search, a Python script for determining the hazard index for any location according to Owen et al. (2023) is created and made available for free use. This script is based on remote sensing data from the Google Earth Engine catalog with global data consistency and is characterized by reliable, fast and uncomplicated application. An exemplary use of the created script in the context of this work and the analysis of the results obtained from it, underline the applicability of the script and confirm the plausibility of the chosen method.

1 Einleitung

1.1 Problemstellung und Motivation

Zahlreiche Regionen weltweit sind dem Risiko einer Vielzahl an Naturgefahren ausgesetzt, die zu erheblichen Schäden und Verlusten führen können. Alleine im Jahr 2023 gab es weltweit rund 95.000 dokumentierte Todesfälle durch Naturkatastrophen – der höchste Wert seit 2010 (Statista 2024, o.S.). Laut eines Berichts der Weltbank bezüglich Hotspots von Naturkatastrophen, sind 3,8 Millionen km² und 790 Millionen Menschen mindestens zwei Naturgefahren relativ stark ausgesetzt. Etwa 0,5 Millionen km² und 105 Millionen Menschen sind sogar drei oder mehr Naturgefahren relativ stark ausgesetzt (Dilley et al. 2005, S. 2). Sogenannte *multi-hazards* können potenziell zu schwerwiegenderen Katastrophen, mit einer höheren Anzahl an Todesfällen sowie verletzten und vertriebenen Personen, führen, als einzeln auftretende Naturgefahren. Darüber hinaus können bereits bestehende Vulnerabilität und Ungleichheiten wie Armut, mangelnder Zugang zu Ressourcen oder unzureichende Infrastruktur verschärft werden. Multi-hazards sollten folglich bei der Bewertung und dem Management von Katastrophenrisiken gemeinsam berücksichtigt werden (Ming et al. 2022, S. 1; Zhang et al. 2023, S. 1).

Das Ausgesetztsein der globalen Bevölkerung als auch der bebauten Fläche gegenüber Naturgefahren hat sich zwischen 1975 und 2015 verdoppelt (Pesaresi et al. 2017, S. 66). Mit dem Fortschreiten des Klimawandels wird sich die Gefährdung durch multiple Risiken auch weiterhin erhöhen, darunter beispielsweise ein vermehrtes gemeinsames Auftreten von Hitze- und Dürreereignissen (Pörtner et al. 2023, S. 18). Wichtig ist es demnach zunächst einmal Kenntnisse darüber zu gewinnen, welche Bereiche überhaupt welchen Naturgefahren in physischer Form ausgesetzt sind. Darüber hinaus sind (Multi-)Risikoanalysen in diesem Zusammenhang von immer größer werdender Bedeutung, um festzustellen, welche Regionen ein besonders hohes Risiko gegenüber Naturgefahren haben, und so die Entscheidungsfindung bezüglich des Risikomanagements zu unterstützen und eine Grundlage dafür zu schaffen, eine verbesserte Vorbereitung sowie Reaktion auf Naturgefahren zu ermöglichen (Zhang et al. 2023, S. 1).

In den letzten Jahren wurden bezüglich Gefahren- und Risikoanalysen einige Ansätze auf globaler Ebene entworfen, zusammengefasst in Kapitel 2.5. Die meisten dieser bisher entwickelten Ansätze weisen allerdings Einschränkungen hinsichtlich der Konsistenz der Datenqualität in einem bestimmten Untersuchungsgebiet auf (Owen et al. 2023, S. 1). Aus diesem Grund haben Owen et al. (2023) einen Index für Klima- und Umweltexposition entwickelt, der auf elf Variablen bezüglich Klima, Wetter und geophysikalischen Bedingungen mit globaler Datenkonsistenz basiert. So ist es möglich, den Index auf eine

Vielzahl von geografischen Kontexten auszuweiten und Klima- und Umweltdaten auch in geografisch abgelegenen Gebieten zuverlässig, kostengünstig und standardisiert zu erfassen (Owen et al. 2023, S. 1). Mithilfe der Indexberechnung lässt sich so die Höhe der Eintrittswahrscheinlichkeit von Naturgefahren ermitteln, als auch der Unterschied im Gefährdungsgrad im Vergleich zu umliegenden Gebieten nachvollziehen. Des Weiteren lässt sich die Veränderung der Gefahr im Laufe der Zeit analysieren (Owen et al. 2023, S. 5).

Der Ansatz von Owen et al. (2023) könnte einen wichtigen Beitrag im Kampf gegen Naturgefahren bieten und eine Möglichkeit schaffen, schnell und einfach eine erste Einschätzung über das Gefahrenpotential innerhalb eines Gebiets zu erlangen. Das zugrunde liegende Skript ist allerdings nicht frei verfügbar, weswegen dieses repliziert und frei zur Verfügung gestellt werden soll. Dies kann beispielsweise die Planung, Standortwahl und Entscheidungsfindung bezüglich neuem Wohnraum und Infrastruktur unterstützen, aber auch zu einer Verringerung des Katastrophenrisikos beitragen und zu vorausschauenden Maßnahmen in Gefahrenbereichen mit bereits bestehender Infrastruktur anregen (Owen et al. 2023, S. 2).

Die Motivation der Arbeit liegt dementsprechend darin, durch die Reproduktion des Gefahrenindex und die anschließende freie Verfügbarkeit des Tools, eine Anwendung für alle zu ermöglichen. Es soll so auch ein Beitrag zur Open Source Community geleistet werden, da Open Source Anwendungen zahlreiche Vorteile mit sich bringen. Open Source ermöglicht einen transparenten und offenen Entwicklungsprozess und fördert den Wissensaustausch sowie Innovation. Die Freiheit der Nutzer*innen wird zudem respektiert, da diese die Freiheit haben, die Software auszuführen, zu verbreiten, zu untersuchen und zu verändern (Free Software Foundation o.J., o.S.).

1.2 Forschungsziel

Die Bedeutsamkeit einer zuverlässigen und konsistenten Gefahrenanalyse im Kontext von Naturgefahren wird durch die steigende Häufigkeit und Intensität dieser Ereignisse weltweit deutlich. Angesichts der zunehmenden Herausforderungen durch den Klimawandel und dem damit verbundenen erhöhten Auftreten multipler Gefahren, ist es von entscheidender Bedeutung, freie Software zu Verfügung zu stellen, die einen Beitrag zur Bewertung und Bewältigung dieser Gefahren leisten. Vor diesem Hintergrund wird folgende zentrale Forschungsfrage aufgestellt:

Wie kann ein Open-Source-Skript zur Berechnung des Gefahrenindex entwickelt werden, das auf dem Ansatz von Owen et al. (2023) beruht?

Weitere Arbeitsfragen sind:

- I. Welche methodologischen Ansätze gibt es im Bereich der Gefahren- und (Multi-) Risikoanalysen?
- II. Was ist der aktuelle Forschungsstand zu Gefahren- und (Multi-) Risikoanalysen (mit globaler Ausdehnung)?
- III. Welche (frei verfügbaren) Multi-Risiko-Tools gibt es bereits und was sind deren Stärken und Limitationen?
- IV. Welche frei verfügbaren Datensätze sind am besten für die Realisierung des Gefahrenindex-Skripts geeignet?

Ziel dieser Arbeit ist, die Arbeitsfragen mithilfe einer ausgiebigen Literaturrecherche zu beantworten sowie das vorgestellte Modell zu replizieren und frei zur Verfügung zu stellen, sodass alle interessierten Personen den Gefahrenindex für beliebige Untersuchungsgebiete weltweit berechnen können. Dies kann unter anderem für NGOs von Vorteil sein, da diese oft mit knappen Budgets arbeiten. Da der Code frei zugänglich sein soll, kann dieser auch kopiert oder verändert und so den eigenen Bedürfnissen angepasst werden.

1.3 Methodische Vorgehensweise

Die Arbeit ist in verschiedene Teile untergliedert, um die vorliegende Forschungsfrage und die damit zusammenhängenden Arbeitsfragen zu beantworten. Zu dieser Gliederung und Vorgehensweise der Arbeit soll in diesem Unterkapitel ein kurzer Überblick gegeben werden.

Der erste Teil der Arbeit widmet sich einer ausgiebigen Literaturrecherche zu den theoretischen Grundlagen und dem Forschungsstand bezüglich Gefahren- und Risikoanalysen (Kapitel 2). Dabei wird zunächst grundlegend auf die Begriffe und Konzepte bezüglich Naturgefahren und die aktuellen Auswirkungen von Naturgefahren eingegangen, bevor Gefahren-, Expositions-, Vulnerabilitäts- und (Multi-) Risikoanalysen voneinander abgegrenzt werden. Anschließend wird auf die methodologischen Ansätze im Bereich der (Multi-) Risikoanalysen eingegangen, die sich in weiten Teilen auch auf die anderen Arten

der Analysen übertragen lassen (Gefahren-, Expositions-, Vulnerabilitätsanalyse). Das Kapitel schließt mit einer Zusammenfassung zum aktuellen Forschungsstand in dem Bereich. Auf Grundlage dieses Teils der Arbeit ist es möglich, die Arbeitsfragen I und II zu beantworten. Weiters werden bereits verfügbare Open-Source-Tools zur Gefahren- und (Multi-)Risikoanalyse vorgestellt und auf deren Stärken und Limitationen eingegangen (Kapitel 3), um auf dieser Grundlage auch die möglichen Stärken und Limitationen des zu entwickelnden Gefahrenindex-Skripts besser einschätzen zu können. Dabei wird die Arbeitsfrage III beantwortet, als auch bereits im gewissen Maße zur Beantwortung der zentralen Forschungsfrage beigetragen.

Der nächste Teil der Arbeit befasst sich mit dem methodischen Vorgehen zur Entwicklung des Gefahrenindex-Skripts (Kapitel 4). Hierbei wird im Wesentlichen auf die Beantwortung der zentralen Forschungsfrage eingegangen. Dabei werden zunächst die technischen Rahmenbedingungen erläutert und die Entwicklungswerkzeuge ausgewählt. Daraufhin wird beschrieben, wie der Gefahrenindex berechnet wird, sowie die verschiedenen Variablen mit den dahinter stehenden Datensätze vorgestellt, die in den Index einfließen.

Auch das darauffolgende Kapitel dient der Beantwortung der zentralen Forschungsfrage. In diesem wird der Programmaufbau des Skripts erklärt und Skriptauschnitte werden beispielhaft vorgestellt und erläutert. Außerdem wird das Skript mit verschiedenen Anwendungsfällen beispielhaft verwendet, um aufzuzeigen, wie es in unterschiedlichen Szenarien effektiv eingesetzt werden kann und dabei verlässliche Ergebnisse liefert (Kapitel 5).

In einem weiteren Teil der Arbeit werden die Herausforderungen, die bei der Entwicklung des Skripts auftraten, vorgestellt, sowie mögliche Lösungsansätze erläutert und es wird gezeigt, welche Lösungsansätze dabei letztlich im Rahmen der Arbeit angewendet wurden (Kapitel 6). Weiters wird die optimale Vorgehensweise bei der Nutzung des Skripts beschrieben (Kapitel 7).

Die Arbeit endet mit einer Schlussbetrachtung, bei der die zentralen Ergebnisse der Arbeit diskutiert, die Limitationen der Arbeit aufgezeigt werden sowie ein Fazit inklusive Ausblick für zukünftige Forschung gezogen wird (Kapitel 8).

2 Theoretische Grundlagen und Forschungsstand

In diesem Kapitel werden die theoretischen Grundlagen und der aktuelle Forschungsstand im Bereich der Naturgefahren- und Risikoanalyse dargelegt. Zunächst werden dabei zentrale Begriffe und Konzepte definiert, gefolgt von einer Übersicht über die aktuellen Auswirkungen von Naturgefahren. Im weiteren Verlauf werden Gefahren-, Expositions-, Vulnerabilitäts- und (Multi-)Risikoanalysen voneinander abgegrenzt. Schließlich werden verschiedene methodologische Ansätze vorgestellt, darunter qualitative, semi-quantitative und quantitative Methoden sowie Multi-Risikoanalysen, die Wechselwirkungen berücksichtigen. Das Kapitel schließt mit einer Diskussion der Vor- und Nachteile bestehender Methoden sowie der Herausforderungen im Bereich der Multi-Risikoanalysen.

2.1 Begriffe und Konzepte bezüglich Naturgefahren

Naturgefahren – wie beispielsweise Dürren oder Erdbeben – stellen eine bedeutende Herausforderung für unsere Gesellschaft dar und bergen Risiken für Mensch und Infrastruktur. Global gesehen sind Millionen von Menschen von ihnen betroffen. Die Auswirkungen sind dabei für die Bevölkerung in Ländern mit niedrigem bis mittlerem Einkommen besonders schwer (Ritchie et al. 2024, o.S.).

Damit ein Naturereignis – also eine ganz natürliche Komponente in einem System – allerdings zur Naturgefahr wird, muss die Möglichkeit gegeben sein, dass das Naturereignis eine Bedrohung für Menschen oder Objekte darstellt. Sind Naturereignisse also beispielsweise potenziell eine Gefahr für die Gesundheit oder gar lebensbedrohlich, können Sachschäden auftreten oder wirtschaftliche bzw. soziale Folgen mit dem Ereignis einhergehen, handelt es sich um eine Naturgefahr (Kappes et al. 2010, S. 351; UN-SPIDER o.J.b, o.S.). Es muss demnach ein bestimmter Schwellenwert überschritten werden, der je nach Person, Gesellschaft, materiellem Gut oder Objekt variieren und sich im Laufe der Zeit verändern kann (Dikau et al. 2020, S. 1103). Dikau et al. (2020, S. 1103) definieren Naturgefahren daher wie folgt:

„Naturgefahren sind [...] natürliche Prozesse, die vom Menschen als potenzielle Bedrohung für Leben und Eigentum betrachtet werden, da Eintrittshäufigkeit (Frequenz) und Eintrittsstärke (Magnitude) eine bestimmte Toleranzgrenze überschritten haben“.

Naturgefahren lassen sich in verschiedene Kategorien einteilen. Allerdings gibt es keine einheitliche Einteilung, die von allen Organisationen oder Regierungen weltweit übernommen wird (UNDRR 2021a, o.S.). Das United Nations Office for Disaster Risk

Reduction (UNDRR) schlägt gemeinsam mit dem International Science Council (ISC) eine Einteilung auf höchster Ebene in die Kategorien „Geophysical“, „Hydrological“, „Meteorological“, „Climatological“, „Biological“ und „Extraterrestrial“ vor (UNDRR und ISC 2020, S. 85). In Tabelle 1 findet sich eine Übersicht über die Aufteilung von Naturgefahren mit Beispielen für entsprechende Ereignisse der jeweiligen Kategorie, aufbauend auf den verschiedenen physikalischen, chemischen und biologischen Prozessen und Gesetzmäßigkeiten (Dikau et al. 2020, S. 1103).

Tabelle 1: Klassifikation von Naturgefahren.

(Quelle: Eigene Darstellung nach UNDRR und ISC (2020, S. 85), Dikau et al. (2020, S. 1104))

Ursache	Primäres Phänomen
Geophysikalisch Gefährliche natürliche Prozesse oder Phänomene der Lithosphäre und Reliefsphäre	• Erdbeben • Massenbewegung • Vulkanische Aktivität
Hydrologisch Gefährliche natürliche Prozesse oder Phänomene der Hydrosphäre	• Überschwemmung • Erdrutsch • Wellenaktivität
Meteorologisch Gefährliche natürliche Prozesse oder Phänomene der Atmosphäre	• Sturm • Extremtemperatur • Nebel
Klimatologisch Gefährliche natürliche Prozesse oder Phänomene aufgrund klimatischer Bedingungen	• Dürre • Ausbruch von Gletschersee • Waldbrand
Biologisch Gefährliche natürliche Prozesse oder Phänomene der Biosphäre	• Krankheit • Insektenplage • Tiervorfall
Extraterrestrisch Gefährliche Prozesse im Weltall	• Weltraumwetter • Einschlag

Besteht die Möglichkeit, dass zeitgleich oder aufeinanderfolgend mehrere Naturgefahren in einem Gebiet auftreten, handelt es sich um sogenannte multiple Naturgefahren bzw. multi-hazards. Der Begriff „multi-hazard“ entstand im politischen internationalen Kontext im Zusammenhang mit dem Streben nach Risikominderung und nachhaltiger Entwicklung in katastrophengefährdeten Gebieten und wurde etwa in dem Aktionsprogramm Agenda 21 und dem Johannesburg-Aktionsplan genutzt (Kappes et al. 2010, S. 351;

Kappes et al. 2012, S. 1926). Multi-hazards haben meist eine drastischere Auswirkung auf die Bevölkerung, insbesondere wenn sie miteinander wechselwirken und sich so gegenseitig verstärken (UNDRR und ISC 2020, S. 53; Zhang et al. 2023, S. 1). Je nach Beziehung zwischen den auftretenden Naturgefahren lassen sich multi-hazards laut Ming et al. (2022, S. 1) in folgende Kategorien einteilen:

- **Concurrent hazards:** Beschreiben das gleichzeitige Auftreten von zwei oder mehr Naturgefahren in Zeit und/oder Raum.
- **Successive hazards:** Beschreiben das mehrmalige Auftreten derselben Naturgefahr kurz hintereinander, sodass diese voneinander abhängen.
- **Cascading hazards:** Beschreiben multi-hazards, bei denen die primäre Naturgefahr eine sekundäre/tertiäre Naturgefahr auslöst oder die Wahrscheinlichkeit für andere Naturgefahren erhöht.

Führen (multiple) Naturgefahren zu schwerwiegenden Erschütterungen der Gesellschaft mit Verlusten und Auswirkungen auf menschlicher, materieller, wirtschaftlicher und/oder ökologischer Ebene, ist die Rede von einer Katastrophe. Die Auswirkungen einer Katastrophe können zeitlich unmittelbar auftreten und örtlich begrenzt sein, allerdings ist es meist der Fall, dass diese großflächig auftreten und über einen langen Zeitraum anhalten (UNDRR 2007a, o.S.).

Bei der Betrachtung von Naturgefahren – ob einzeln auftretende oder multiple – ist der Begriff des Risikos ein zentraler. Dabei geht es in diesem Zusammenhang vor allem um das Katastrophenrisiko. Generell wird der Risikobegriff je nach Kontext aber unterschiedlich definiert und wird dabei von einer Vielzahl disziplinärer Perspektiven und konzeptioneller Ansätze geprägt. Allem voraus lassen sich laut Birkmann (2008, S. 9) und Dikau et al. (2020, S. 1107) zwei wesentliche Ansätze differenzieren:

- **Risikoansatz 1:** Bezieht das Risiko auf zukünftige Ereignisse, bei denen potenziell die Möglichkeit besteht, dass ein Schaden eintritt. Wenn der Schaden tatsächlich eintritt, tritt dieser aufgrund des Verhaltens bzw. der Entscheidung des Einzelnen oder einer Gruppe ein, sodass dieser den Entscheidenden zugerechnet werden kann.
- **Risikoansatz 2:** Definiert Risiko als das Resultat der Interaktion zwischen einer Gefahr und einer anfälligen Gesellschaft oder einem anfälligen Objekt.

Folgt man der Definition des UNDRR (2009, o.S.), so ist das Katastrophenrisiko “[t]he potential loss of life, injury, or destroyed or damaged assets which could occur to a system, society or a community in a specific period of time, determined probabilistically as

a function of hazard, exposure, vulnerability and capacity". Abgesehen von der *Gefahr* an sich, also dem Prozess oder Phänomen, bei dem Todesfälle, Verletzungen, Sachschäden oder soziale/wirtschaftliche Erschütterungen als Folge möglich sind, spielen also – wie auch in Abbildung 1 zu erkennen – die Exposition und die Vulnerabilität eine bedeutende Rolle und sind damit wichtige Determinanten für das Risiko (Field et al. 2012, S. 6; UNDRR 2007b, o.S.).




Abb. 1: Einflussgrößen von Risiko.
(Quelle: Eigene Darstellung nach UN-SPIDER (o.J.a))

Die *Exposition* ist dabei ein Maß für die physische Ausgesetzttheit gegenüber der Naturgefahr, z.B. aufgrund der räumlichen Nähe (Bundesamt für Bevölkerungsschutz und Katastrophenhilfe o.J., o.S.; Dikau et al. 2020, S. 1115). Befinden sich also Menschen, Infrastruktur, Wohnraum oder andere materielle Güter in Gefahrenbereichen, sind diese anfällig für Schäden und damit exponiert. Soll Exposition quantifiziert werden, so lassen sich beispielsweise die Anzahl der Personen oder die Art der materiellen Güter hinzuziehen, die sich im Gefahrenbereich befinden, aber auch räumlichen Gegebenheiten vor Ort oder Wetter- und Geodaten können zur Abschätzung der Exposition nützlich sein (Bundesamt für Bevölkerungsschutz und Katastrophenhilfe o.J., o.S.; Geiß et al. 2023a, S. 779; UNDRR und ISC 2020, S. 55).

Die Analyse der *Vulnerabilität* kann wichtige Erkenntnisse darüber liefern, wie anfällig ein Individuum, eine Gruppe, materielle Güter oder ein System für Gefahren ist (Dikau et al. 2020, S. 1114). Das UNDRR und ISC (2020, o.S.) definiert Vulnerabilität dabei wie folgt: „The conditions determined by physical, social, economic and environmental

factors or processes which increase the susceptibility of an individual, a community, assets or systems to the impacts of hazards". Wie auch in Abbildung 2 zu erkennen, können physische Faktoren dabei beispielsweise schlechte bzw. unangepasste Baustandards oder unregulierte Landnutzungsplanung sein, soziale Faktoren hingegen Armut, Ungleichheit, Marginalisierung oder Diskriminierung. Trotz gleicher räumlicher Exposition, kann die Vulnerabilität verschiedener Personen oder Bevölkerungsgruppen so aufgrund der sozialen Positionen auseinandergehen. Auf der Seite der natürlichen Faktoren lassen sich beispielsweise schlechtes Umweltmanagement oder der Klimawandel anführen und als ökonomische Faktoren der informelle Sektor oder die Abhängigkeit von Industrien (Birkmann 2008, S. 8; UNDRR 2021b, o.S.).




Abb. 2: Multidimensionalität der Vulnerabilität.
(Quelle: Eigene Darstellung nach Lenz (2009); UNDRR (2021b)).

Aber auch bei der Betrachtung von Vulnerabilität gehen die Definitionen je nach Fachgebiet und operationeller Praxis auseinander und es werden diverse Ansätze verwendet, sodass sich das Konzept der Vulnerabilität zu einem interdisziplinären Forschungsfeld entwickelt hat, in welchem verschiedenste Fragestellungen untersucht werden (Birkmann 2008, S. 8; Dikau et al. 2020, S. 1114). Was das Konzept jedoch über alle

Disziplinen hinweg verbindet, ist seine Multidimensionalität, Dynamik, Maßstabsabhängigkeit und seine ortsspezifische Komponente (Harb und Dell'Acqua 2017, S. 2). Die Multidimensionalität drückt sich darin aus, dass verschiedene Dimensionen, die in komplexer Weise miteinander verbunden sind (z.B. physische oder soziale Dimension), Einfluss auf die Vulnerabilität nehmen. Die Dynamik wiederum zeichnet sich darin ab, dass es sich bei Vulnerabilität nicht um einen statischen Zustand handelt, sondern um einen, der über die Zeit hinweg variieren kann. Darüber hinaus differieren die Einflussfaktoren je nach räumlichem Maßstab. Verschiedene Betrachtungsebenen ergeben also unterschiedliche Stärken und Formen der Vulnerabilität (Lenz 2009, S. 33ff.). Wird über die Herausforderungen hinweggeschaut, die die Entwicklung eines gemeinsamen Ansatzes der Vulnerabilität über alle Disziplinen hinweg mit sich bringt, haben die verschiedenen Sichtweisen laut Birkmann (2008, S. 8) aber unter anderem auch dazu geführt, dass „sog. Naturkatastrophen heute nicht mehr als rein physisches Ereignis, sondern als vielschichtiges Mensch-Umwelt-Interaktionsproblem wahrgenommen werden“.

Da Vulnerabilität ein dynamisches Konzept ist und über zeitliche und räumliche Skalen variiert, weil es innerhalb der zutiefst vielschichtigen, dynamischen und miteinander verflochtenen Systeme der menschlichen Gesellschaft sowie der natürlichen Umwelt besteht, ist die genaue Erfassung von Vulnerabilität schwierig. Dementsprechend gibt es auch nicht *die eine* Methode, zur Bewertung von Vulnerabilität. Entscheidende Aspekte für die Ermittlung der Vulnerabilität einer Person können aber u.a. die verfügbaren materiellen Mittel sowie die Teilhabe an politischen und ökonomischen Ressourcen sein (Dikau et al. 2020, S. 1116; IPCC 2012, S. 7; UNDRR 2021b, o.S.).

Im Gegensatz zur Vulnerabilität ist die *Kapazität* als positiver Faktor zu sehen, der Menschen die Möglichkeit gibt, besser mit Gefahren umzugehen (UNDRR 2007c, o.S.). Die Bewältigungskapazität beschreibt in diesem Zusammenhang „die Fähigkeit, mit den Einwirkungen des Ereignisses für eine kurze Zeit umgehen zu können oder nach dem Ereignis eine schnelle Wiederherstellung des Ausgangszustandes zu erreichen“ (Birkmann et al. 2013, S. 3). Mit der Betrachtung der verschiedenen Dimensionen der Vulnerabilität und Einführung von entsprechenden Maßnahmen und positiven Veränderungen (also einer Ausweitung der Kapazität), wie beispielsweise der Einführung von Bauvorschriften oder dem besseren und sparsameren Umgang mit natürlichen Ressourcen, kann somit die Vulnerabilität der Bevölkerung verringert werden (Harb und Dell'Acqua 2017, S. 2).

2.2 Aktuelle Auswirkungen von Naturgefahren

In den letzten Jahren kam es zu einer Vielzahl an Katastrophen, ausgelöst durch Naturgefahren. Seit der Gründung der Emergency Events Database (EM-DAT) 1988 als gemeinsame Initiative des Centre for Research on the Epidemiology of Disasters (CRED) und der World Health Organization (WHO), gibt es eine umfassende Datenbank, die das Auftreten und die Auswirkungen von naturgefahrbedingten Katastrophen genaustens erfasst (CRED o.J., o.S.; UNDRR und CRED 2020, S. 4).

In den Jahren 2000-2019 wurden so 7.348 Katastrophen von der EM-DAT erfasst. Dabei werden allerdings nur solche Katastrophen erfasst, bei denen zehn oder mehr Menschen ums Leben gekommen sind, 100 oder mehr Menschen betroffen sind, ein Ausnahmezustand ausgerufen und international um Hilfe gebeten wird. Betrachtet man die Anzahl der erfassten Katastrophen der vorangegangenen zwanzig Jahre von 1980-1999 (4.212 erfasste Katastrophen), so lässt sich feststellen, dass sich die Zahl fast verdoppelt hat. Dies hängt zwar auch mit verbesserten Möglichkeiten der Erfassung und Meldung von Katastrophen zusammen, vor allem lässt sich der Anstieg aber mit einem signifikanten Anstieg an klimabedingten Katastrophen – also Katastrophen durch Naturgefahren der Klassen Meteorologisch, Klimatologisch oder Hydrologisch – erklären (UNDRR und CRED 2020, S. 6).

Der Klimawandel bedingt ein vermehrtes Auftreten von Naturgefahrenereignissen sowie das Auftreten von Naturgefahrenereignissen in neuen Gebieten, was wiederum die Exposition und Vulnerabilität der Bevölkerung steigert. Darüber hinaus wird es durch den Klimawandel schwieriger die Wahrscheinlichkeit, als auch die Folgen von Katastrophen abzuschätzen und zu kommunizieren, insbesondere im Zusammenhang mit Extremereignissen (IPCC 2012, S. 46). Bereits mit einer globalen Klimaerwärmung im Jahr 2019 von 1,1 °C mehr als zu vorindustriellen Zeiten, lässt sich ein erhöhtes Vorkommen von Extremwetterereignissen wie Hitzewellen, Dürren, Überschwemmungen, Hurricanes und Waldbränden feststellen. Vergleicht man die Zahlen der Katastrophenauswirkungen wie Todesfälle, Betroffene und wirtschaftliche Verluste in den Jahren 2000-2019 im Vergleich zu 1980-1999, so sieht man in allen Punkten einen deutlichen Anstieg – auch zu erkennen in Abbildung 3. Die Zahl der Betroffenen stieg beispielsweise von 3,25 Milliarden auf 4,03 Milliarden, die Zahl der wirtschaftlichen Verluste in US\$ von 1,63 Billionen auf 2,97 Billionen (UNDRR und CRED 2020, S. 6f.). Es wird davon ausgegangen, dass diese Zahlen in Zukunft weiter ansteigen, sollte der Ausstoß von Treibhausgasen nicht drastisch reduziert und das Übereinkommen von Paris mit einem Ziel von maximal 1,5 °C Erderwärmung im Vergleich zur vorindustriellen Zeit eingehalten werden, da jegliche Zunahme der globalen Erwärmung die Häufigkeit und Intensität sowie das Vorkommen von multiplen und

gleichzeitig auftretenden Naturgefahren verstärkt. Wenn die globale Erwärmung im derzeitigen Tempo weiter zunimmt, wird diese voraussichtlich bereits zwischen 2030 und 2052 1,5 °C erreichen (Lee und Romero 2023, S. 12; Masson-Delmotte et al. 2022, S. 4). Laut Copernicus Climate Change Service (2024, o.S.) wurde dieser Wert bereits innerhalb einer zwölfmonatigen Periode von Februar 2023 bis Januar 2024, mit einer mittleren Temperatur von 1,52 °C über dem vorindustriellen Niveau, überschritten.




Abb. 3: Auswirkungen von Katastrophen 1980-1999 vs. 2000-2019 mit logarithmischer Skalierung. (Quelle: Eigene Darstellung nach UNDRR und CRED (2020))

Betrachtet man die Anzahl der Betroffenen von Katastrophenereignissen nach Ländern, so lässt sich feststellen, dass mit standardisierten Daten (Betroffene pro 100.000 Einwohner*innen) sechs der Top 10 betroffenen Länder in Afrika liegen: Eswatini (11.380), Mauretanien (9.279), Somalia (8.939), Zimbabwe (8.511), Lesotho (7.650) und Niger (7.500). Eswatini und Mauretanien waren dabei in den letzten zwei Jahrzehnten von starken und häufigen Dürren betroffen. Des weiteren befinden sich die drei Inselstaaten Kuba (9.051), Dominikanische Republik (7.560) und Philippinen (7.796) sowie die Mongolei (8.664) unter den Top 10, wobei die Inselstaaten von Stürmen betroffen waren (UNDRR und CRED 2020, S. 20).

Die meisten der erfassten Katastrophen zwischen 2000-2019 waren auf Überschwemmungen – insgesamt 3254, was einem Anteil von 44 % entspricht – zurückzuführen, gefolgt von Stürmen mit insgesamt 2043 Vorfällen (28 %). Der prozentuale Anteil weiterer Katastrophen-Typ liegt jeweils unter 10 % (UNDRR und CRED 2020, S. 10). Eine genaue Auflistung der Katastrophenzahlen nach Typ findet sich in Abbildung 4.

Problematisch wird es auch, wenn Menschen mehr als einer Naturgefahr gleichzeitig ausgesetzt sind, da dies aufgrund der kumulativen und kaskadierenden Effekte potenziell zu schwerwiegenden Katastrophen führt und eine erhebliche Bedrohung für Menschenleben und Sachgüter darstellt (Lee et al. 2024, S. 1; Ming et al. 2022, S. 1). Laut einem Bericht der Weltbank bezüglich Hotspots von Naturkatastrophen, sind weltweit 3,8 Millionen km² und 790 Millionen Menschen mindestens zwei Naturgefahren relativ stark ausgesetzt. Etwa 0,5 Millionen km² und 105 Millionen Menschen sind sogar drei oder mehr Naturgefahren relativ stark ausgesetzt (Dilley et al. 2005, S. 2). Außerdem leben in mehr als 90 Ländern mehr als 10 % der Gesamtbevölkerung in Gebieten mit einem relativ hohen Sterblichkeitsrisiko aufgrund von zwei oder mehr Naturgefahren (Dilley et al. 2005, S. 8).




Abb. 4: Anzahl der Katastrophenereignisse nach Typ: 1980-1999 vs. 2000-2019.
(Quelle: Eigene Darstellung nach UNDRR und CRED (2020))

2.3 Abgrenzung von Gefahren-, Expositions-, Vulnerabilitäts- und Risikoanalysen

In den letzten Jahren wurden zahlreiche Gefahren-, Expositions-, Vulnerabilitäts- und Risikoanalysen bezüglich Naturgefahren realisiert. Insbesondere Risikoanalysen spielen bei der Bewertung von Naturgefahren eine entscheidende Rolle, da diese helfen die Komplexität der Gegebenheiten zu verstehen, und somit zur Entscheidungsfindung bezüglich des Risikomanagements beitragen. Nur so können wirksame Strategien zur Vorbereitung und Reaktion auf diverse Arten von Naturgefahren entwickelt und Maßnahmen getroffen werden, die die Auswirkungen von diesen abschwächen und reduzieren (Zhang et al. 2023, S. 1). Die unterschiedlichen Arten der Analysen können nach v. Elverfeldt et al. (2008) und UNDRR (2017) wie folgt beschrieben werden:

- **Gefahrenanalyse:** Die Abschätzung der Eintrittswahrscheinlichkeit von Naturgefahren in einem bestimmten Raum sowie mit einer bestimmten Intensität und Frequenz.
- **Expositionsanalyse:** Konzentrieren sich darauf zu ermitteln, welche Gebiete oder Vermögenswerte Naturgefahren physisch ausgesetzt sind und erfassen somit potenzielle Schadenobjekte.
- **Vulnerabilitätsanalyse:** Untersuchung der Verwundbarkeit der Betroffenen und ihres Lebensumfelds gegenüber Naturgefahren, aufgrund von physikalischen, sozialen, wirtschaftlichen und ökologischen Faktoren.
- **Risikoanalyse:** Bestimmen die Art und das Ausmaß des Risikos und bestehen meist aus den drei Komponenten der Naturgefahren-, Expositions- und Vulnerabilitäts-Analyse.

Auch Erkenntnisse darüber zu gewinnen, wie sich Risiken im Laufe der Zeit verändern, ist bei der Risikoanalyse von großer Wichtigkeit. Diese Erkenntnisse werden im besten Fall dazu genutzt, entsprechende Maßnahmen zu etablieren (UNISDR 2007, S. 7). Wichtig ist es beim Etablieren von Maßnahmen und bei generellen Entscheidungen im Risikomanagement aber nicht nur einzelne Risiken zu berücksichtigen, sondern die Komplexität multipler Gefahren miteinzubeziehen:

„While single-risk approaches, i.e. risk considering a single type of hazards, may not provide sufficient information for risk management decision, the multi-risk concept forms a better tool for understanding and demonstrating the complexity of danger issues of a given area. Additionally, a multi-risk method enables a considerable participation of decision makers and offers an objective-based guidance of the analysis” (Harb und Dell'Acqua 2017, S. 3).

Laut Harb und Dell'Acqua (2017, S. 3) sollten Multi-Risikoanalysen dennoch nicht als eine Alternative zu Risikoanalysen mit Bezug auf nur eine Gefahrenart betrachtet werden. Die verschiedenen Analyseformen sind nicht austauschbar, da sie unterschiedliche Informationen widerspiegeln. Wird eine Risikoanalyse für eine einzelne Naturgefahr ausgearbeitet, sind diese meist detaillierter, als entsprechende Multi-Risikoanalysen und bieten so genauere Informationen zu den potenziellen Gefahren und möglichen Folgen. Ergänzend geben Multi-Risikoanalysen Auskunft über die Agglomeration mehrerer Gefahrenarten sowie deren möglichen Wechselwirkungen und berücksichtigen so die lokale Bedeutung verschiedener Gefahrenarten (Harb und Dell'Acqua 2017, S. 3). Delmonaco et al. (2006, S. 15) definieren Multi-Risikoanalysen dabei als „[i]mplementation of methodologies and approaches aimed at assessing and mapping the potential damage/expected

loss due to the occurrence of different types of natural or human-induced hazards on social, environmental and economic settings of a given area". Die eingesetzten Methoden müssen dabei sämtliche potenziellen Gefahren, die Exposition sowie die Vulnerabilität berücksichtigen (Delmonaco et al. 2006, S. 15).

In den vergangenen Jahrzehnten hat das Interesse an Multi-Risikoanalysen, die sowohl verschiedene Naturkatastrophen, als auch menschenverursachte Gefahrenereignisse einbeziehen, sowohl auf globaler als auch auf europäischer Ebene, zugenommen. Besonders im Fokus stehen dabei Anwendungen und Programme zur umfassenden Einschätzung von Naturgefahren (Gallina et al. 2016, S. 124). Dabei lassen sich laut Gallina et al. (2016, S. 125) und Kappes et al. (2010, S. 352) je nach spezifischem Vorgehen bei der Analyse zwei Ansätze unterscheiden (mehr zum verwendeten Ansatz im Rahmen des Gefahrenindex in Kapitel 4.2):

- **Multi-risk assessment:** Beziehungen und Wechselwirkungen der Naturgefahren stehen im Fokus und werden bei der Analyse berücksichtigt. Auch die Vulnerabilität wird hierbei im Gesamten bewertet.
- **Multi-hazard risk assessment:** Risiken der verschiedenen Naturgefahren werden separat analysiert und die Ergebnisse zusammengeführt.

Sollen reale Probleme im Zusammenhang mit Naturgefahren gelöst werden, ist es wichtig auch Analysen des ersten Ansatzes durchzuführen, da Naturgefahren im selben Gebiet nicht unabhängig voneinander wirken, da sie als Bestandteile eines größeren Systems voneinander beeinflusst werden – auch bekannt als *Dominoeffekt*. Bisher gibt es dazu aber nur wenige Methoden, auf welche in Kapitel 2.4.4 näher eingegangen wird. Mit Hilfe dieser Methoden erhalten Entscheidungsträger*innen alle unverzichtbaren Informationen, um konkrete Leitlinien für Notfallvorsorge (beispielsweise die Entwicklung von Evakuierungsplänen oder der Bau von widerstandsfähiger Infrastruktur) bereitzustellen sowie eine räumliche nachhaltige Entwicklung mit Augenmerk auf eine Steigerung der Resilienz und sichere Landnutzungsplanung zu gewährleisten (Tsiplakidis und Photis 2019, S. 403f.).

2.4 Methodologische Ansätze im Bereich der (Multi-)Risikoanalysen

Aufgrund der stetig wachsenden Bedeutung von (Multi-)Risikoanalysen und deren Komponenten gibt es bereits zahlreiche Studien, die sich damit befassen und verschiedene Ansätze verfolgen. Grundsätzlich lassen sich hierbei qualitative, semi-quantitative und quantitative Ansätze unterscheiden, wobei die meisten bestehenden Analysen auf qualitativen oder semi-quantitativen Methoden beruhen (Ming et al. 2022, S. 2; Tsiplakidis und

Photis 2019, S. 405). Des Weiteren sind bei den verschiedenen Methoden Unterschiede in der Einbindung bzw. Nichteinbindung von Interaktionen zwischen verschiedenen Naturgefahren und auf dem Vulnerabilitätslevel zu beachten – dargestellt in Abbildung 5. Je nach wahrgenommener Relevanz der Methode, Nutzen und verfügbaren Ressourcen wird auf den dazu passenden Ansatz zurückgegriffen (Simmons et al. 2017, S. 50). Auf die einzelnen Methoden, deren Vor- und Nachteile sowie Limitationen wird in diesem Kapitel eingegangen.




Abb. 5: Von der Einzelrisiko- zur Multi-Risikoanalyse.
(Quelle Zschau (2017, S. 99))

2.4.1 Qualitative Methoden

Qualitative Methoden zur Analyse der Gefahr, der Exposition oder des Risikos sind in ihrer Durchführung vergleichsweise simpel (Gallina et al. 2016, S. 126). Eine zentrale Rolle spielen hier die *Einschätzungen von Expert*innen*. In ihrer simpelsten Ausprägung kommen qualitative Methoden als narrative Beschreibungen in Form von Ereignisberichten oder zukunftsorientierten Schilderungen möglicher Auswirkungen bestimmter Naturgefahrenereignisse vor. Häufiger jedoch werden verschiedene Variablen, die die Merkmale und möglichen Folgen von Gefahren wie Intensität, Ausmaß und Häufigkeit widerspiegeln, von Expert*innen mit Hilfe von Fragebögen oder Interviews kategorisiert (z.B. hoch, mittel, niedrig). Wenn mehr als eine Naturgefahr vorliegt, werden die Gefahrenklassen oft separat geschätzt und anschließend zusammengefasst (zu Methoden, die die Interaktion verschiedener Naturgefahren berücksichtigen, s. Kapitel 2.4.4). Meist wird das Ganze

nachfolgend in einer *Matrix* zusammengetragen, um das Risiko entsprechend zu klassifizieren (Ciurean et al. 2018, S. 9; Harb und Dell'Acqua 2017, S. 3; Tsiplakidis und Photis 2019, S. 405ff.).

Ein Beispiel für eine solche Matrix, die auf einem Multilayer single-risk Ansatz beruht, aus den Schweizer Richtlinien zur Analyse und Bewertung von Naturgefahren, findet sich in Abbildung 6. Hierbei ergibt sich das Ausmaß der Gefahr aus der Kombination der Intensität und Häufigkeit, die jeweils in *high*, *moderate* und *low* eingeteilt werden, wobei für die Zuordnung zu einer bestimmten Kategorie die möglichen Auswirkungen auf Gebäude und Menschen ausschlaggebend sind. Rot steht dabei für eine hohe Gefahr, wobei Menschen innerhalb und außerhalb von Gebäuden gefährdet sind und die Möglichkeit einer raschen Zerstörung von Gebäuden besteht, blau für eine moderate Gefahr, was bedeutet, dass Menschen außerhalb von Gebäuden gefährdet sind und Schäden an der Bausubstanz möglich sind, aber keine rasche Zerstörung des Gebäudes stattfinden sollte und gelb für eine geringe Gefahr, wobei Menschen außerhalb von Gebäuden einer geringen Gefahr unterliegen und zwar Schäden innerhalb von Gebäuden auftreten können, jedoch nicht an der Bausubstanz. Gelb-weiß gestreift steht wiederum für eine Restgefährdung mit hoher Intensität, die aber sehr unwahrscheinlich in ihrem Eintreten ist (Kappes et al. 2012, S. 1930; Kunz und Hurni 2008, S. 134f.).




Abb. 6: Schweizer Intensitäts-Wahrscheinlichkeits-Matrix.
(Quelle: Kunz und Hurni (2008, S. 134); Zschau (2017, S. 102))

Bei einer beispielhaften Einteilung der Gefahr in hoch, mittel und niedrig, wie auch im Falle der Schweizer Intensitäts-Wahrscheinlichkeits-Matrix, ist jedoch ungewiss, wie der quantitative Unterschied zwischen den Dimensionen ist, also wie viel höher genau

„hoch“ im Vergleich zu „mittel“ ist. Eine numerische Bewertung der Gefahr gibt es hier demnach nicht (Gallina et al. 2016, S. 126; Kappes et al. 2012, S. 1928). Mit Hilfe von Gefahrenmatrizen können aber die Bedeutungen der einzelnen Naturgefahren verglichen werden. Zudem lassen sich aus den Matrizen Gefahrenkarten ableiten. Werden die Klassifizierungsergebnisse überlagert, lassen sich so alle Gefahren gemeinsam auf einer Gesamtgefahrenkarte darstellen (Zschau 2017, S. 101).

Qualitative Methoden werden häufig im Zusammenhang mit größeren Skalen, also beispielsweise auf nationaler Ebene, eingesetzt, insbesondere dann, wenn die vorhandenen Daten weniger detailreich sind und dies mit Hilfe des qualitativen Ansatzes kompensiert werden soll (Harb und Dell'Acqua 2017, S. 3).

2.4.2. Semi-quantitative Methoden

Semi-quantitative Ansätze beziehen sich bei der Beschreibung auf eine Skala, die eine relative Rangfolge ermöglicht und Aufschluss darüber gibt, wie viel stärker ein bestimmtes Gefahren-Szenario im Vergleich zu einem anderen ist (Kappes et al. 2012, S. 1928; Tsiplakidis und Photis 2019, S. 405ff.). Aufgrund dessen ist das Maß an Generalisierung und Subjektivität im Vergleich zu qualitativen Ansätzen geringer. Die Schwellenwerte für die Kategorisierung von Variablen wie Intensität oder Wahrscheinlichkeit beruhen bei den semi-quantitativen Ansätzen auf statistischen Analysen und werden nicht von Expert*innen bestimmt (Harb und Dell'Acqua 2017, S. 3). Dabei werden den verschiedenen Klassen meist numerische Werte oder Gewichtungen zugewiesen (Gallina et al. 2016, S. 128).

Der Ansatz der semi-quantitativen Methoden, der am häufigsten zum Einsatz kommt, ist der *Index-basierte Ansatz* (Harb und Dell'Acqua 2017, S. 3; Ming et al. 2022, S. 2). Hierbei werden, je nachdem um welche Art der Analyse es sich handelt (s. Abbildung 5), verschiedene Faktoren, wie beispielsweise Exposition, Vulnerabilität oder die Auftretenswahrscheinlichkeit von Naturgefahren, bewertet und üblicherweise zwischen null und eins standardisiert. Abschließend werden die Werte rechnerisch zu einem Index zusammengefasst (Gallina et al. 2016, S. 130; Tsiplakidis und Photis 2019, S. 405; Zschau 2017, S. 102f.). Dabei ist jedoch zu beachten, dass es laut Ciurean et al. (2018, S. 12) für einen Index, der multiple Gefahren einbezieht, nicht immer ausreicht, die einzelnen Indizes der Einzelgefahren zu aggregieren – mehr dazu in Kapitel 2.4.4.

2.4.3 Quantitative Methoden

Quantitative Ansätze arbeiten mit genauen Messungen – beispielsweise mit der gewichtete Summe oder dem Bayessches Netz – und ermöglichen die Bestimmung absoluter Werte auf einer festgelegten Skala (Kappes et al. 2012, S. 1928). So können direkte Auswirkungen oder indirekte Verluste sowie das Risiko von Gefahren und deren Eintrittswahrscheinlichkeit genauestens in Zahlen ausgedrückt werden. Aufgrund der Komplexität quantitativer Methoden und der Notwendigkeit detaillierter Daten werden diese in der Regel auf lokaler Ebene angewendet (Harb und Dell'Acqua 2017, S. 3; Tsiplakidis und Photis 2019, S. 408). In den Tabellen 2 und 3 ist beispielhaft zu erkennen, wie der Unterschied zwischen qualitativen und quantitativen Definitionen bezüglich Eintrittswahrscheinlichkeit und Intensität aussehen kann.

Tabelle 2: Beispiel zur qualitativen und quantitativen Definition der Eintrittswahrscheinlichkeit eines Ereignisses.

(Quelle: Harb und Dell'Acqua (2017, S. 4))

	Rare	Unlikely	Possible	Likely	Certain
Qualitative	Events virtually never occurred	Events are unlikely to occur, but has to be considered as being possible	Unlikely but may occur when considering several similar situations	May occur once during the total studied period	May occur several times during the studied period
Quantitative	Event probability is $< 10^{-4}$ per 25 years	Event probability is between 10^{-4} & 10^{-3} per 25 years	Event probability is between 10^{-3} & 10^{-2} per 25 years	Event probability is between 10^{-2} & 10^{-1} per 25 years	Event probability is $\geq 10^{-1}$ per 25 years

Tabelle 3: Beispiel für die qualitative und quantitative Definition der Schwere des Ereignisses als Verhältnis der Verluste zum nationalen BIP.

(Quelle: Harb und Dell'Acqua (2017, S. 4))

	Negligible	Low	Moderate	Significant	Catastrophic
Qualitative	Negligible economic loss	Low direct impact economic loss which can be easily restored	Moderate economic loss, still can be hardly restored	Large economic loss which cannot be restored	Catastrophic economic loss which cannot be restored
Quantitative	Event Severity is $< 10^{-4}$ of National GDP	Event Severity is between 10^{-4} & 10^{-3} of National GDP	Event Severity is between 10^{-3} & 10^{-2} of National GDP	Event Severity is between 10^{-2} & 10^{-1} of National GDP	Event Severity is $\geq 10^{-1}$ of National GDP

Ein Beispiel für einen probabilistischen quantitativen Ansatz wäre die Modellierung der Auswirkungen für verschiedene Szenarien, wobei die Ergebnisse meist in Form von *Risikokurven* dargestellt werden (Harb und Dell'Acqua 2017, S. 3). Dabei werden die Auswirkungen/Verluste, beispielsweise monetäre Schäden, der Eintrittswahrscheinlichkeit gegenübergestellt. Für die Berechnung wird u.a. auf Daten wie historische Aufzeichnungen, Zeitreihendaten oder Daten aus Häufigkeitsanalysen und Gefahrenmodellen zurückgegriffen. Werden mehrere Risikokurven in einer Graphik dargestellt, ermöglicht dies den direkten quantitativen Vergleich der Risiken für die entsprechenden Wahrscheinlichkeitsbereiche. Ein Beispiel für eine solche Risikokurve findet sich in Abbildung 7, wobei hier die monetären Schäden für Gebäude und Hausrat in den Bereichen privater Wohnungsbau, Gewerbe und Industrie in der Stadt Köln, der Überschreitungswahrscheinlichkeit für die drei Naturgefahren Sturm, Überschwemmung und Erdbeben, gegenübergestellt werden. Gut zu erkennen ist hier auch der Nutzen solcher Kurven, da sich die jeweiligen Merkmale und die Bedeutsamkeit der einzelnen Naturgefahren klar abzeichnen. So ergibt sich in diesem Beispiel u.a., dass Überschwemmungen, die relativ häufig vorkommen, durchaus einen hohen monetären Schaden bewirken, seltener vorkommende Erdbeben allerdings einen deutlich höheren (Grünthal et al. 2006, S. 38; Kappes et al. 2012, S. 1947; Schmidt et al. 2011, S. 1174).




Abb. 7: Risikokurven für die Stadt Köln (Referenzjahr: 2000).
(Quelle: Grünthal et al. (2006, S. 39))

Die Möglichkeit ein Risiko quantitativ einzuschätzen, ist äußerst wichtig, um Gefahren eindeutig darzustellen. Mit der Verfügbarkeit von Zahlen und somit detaillierteren Informationen zu potenziellen Schäden und Verlusten, können Risikomanagemententscheidungen durch Entscheidungsträger*innen besser gefällt und Präventionsmaßnahmen besser geplant werden (Ming et al. 2022, S. 2; Tsiplakidis und Photis 2019, S. 408).

2.4.4 Multi-Risikoanalysen unter Berücksichtigung von Wechselwirkungen

Nachdem ein Überblick über qualitative, semi-quantitative und quantitative Methoden für Gefahren-, Expositions- und Risikoanalysen sowie deren Unterschiede gegeben wurde, wird im Folgenden auf Methoden eingegangen, die die Interaktion von mehreren Naturgefahren mit einbeziehen. Noch immer werden Naturgefahren bei der Analyse häufig isoliert betrachtet und als unabhängig voneinander angesehen, sodass lediglich die Ergebnisse der Einzelanalysen zusammengeführt werden. Doch bei der Beobachtung im Feld zeigt sich, dass diese Darstellung nicht der Realität entspricht und sich durch den Dominoeffekt das Gefahrenniveau über dem Bereich befinden kann, der sich bei ausschließlicher Aufsummierung der einzelnen Gefahren ergeben würde. Katastrophen die auf Dominoeffekten basieren, haben meist die größten Auswirkungen auf Mensch und Umwelt. Daher sind Ansätze erforderlich, die diese Interaktionen und Wechselbeziehungen berücksichtigen (Kappes et al. 2010, S. 351f.; Tsiplakidis und Photis 2019, S. 411). Bisher wurden nur vereinzelt Ansätze, die die räumlichen und zeitlichen Wechselwirkungen zwischen den Gefahren berücksichtigen, entwickelt. Dazu zählen Interaktionsmatrizen, probabilistische grafische Modelle wie Event Tree oder Bayesian Network und Machine Learning Modelle (Tsiplakidis und Photis 2019, S. 404).

Interaktionsmatrizen gehören zu den semi-quantitativen Methoden. Zschau (2017, S. 107) beschreibt diesen Ansatz wie folgt: „[Interaction-matrices] offer a structured approach to examine and visualise hazard interactions and to see how strong these interactions are, aiming not only at the identification of important hazard relations but also at getting insight into the evolution of the system when different hazards interact“. Ein Beispiel für eine solche Interaktionsmatrix findet sich in Abbildung 8. Die Matrix ist so aufgebaut, dass sich in dessen Diagonale alle potenziell interagierenden Gefahren für ein Untersuchungsgebiet befinden. Die übrigen Elemente beschreiben wiederum im Uhrzeigersinn die Wechselwirkungen, sodass die Einflüsse einer Gefahr auf das System in der zugehörigen Matrixzeile und die Einflüsse des Systems auf die Gefahr in der Spalte der Gefahr abgebildet sind. „Deposits only“ wäre hier demnach der Einfluss von Slides auf Debris Flows und „No Interaction“ der Einfluss von Debris flows auf Slides. Die Stärke der

Wechselwirkungen wird dabei mit numerischen Codes zwischen null (keine Interaktion) und drei (starke Interaktion) angegeben, um die Priorität jeder Interaktion darzustellen. Um eine übermäßige Gewichtung einer einzelnen Gefahr zu vermeiden, wird jeweils die Summe der Codes für die Zeilen und Spalten, also der Ursachen und Wirkungen, evaluiert (Liu et al. 2015, S. 5f.; Tsiplakidis und Photis 2019, S. 412; Zschau 2017, S. 108).




Abb. 8: Interaktionsmatrix zur Identifizierung der Wechselwirkungen zwischen Gefahren. (Quelle: Liu et al. (2015, S. 5); Zschau (2017, S. 107))

Ein weiterer Ansatz zur Bewertung der Wechselwirkungen zwischen Gefahrenarten sind *probabilistische grafische Modelle*. Die Ergebnisse dieser sind aussagekräftiger als die Ergebnisse von Interaktionsmatrizen, weswegen dieser Ansatz ein wirksames Instrument im Bereich der Multi-Risikoanalysen darstellt (Tsiplakidis und Photis 2019, S. 413). Beim *Event Tree* werden die möglichen Folgen eines initialen Ereignisses betrachtet, wobei das Ganze als Knoten, die über Zweige verbunden sind, dargestellt wird und so verschiedene Szenarien identifiziert werden. Die verschiedenen Szenarien werden jeweils quantifiziert, indem ihnen Eintrittswahrscheinlichkeiten mit Hilfe einer Wahrscheinlichkeitsdichtefunktion zugeschrieben werden. Als letzter Schritt werden die Wahrscheinlichkeiten der möglichen Endzustände des Gesamtsystems berechnet, wobei sich das Risiko aus den jeweiligen Folgen des Ereignisses und dessen Wahrscheinlichkeiten ergibt. Eine schematische Darstellung eines Event Trees findet sich in Abbildung 9 (Kappes et al. 2012, S. 1937; Terzi et al. 2019, S. 767; Tsiplakidis und Photis 2019, S. 413).




Abb. 9: Schematische Darstellung eines Event Trees.
(Quelle: van Westen (2014, o.S.).)

Eine weitere Methode der probabilistischen grafischen Modelle sind *Bayesian Networks*. Auch hier werden folglich Wahrscheinlichkeiten, genauer gesagt bedingte Wahrscheinlichkeiten, genutzt um Risiken zu ermitteln. Die grafische Struktur besteht dabei aus Knoten und Pfeilen, wobei erstere die Ursache/Wirkung und zweitere die Abhängigkeit zwischen den Variablen aufzeigen. Jeder Knoten ist dabei einer Zufallsvariablen zugeordnet und die Wechselbeziehungen werden mit den entsprechenden bedingten Wahrscheinlichkeiten dargestellt (Liu et al. 2015, S. 7; Tsiplakidis und Photis 2019, S. 415).

In den letzten Jahren hat sich zudem der Einsatz von *Machine Learning* als eine bedeutsame Methode im Rahmen von Multi-Risikoanalysen etabliert, wobei ganz verschiedene Machine Learning Verfahren, wie beispielsweise *Support Vector Machine*, *Random Forest* oder *K-means clustering*, verwendet werden. Alle Verfahren weisen dabei gewisse Vor- und Nachteile auf, wobei die Performance des Modells je nach verwendeten Input-Daten, der Struktur sowie der Genauigkeit des Modells variiert. Für die Anwendung eines Modells werden zunächst passende Datensätze gesammelt und bereinigt. Diese werden daraufhin in einem nächsten Schritt in Trainings- und Testdaten unterteilt. Dabei werden meist 70 % der Daten als Trainings- und 30 % der Daten als Testdaten verwendet. Basierend auf den Trainingsdaten können dann Vorhersagen, beispielsweise zum erwarteten Schaden, getroffen werden. Die Genauigkeit der Vorhersagen kann mit der Berechnung von *Precision*, *Recall*, *F1 Score* und *Accuracy* ermittelt werden (Nachappa et al. 2020, S. 10; Rocchi et al. 2022, S. 2; Zhang et al. 2023, S. 2).

Es ist wichtig, dass die vorgestellten Methoden, zur Einbeziehung von Interaktionen und Wechselwirkungen zwischen Naturgefahren, im Zuge von Risikoanalysen zukünftig vermehrt zum Einsatz kommen, da u.a. Gill und Malamud (2016, S. 659) warnen, „that ignoring interactions between important environmental and anthropogenic processes could distort management priorities, increase vulnerability to other spatially relevant hazards or underestimate disaster risk“.

2.4.5 Stärken und Schwächen bestehender Methoden

Die vorgestellten Methoden weisen jeweils unterschiedliche Stärken und Schwächen auf. Die Durchführung qualitativer Risikoanalysen ist sehr simpel und auch in Fällen von Datenknappheit möglich. Allerdings dienen die Ergebnisse aus qualitativen Risikoanalysen meist nur einer ersten gröberen Einschätzung des Risikos bzw. als erster Schritt innerhalb einer breiter angelegten Risikoanalyse, da eine Analyse ohne numerische Werte weniger präzise ist, Subjektivität stärker zulässt und nur eine eingeschränkte Vergleichbarkeit sowie begrenzte Vorhersagekraft bietet (Harb und Dell'Acqua 2017, S. 3; Ming et al. 2022, S. 2). Die Subjektivität ergibt sich daraus, dass Expert*innen Gefahren und Risiken nach ihren Erwartungen und ihrer Expertise klassifizieren. Unterschiedliche Expert*innen können folglich unterschiedliche Einschätzungen und Beurteilungen abgeben, wobei beispielsweise auch, bei entsprechenden Ansätzen, die simple Definition der Klassenschwellen auf diesen beruht. Die eingeschränkte bzw. nicht vorhandene Vergleichbarkeit resultiert daraus, dass qualitative Risikoanalysen, und dabei insbesondere klassifizierte Informationen, wie in Intensitäts-Wahrscheinlichkeits-Matrizen, meist für einen bestimmten Anwendungsfall entwickelt werden und so unterschiedliche Kriterien bei verschiedenen Studien zum Einsatz kommen (Kappes et al. 2012, S. 1929; Tsiplakidis und Photis 2019, S. 403). Qualitative Risikoanalysen werden aufgrund ihrer Merkmale häufig in frühen Phasen des Risikomanagements eingesetzt, um verschiedene Risiken, die im selben Interessengebiet auftreten, priorisieren zu können (Gallina et al. 2016, S. 130).

Um die Qualität der qualitativen Methoden dennoch gewährleisten zu können, wird bei der Befragung von Expert*innen immer häufiger die *Delphi-Methode* eingesetzt, um sicherzustellen, dass Fehleinschätzungen möglichst gering gehalten werden (Gallina et al. 2016, S. 126). Die Delphi Methode lässt sich in diesem Zusammenhang laut Greiving (2006, S. 79) wie folgt beschreiben:

„The Delphi Method is based on a structured process for collecting and synthesizing knowledge from a group of experts through iterative and anonymous investigation of opinions by means of questionnaires accompanied by controlled opinion feedback. After several rounds of assigning weights, the individual scores are finally aggregated to achieve collective weights for all hazards”.

Da die Entscheidungen und Antworten von Expert*innen bei diesem Ansatz einen erheblichen Einfluss auf das Ergebnis der abgefragten Werte haben, ist dieser Schritt von hoher Wichtigkeit für ein aussagekräftiges Ergebnis (Greiving 2006, S. 79).

Semi-quantitative Ansätze beziehen sich bei der Beschreibung auf eine Skala, weshalb diese den Vorteil der relativen Rangfolge sowie die Möglichkeit der Quantifi-

zierung von Unterschieden zwischen verschiedenen Klassifizierungen bieten. Die Generalisierung ist also etwas geringer. Trotz dessen ist auch mit diesem Ansatz weiterhin keine Quantifizierung von Gefahrenfolgen, wie beispielsweise die Anzahl Todesfälle oder das Ausmaß von Sachschäden, möglich (Kappes et al. 2012, S. 1928; Tsiplakidis und Photis 2019, S. 405ff.).

Quantitative Methoden können diese Limitation überwinden und geben Aufschluss zu potenziellen Schäden oder Verlusten. Zudem sind sie weit weniger subjektiv, was auch eine breitere Anwendbarkeit der Ergebnisse ermöglicht, da nicht zuerst Klassenschwellen oder Indexbereiche definiert werden müssen. Sie bieten so eine relativ objektive Grundlage für die Entscheidungsfindung. Nachteile hingegen sind, dass die Anwendung von quantitativen Methoden komplexer ist und eine hohe Datenverfügbarkeit notwendig ist (Kappes et al. 2012, S. 1945f.; Simmons et al. 2017, S. 58). Eine Übersicht zu den Vor- und Nachteilen von qualitativen, semi-quantitativen und quantitativen Ansätzen findet sich in Tabelle 4.

Tabelle 4: Vor- und Nachteile verschiedener Methoden zur Gefahren- und Risikobewertung.
(Quelle: Eigene Darstellung)

Methode	Vorteile	Nachteile
Qualitative Methoden	• Einfache Anwendbarkeit • Anwendbarkeit bei Datenknappheit • Leichte Integration der Einschätzungen von Expert*innen • Darstellbarkeit von großen Mengen multidisziplinärer Informationen	• Subjektivität • Keine/eingeschränkte Vergleichbarkeit • Weniger präzise • Keine numerische Bewertung
Semi-quantitative Methoden	• Gewichtung, relative Rangfolge (Quantifizierung der Unterschiede zwischen verschiedenen Klassifizierungen möglich) • Verminderte Generalisierung	• Keine Quantifizierung von Gefahrenfolgen (Anzahl Todesfälle, Ausmaß Sachschäden etc.)
Quantitative Methoden	• Deutlich geringere Subjektivität • Detailreiche Informationen über potenzielle Schäden o. Verluste • Breitere Anwendbarkeit der Ergebnisse	• Umfangreiche Datenverfügbarkeit notwendig • Komplexe Anwendung

Gewisse Vor- und Nachteile gibt es auch bei Methoden, die verschiedene Naturgefahren als einzelne Prozesse ansehen bzw. diese lediglich aufsummieren vs. Methoden, die Naturgefahren als interagierende Prozesse ansehen, auch zu erkennen in Tabelle 5. Multilayer single-hazard Ansätze haben zwar den Vorteil, dass diese simpler in der

Umsetzung sind, laut Ming et al. (2022, S. 2) besteht dafür allerdings die Limitation, dass „the physical interaction between the contributing hazards, i.e. the impact of one hazard on the other hazard(s) [...], is either neglected or taken into account using over-simplified approaches, e.g. by spatially overlying hazard components without proper consideration of the underlying complex interacting processes“. Dies kann dazu führen, dass Katastrophenrisiken unterschätzt werden (Gill und Malamud 2016, S. 659). Bei Multi-Risikoanalysen besteht diese Limitation nicht, weshalb diese das potenzielle Gesamtrisiko mehrerer Naturgefahren und deren Wechselwirkungen quantifizieren können, was hilfreich für die Entscheidungsfindung und Entwicklung von Notfallplänen ist. Allerdings sind Multi-Risikoanalysen dadurch sehr vielschichtig und bringen daher, je nach angewendeter Methode, verschiedene Herausforderungen mit sich (Kappes et al. 2012, S. 1953; Schmidt et al. 2011, S. 1170).

Für Interaktionsmatrizen gelten dabei die gleichen Nachteile wie bei den qualitativen bzw. semi-quantitativen Methoden. Vorteile sind allerdings die Skalierbarkeit, eine Anwendbarkeit bei nur gering vorhandener Datenmenge sowie die Möglichkeit große Mengen multidisziplinärer Informationen darzustellen (Ciurean et al. 2018, S. 10). Außerdem spielt auch hier wieder das Problem der Subjektivität eine Rolle.

Andere Ansätze der Multi-Risikoanalysen, wie die probabilistischen grafischen Modelle, arbeiten objektiver. Dazu zählen Event Trees, bei denen sich, für einen Ansatz der Multi-Risikoanalyse, die Komplexität zudem in Grenzen hält. Außerdem besteht die Möglichkeit qualitative und quantitative Daten einzubinden, sodass auch partizipatorische Ansätze möglich sind. Nachteil ist dabei allerdings, dass dessen Struktur begrenzt ist, nicht-lineare Prozesse nur bedingt erfasst werden können und Event Trees nur einen Startpunkt haben können (Terzi et al. 2019, S. 767; Tsiplakidis und Photis 2019, S. 414). „[F]or that reason they can not handle scenarios with more than one primary event which can be possible in multihazard risk assessment“ (Tsiplakidis und Photis 2019, S. 415). Zudem kommt, dass die Anwendung nur bei größeren Maßstäben möglich ist, da ansonsten riesige Mengen an Daten gebraucht werden würden (Kappes et al. 2010, S. 355). Bayesian Networks, der zweite in Kapitel 2.4.4 vorgestellte Ansatz der probabilistischen grafischen Modelle, können Zuverlässigkeits- als auch Kausalitätsbeziehungen modellieren und sind besonders effektiv wenn eine Vielzahl an Variablen vorliegt. Allerdings kann die Komplexität schnell überhand nehmen und eine große Menge an Daten benötigt werden. Außerdem ist die zeitlich-dynamische Integration eine Schwäche der Bayesian Networks, wobei auch die steigende Rechenzeit zum Problem werden kann (Terzi et al. 2019, S. 765; Tilloy et al. 2019, S. 17).

Eine kürzere Rechenzeit sowie eine höhere Genauigkeit bei der Identifizierung und Bewertung von Multi-Risiken gegenüber den klassischen Ansätzen, sind wiederum Vorteile der Machine-Learning-Ansätze, die in den letzten Jahren vermehrt zum Einsatz kommen. Zudem sind diese gänzlich unabhängig von Expert*innenwissen. Nachteil ist allerdings auch hier wieder die hohe benötigte Datenmenge (Nachappa et al. 2020, S. 10; Zhang et al. 2023, S. 2).

Tabelle 5: Vor- und Nachteile Multi-Layer- vs. Multi-Risikoanalyse.
(Quelle: Eigene Darstellung)

Methode	Vorteile	Nachteile
Multi-Layeranalyse	• Einfache Anwendung	• Keine Berücksichtigung von Wechselwirkungen • Risiken können unterschätzt werden • Vulnerabilität kann erhöht werden • Managementprioritäten können verzerrt werden
Multi-Risikoanalyse	• Wechselwirkungen werden berücksichtigt • Realistische Einschätzung von Risiken • Aussagekräftig für Entscheidungsfindung und Entwicklung von Notfallplänen	• Komplexe Anwendung

Es ist wichtig zu betonen, dass die Wahl der Methode (qualitativ, semi-quantitativ oder quantitativ bzw. Multi-Layeranalyse oder Multi-Risikoanalyse) für Gefahren- und Risikoanalysen stark vom spezifischen Anwendungsfall abhängt. Jede Methode bringt ihre eigenen Vor- und Nachteile mit sich, die berücksichtigt werden müssen, um eine Analyse effektiv und zielführend durchzuführen zu können. Bei der Bewertung der verschiedenen Methoden ist es demnach entscheidend, die Anforderungen, Zielsetzungen und Kapazitäten der jeweiligen Studie bzw. die Gegebenheiten des betrachteten Gebiets zu berücksichtigen. Beispielsweise könnten quantitative Ansätze, die auf umfangreichen Daten basieren, in Regionen mit einer reichen Datengrundlage zu sehr guten Ergebnissen führen. Auf der anderen Seite können qualitative oder semi-quantitative Ansätze in Gebieten mit begrenzter Datenverfügbarkeit eine nützliche Alternative sein. Sie ermöglichen es, Expert*innenwissen in die Analyse einzubeziehen, was je nach Anforderungen von Vorteil sein kann (Kappes et al. 2012, S. 1953).

2.5 Forschungsstand zu Gefahren-, Expositions- und Risikoanalysen

Aufgrund der stetig wachsenden Bedeutung von (Multi-)Risikoanalysen gibt es bereits zahlreiche Studien, die sich damit befassen und verschiedene Ansätze verfolgen. Viele Forschungsanstrengungen konzentrieren sich dabei auf die Identifizierung und Aggregation mehrerer Gefahrenarten mittels quantitativer und semiquantitativer Ansätze (Gallina et al. 2016, S. 126). Eine der ersten Risikobewertungen von Naturgefahren auf globaler Ebene haben dabei Dilley et al. (2005) durchgeführt, wobei geografische Gebiete mit dem höchsten Risikopotential für Naturkatastrophen identifiziert wurden. Die dieser Studie zugrunde liegenden Daten reichen zwar nicht aus, um das absolute Risikoniveau einer bestimmten Gefahr oder Gefahrenkombination zu verstehen, allerdings können Gebiete identifiziert werden, in denen ein relativ höheres Risiko für Einzel- oder Mehrfachgefahren besteht (Dilley et al. 2005, S. 1).

Seit der Veröffentlichung von Dilley et al. (2005) sind zahlreiche weitere Risikobewertungen von Naturgefahren erschienen. Viele davon ebenfalls mit globaler Ausdehnung. Ward et al. (2020) fassen über 50 zwischen 1984 und 2020 erschienenen Veröffentlichungen zu diesem Thema, unterteilt in die verschiedenen global betrachteten Naturgefahren, in ihrem Review-Paper zusammen. Dabei lassen sich Unterschiede und Gemeinsamkeiten über die Studien hinweg feststellen. Gemeinsam haben die vorgestellten Studien, dass in fast allen Fällen eine explizite Darstellung der beiden Risikoelemente Gefahrenintensität und/oder -wahrscheinlichkeit sowie der Exposition erfolgt. Das dritte Risikoelement, die Vulnerabilität, wird bei ungefähr zwei Dritteln der Studien spezifisch benannt. Auf eine Dynamik dieser Elemente wird vor allem in Studien bezüglich hydrologischen, klimatologischen und meteorologischen Naturgefahren eingegangen und weniger in Studien zu beispielsweise geologischen Naturgefahren, was damit zu erklären ist, dass Zukunftsprognosen bei einem klimawandelbezogenen Schwerpunkt von hoher Wichtigkeit sind und dieser Schwerpunkt insbesondere bei Studien zu den zuerst genannten Naturgefahren vorliegt. Hier wird oft gleichzeitig der Einfluss des Klimawandels auf das bestehende und zukünftige Risiko untersucht. Bezüglich Risikoindikatoren ist zu erkennen, dass hierbei die Zahl der betroffenen Personen am meisten herangezogen wird (in 59 % der betrachteten Studien), gefolgt von den direkten wirtschaftlichen Schäden (44 %), Todesfällen (26 %) und dem betroffenen BIP (24 %). Die verwendeten Analysemethoden lassen sich in probabilistisch und nicht probabilistisch unterteilen, wobei diese je nach betrachteter Naturgefahr in ganz unterschiedlichem Maß zum Einsatz kommen (Ward et al. 2020, S. 1082ff.). Bei Dürren, Vulkanen und Erdbeben kommen bislang ausschließlich nicht-probabilistische Ansätze zum Einsatz, bei Überschwemmungen sowie Erdbeben geht die Tendenz in den letzten Jahren hin zu probabilistischen Ansätzen, wobei

probabilistisch in diesem Zusammenhang durch Ward et al. (2020, S. 1084) wie folgt definiert wird: „[P]robabilistic refers to studies that assess expected annual impacts by integrating across return periods based on a probabilistic stochastic event set“. Bei Risikoanalysen bezüglich der Naturgefahren tropische Zyklone und Waldbrände werden beide Ansätze gleichermaßen genutzt. Werden die verwendeten Daten und deren Auflösung über die Studien hinweg betrachtet, lässt sich feststellen, dass, mit einzelnen Ausnahmen, mit der Aktualität der Studie ebenso die Auflösung der Risikoanalysen zunimmt. Zudem lässt sich erkennen, dass bestimmte Datensätze besonders häufig verwendet werden. So wären das für die Exposition beispielsweise Rasterdaten zur Bevölkerung und dem Bruttoinlandsprodukt (BIP). Datensätze zur Repräsentation der Vulnerabilität sind beispielsweise Intensitäts-Schadens-Funktionen oder das Verhältnis von betroffenem BIP zu gemeldeten Verlusten bzw. betroffener Bevölkerung zu gemeldeten Todesfällen. Die Bandbreite der verwendeten Datensätze ist hier recht umfangreich (Ward et al. 2020, S. 1082ff.).

Um einige Beispiele der von Ward et al. (2020) untersuchten Studien zu nennen: Alfieri et al. (2017) haben die Häufigkeit und das Ausmaß von Flussüberschwemmungen und deren Auswirkungen bezüglich verschiedener repräsentativer Konzentrationspfade untersucht. Dazu wurde ein Kaskadenmodell herangezogen, das Simulationen von hydrologischen, hydraulischen und sozioökonomischen Auswirkungen umfasst. Djordjevic et al. (2016) haben die stärksten und am wenigsten gefährdeten Länder der Welt bezüglich Erdbeben basierend auf dem Datensatz *Zones of probable maximum earthquake intensity* des Umweltprogramms der Vereinten Nationen ermittelt. Carrão et al. (2016) haben das Dürreisiko für den Zeitraum 2000-2014 mit einer räumlichen Auflösung von 0,5° bewertet. Dabei wurde die Dürregefahr aus einer Analyse der historischen Niederschlagsdefizite abgeleitet, die Exposition aus der Aggregation von Rasterindikatoren für Bevölkerungs- und Viehdichte, der Landnutzung Ackerland und Wasserstress und die Vulnerabilität aus verschiedenen sozialen, wirtschaftlichen und infrastrukturellen Indikatoren. Meng et al. (2015) analysieren das globale Waldbrandrisiko auf der Grundlage der MODIS-Waldbrandprodukte quantitativ. Dabei wurde das Auftreten von Waldbränden als Indikator für die Gefahr an sich gesehen und die durchschnittliche verbrannte Fläche pro Waldbrand als Indikator für die Exposition herangezogen. Erstellt wurde zudem eine globale Karte des Waldbrandrisikos mit einer räumlichen Auflösung von 0,1°.

Die Veröffentlichungen, die von Ward et al. (2020) beleuchtet wurden, betrachten häufig nur eine einzelne Naturgefahr und die damit zusammenhängenden Risiken. Im Review Article *Challenges of analyzing multi-hazard risk: a review* identifizieren und beschreiben Kappes et al. (2012), im Gegensatz dazu Studien mit einem multi-hazard-risk Ansatz und welche Herausforderungen, im Zuge dieser Art der Risikoanalyse auftreten

können. Multi-hazard risk Analysen sind im Vergleich zum Feld der Einzelrisikoanalysen noch ein relativ neues Forschungsfeld. Aufgrund dessen gibt es hier, im Gegensatz zur Einzelrisikoanalyse, noch keine etablierte standardisierte Herangehensweise, um diese Art der Analyse durchzuführen. Außerdem fehlt es an historischen Erfahrungen bezüglich des Umgangs mit möglicherweise auftretenden Problemen, was ebenfalls eine Herausforderung darstellen kann (Kappes et al. 2012, S. 1927). Zwei Schwierigkeiten, die bei der Entwicklung von neuen Methoden im Bereich der multi-hazard risk Analysen entstehen, werden von Kappes et al. (2012, S. 1929) wie folgt benannt:

„(1) differing process characteristics so that it becomes difficult to compare multiple hazards [...]

(2) the existence of relations and interactions between hazards”

Das erste Problem, wobei bei verschiedenen Naturgefahren unterschiedliche Messweisen und Referenzeinheiten verwendet werden, wird in vorliegenden Veröffentlichungen bislang vorwiegend damit gelöst, Gefahren zu klassifizieren oder Indizes zu entwickeln (s. auch Kapitel 2.4). Ein Beispiel für eine solche Klassifizierung von Kunz und Hurni (2008) aus den Schweizer Richtlinien zur Analyse und Bewertung von Naturgefahren, wurde bereits in Kapitel 2.4.1 vorgestellt. Einen ähnlichen Ansatz verfolgen Thierry et al. (2008), die eine Bedrohungsmatrix mit den Komponenten Häufigkeit, Intensität und Ausdehnung bezüglich der des Lavastroms ausgesetzten Gebiete des aktiven Vulkans Kamerunberg entwickelt haben. Dabei wurden fünf Gefahrenklassen zwischen *negligible* und *very high* erstellt, die die Stärke der Gefährdung anzeigen (Thierry et al. 2008, S. 437). Auch im Rahmen des im Jahr 2007 abgeschlossenen ARMONIA Projekts der EU, dessen Ziel es war „to provide the EU with a set of harmonised methodologies for producing integrated risk maps to achieve effective spatial planning procedures in areas prone to natural disasters in Europe“, wurde ein Klassifikations-Ansatz vorgestellt, der die Gefahren bezüglich ihrer Intensität in *low*, *medium* und *high* einteilt (Europäische Kommission o.J., o.J.; Kappes et al. 2012, S. 1929). Die bereits erwähnte Veröffentlichung von Dilley et al. (2005) bedient sich zur multiplen Gefahrendarstellung eines *Simple Multihazard Index*, der auf der Eintrittswahrscheinlichkeit der Naturgefahren sowie Expositionsdaten beruht. Dieser gibt die Anzahl der vorkommenden Gefahren in einer Gitterzelle wieder, die als vergleichsweise bedeutsam betrachtet werden (Dilley et al. 2005, S. 47).

In den genannten Studien wird allerdings die Interaktion der verschiedenen Naturgefahren übergangen. Dieser Herausforderung, der Existenz von Beziehungen und Wechselwirkungen zwischen Naturgefahren, stellen sich eine begrenzte Zahl weiterer Publikationen. Allerdings fehlt auch hier bisher ein einheitlicher konzeptioneller Ansatz als auch

eine allgemein gebräuchliche Terminologie (Kappes et al. 2012, S. 1935). Erwähnenswerte Publikationen mit dem Ansatz einer Interaktionsmatrix sind hier die von Tarvainen et al. (2006) und Pippo et al. (2008). Tarvainen et al. (2006, S. 84) fassen dabei 15 verschiedene Gefahrenarten in der Interaktionsmatrix zusammen, indem jeweils angegeben wird, ob ein Einfluss von einer Gefahrenart auf eine andere Gefahrenart besteht oder nicht, wohingegen Pippo et al. (2008, 459f.) eine deskriptive Interaktionsmatrix nutzen und die Interaktionen zwischen sechs verschiedenen Gefahrenarten, also 30 interagierende Elemente, an der Küste in Nordkampanien (Italien), jeweils kurz beschreiben. Damit die Stärke der verschiedenen Interaktionen auch quantitativ festgehalten wird, werden Werte von null bis vier vergeben, wobei null für „none“ und vier für „critical“ steht. Den Ansatz eines Event Trees nutzen hingegen unter anderem Newhall und Hoblitt (2002) zur Einschätzung von Gefahr und Risiko aus vulkanischen Aktivitäten und der Wahrscheinlichkeit möglicher Folgen: „Their nine stage event tree [...] follows a logical discrete process from a primary event to final results that reflect vulnerability. [...] Probabilities of each event are calculated by exploiting the theorem of conditional probabilities in conjunction with the Bayes’s rule“ (Tsiplakidis und Photis 2019, S. 413).

Nachdem eine Bandbreite an verschiedenen Ansätzen und Studien zum Thema Gefahren-, Expositions- und Risikoanalysen bezüglich Naturgefahren betrachtet wurde, lässt sich sagen, dass sich der in dieser Arbeit zu replizierende Gefahrenindex, in dem Sinne von den bislang betrachteten Studien abhebt, dass bezüglich der verwendeten Daten eine globale Datenkonsistenz gegeben ist. So ist es möglich, den Index auf eine Vielzahl von geografischen Kontexten auszuweiten und Klima- und Umweltdaten auch in geografisch abgelegenen Gebieten zuverlässig, kostengünstig und standardisiert zu erfassen (Owen et al. 2023, S. 1). Mithilfe der Indexberechnung lässt sich so das Gefahrenpotential innerhalb eines Gebiets ermitteln, als auch der Unterschied in der Höhe der Gefahr im Vergleich zu umliegenden Gebieten nachvollziehen (Owen et al. 2023, S. 5).

3 Multi-Risk-Tools

Neben einer Fülle an Studien, die sich mit Gefahren-, Expositions- und (Multi-)Risikoanalysen befassen, wurden in den letzten Jahren auch eine Vielzahl an Software-Tools entwickelt, mit denen die Risiken von Naturgefahren quantifiziert und beispielsweise die Anzahl der exponierten Gebäude, die absoluten ökonomischen Verluste oder die jährlich erwarteten Todesfälle berechnet werden können. Dabei werden in die Software-Tools häufig GIS-Anwendungen integriert. Diese Werkzeuge bieten nicht nur eine effiziente Möglichkeit, komplexe Analysen zu Naturgefahren und möglichen Folgen durchzuführen, sondern ermöglichen auch eine präzisere Bewertung und Planung von Maßnahmen zur Risikominderung. Einige dieser Tools sind zudem frei zugänglich und nutzbar, also Open Access. In den letzten zwei Jahrzehnten ist die Qualität und Verfügbarkeit von Open-Access- und Open-Source-Software deutlich gestiegen, wodurch diese Instrumente einer breiteren Nutzer*innenbasis zugänglich sind (The World Bank 2014, S. 3; Tsiplakidis und Photis 2019, S. 409). Einige dieser Tools sollen in diesem Kapitel vorgestellt werden.

3.1 Verfügbare Open Source Tools zur Gefahren- und (Multi-)Risikoanalyse

RiskScape ist die erste Open Source Software zur Analyse und Bewertung von Risiken im Zusammenhang mit Naturgefahren, die vorgestellt werden soll. Das dazugehörige Forschungsprogramm wurde bereits im Jahr 2004 vom National Institute of Water and Atmospheric Research (NIWA) und vom geowissenschaftlichen Forschungsinstitut GNS Science in Neuseeland gegründet, woraufhin die Veröffentlichung der ersten Version der *RiskScape*-Software im Jahr 2006 erfolgte. Zwischenzeitlich wurde die Software 2017 eingestellt, da diese als veraltet und schwer zu überarbeiten galt, bevor ab dem Jahr 2018 mit Mitteln der staatlichen Institution EQC Toka Tū Ake für Katastrophenforschung und -versicherung eine neue Version entwickelt wurde (GNS Science o.J., o.S.).

Mit *RiskScape* 2.0 können potenzielle Folgen und Verluste von Naturgefahrensszenarien simuliert werden. Die benötigten Daten sind nicht hartkodiert, sondern müssen von den Benutzer*innen übergeben werden. So kann bei unterschiedlichen Anforderungen mit den passenden gefahren- und ortsspezifischen Daten gearbeitet werden. Das Design des Modells, das in der Software implementiert ist, beruht auf der klassischen Einflussgrößen von Risiko, also Gefahr, Exposition und Vulnerabilität (GNS Science o.J., o.S.):

$$R = f_c(H_i, E, V_i)$$

Formel 1: R (Risiko) als Funktion (fC) der Folgen des Gefahrenereignisses (H), das sich auf exponierte Elemente auswirkt (E). Folgen ergeben sich aus der Vulnerabilität (V) gegenüber des Gefahrenereignisses (i). (Quelle: Paulik et al. (2023, S. 1074))

Dementsprechend müssen Gefahren- und Expositionsdaten in üblichen Dateiformaten der GIS-Raster- oder Vektordaten sowie Vulnerabilitätsmodelle übergeben werden, um die Software nutzen zu können. Zusätzlich können weitere optionale Inputdaten (Area und Ressource Layer) übergeben werden. In weiterer Folge können dann Schäden und Verluste, beispielsweise die Wahrscheinlichkeit von Gebäudeschäden, Schäden an der Infrastruktur, Personenschäden oder Todesfällen berechnet werden. Die Ergebnisse lassen sich unter anderem als Karten, Graphen oder Tabellen darstellen. Welche weiteren Schritte zwischen der Übergabe der Daten und der Ausgabe der Ergebnisse liegen, ist in Abbildung 10 schematisch zu erkennen. Die Zwischenergebnisse aus den einzelnen Schritten dienen dabei als Eingabe für den darauffolgenden Schritt (GNS Science o.J., o.S.; Paulik et al. 2023, S. 1074).




Abb. 10: Schematische Darstellung der Modell-Pipeline von RiskScape.
(Quelle: Paulik et al. (2023, S. 1078))

Nach der Übergabe der Daten gibt es den optionalen Schritt des Geoprocessings bei dem die Daten vorbereitet und angepasst werden, bevor diese in das Modell einfließen. So kann beispielsweise in den Daten nach bestimmten Attributen gefiltert werden, exponierte Objekte können mit einem Buffer um einen angegebenen Abstand vergrößert werden oder es können mit Hilfe von räumlichen Filtern neue Expositionslayer erstellt werden, wenn das Forschungsinteresse z.B. nur für eine eingeschränkere Region besteht. Beim Spatial sampling werden die verschiedenen Layer, also die Attribute des

Gefahrenlayers – und gegebenenfalls die optionalen Layer – mit den Objekten aus dem Expositionslayer, räumlich verknüpft. Falls ein Element von der Gefahr aus dem Gefahrenlayer betroffen ist, wird die entsprechende Intensität ermittelt (Paulik et al. 2023, S. 1079). Im nächsten Schritt, der Consequence analysis werden die Auswirkungen der Exposition eines Elements in ihrem Ausmaß mit Hilfe der übergebenen Vulnerabilitätsmodelle bestimmt. Im letzten Schritt vor der Ausgabe der Ergebnisse, der Risk Analysis, wird das Risiko berechnet, indem optional probabilistische Modelle angewendet werden können (Paulik et al. 2023, S. 1083f.). Weitere detailliertere Informationen zur RiskScape Software und der Implementation finden sich in Paulik et al. (2023).

Ein GIS-basiertes Tool zur Risikomodellierung bezüglich der Naturgefahren Erdbeben, Überschwemmungen, Hurricanes und Tsunamis ist *Hazus*, das von der Federal Emergency Management Agency (FEMA) der USA entwickelt wurde. Mit diesem Tool lassen sich Gebiete mit hohem Risiko identifizieren und die physischen, wirtschaftlichen und sozialen Auswirkungen der Naturgefahren abschätzen, allerdings ist keine gleichzeitige Auswertung von Schäden mehrerer Gefahren und dessen Wechselwirkungen möglich. Bei den physischen Auswirkungen geht es um Folgen wie Schäden an Gebäuden oder Infrastruktur, bei den ökonomischen Auswirkungen können beispielsweise ökonomische Verluste wie verlorene Arbeitsplätze oder Reparaturkosten quantifiziert werden und bei den sozialen Auswirkungen vertriebene Haushalte oder die Anzahl der von den Naturgefahren betroffenen Personen (FEMA o.J.c, o.S.; Gallina et al. 2016, S. 126).

Im Gegensatz zum Tool RiskScape, müssen Benutzer*innen von Hazus keine eigenen Daten übergeben, um das Tool nutzen zu können, da Datensätze für diverse Abfragen zur Verfügung gestellt werden. Die Möglichkeit, eigene Daten zu verwenden, die für den eigenen Verwendungszweck möglicherweise besser geeignet sind, besteht dennoch. Hazus besteht aus vier verschiedenen Modellen: Hazus Earthquake Model, Hazus Tsunami Model, Hazus Flood Model und Hazus Hurricane Model. Dabei verwenden alle Modelle Informationen zu Gebäuden, Infrastruktur und Bevölkerung, als auch Daten zum Ausmaß und zur Intensität der Naturgefahr sowie Schadensfunktionen, die die Auswirkungen von Katastrophen hinsichtlich der Intensität der Gefahr quantifiziert (FEMA o.J.c, o.S.). Abbildung 11 zeigt beispielhaft den Aufbau des Hazus Flood Models. Dabei muss zuerst das Untersuchungsgebiet definiert werden sowie daraufhin das Gefahrenszenario. Danach werden exponierte Elemente wie Gebäude oder Infrastruktur in das Modell integriert, woraufhin beispielsweise die wirtschaftlichen Verluste oder der Bedarf an Notunterkünften sowie der verursachte Schaden berechnet wird (FEMA 2022, S. 2-2). Genauere Informationen zu den Modellen finden sich in den Benutzer*innenhandbüchern sowie den technischen Bedienungsanleitungen von Hazus, s. FEMA (o.J.a, o.S.).




Abb. 11: Schematische Darstellung der Methodik des Hazus Flood Models.
(Quelle: FEMA (2022, S. 2-2))

Abgesehen von Hazus stellt die FEMA das Online Tool *National Risk Index* zur Verfügung, das auf einer interaktiven Karte der USA basiert. Mit Hilfe von diesem lässt sich der Risk Index für 18 Naturgefahren auf dem County oder Census Tract Level ablesen, als auch das Ausmaß der erwarteten jährlichen Verluste, die soziale Vulnerabilität und die Widerstandsfähigkeit von Gemeinden in klassifizierter Form (very low bis very high). Diese Informationen können gesammelt für alle Naturgefahren ausgegeben werden, als auch separat für eine einzelne ausgewählte Naturgefahr. Zudem können Daten exportiert werden, um diese in anderen Programmen zu analysieren (FEMA o.J.b, o.S.). Die Risikoberechnung beruht bei der Anwendung auf folgender vereinfachter Gleichung:

$$Risk = Expected Annual Loss \times Community Risk Factor$$

$$where Community Risk Factor = f\left(\frac{Social Vulnerability}{Community Resilience}\right)$$

Formel 2: Vereinfachte Gleichung zur Berechnung des Risikos des National Risk Index.
(Quelle: FEMA (2023, 3-1))

Eine Darstellung der Benutzeroberfläche des Tools findet sich in Abbildung 12. Weitere Informationen zum National Risk Index sind in FEMA (2023) zu finden.




Abb. 12: Interaktive WebMap des National Risk Index der USA.
(Quelle: FEMA (o.J.a, o.S.))

Die erste Version der Open Source Risikomodellierungsplattform *CAPRA* (Comprehensive Approach to Probabilistic Risk Assessment) wurde im Jahr 2008 als Kooperation zwischen dem *Center for Coordination of Natural Disaster Prevention in Central America* (CEPRENAC), der *United Nations International Strategy for Disaster Reduction* (UNISDR), der *Inter-American Development Bank* (IADB) und *The World Bank* veröffentlicht. Das Ziel der Initiative war es dabei umfassende Modelle von Naturgefahren, Exposition und Vulnerabilität zu integrieren und Risikobewertungen durchzuführen, um Ländern in Mittelamerika passende Informationen und Instrumente zur Verfügung zu stellen, um Naturereignisse besser verstehen können. *CAPRA* wurde seit der ersten Veröffentlichung stetig weiterentwickelt. Die aktuelle Version besteht aus 14 verschiedenen Softwaremodulen, wobei acht verschiedene Naturgefahren miteinbezogen werden: Erdbeben, Tsunamis, Erdrutsche, Vulkanausbrüche, tropische Wirbelstürme, konvektive Niederschläge, Überschwemmungen und Dürren. Die Module gliedern sich in Module zur Betrachtung und Bewertung der Gefahren an sich, Module bezüglich Exposition und Vulnerabilität sowie Module zur Risikobewertung und zum Datenmanagement (Bernal und Cardona 2018, S. 1; *CAPRA* o.J., o.S.). Eine Übersicht aller 14 Module findet sich in Abbildung 13.




Abb. 13: Kernmodule von CAPRA.
(Quelle: Bernal und Cardona (2018, S. 2))

Module bezüglich verschiedener Naturgefahren sind beispielsweise das Erdbeben- und Tsunami-Gefahrenmodul CRISIS 2015, womit probabilistische seismische Gefahrenanalyse durchgeführt werden können, Landslide Hazard Mapper, das Werkzeuge für die probabilistische Bewertung der Gefahr von Erdrutschen bereitstellt und Drought Pro, mit dem das Risiko für Dürren in der Landwirtschaft ermittelt werden kann. Module bezüglich der Exposition und Vulnerabilität sind der Exposure Editor, der Werkzeuge für die Erstellung von Datenbanken für geografische Expositionen bietet und Vulnerability Studio, mit dem sogenannte Vulnerability Functions erstellt und bearbeitet werden können. Mit CAPRA-GRM kann letztlich das gesamte Risiko probabilistisch berechnet werden, indem eine Risikokurve, mit der die Wahrscheinlichkeit ermittelt wird, dass ein Schaden einer bestimmten Höhe innerhalb eines bestimmten Zeitraums überschritten wird, für die unterstützten Naturgefahren berechnet wird. Dabei können auch Analysen bezüglich mehrerer Gefahren durchgeführt werden, indem die Verluste aus den verschiedenen Gefahren aggregiert werden. Außerdem können die durchschnittlichen jährlichen oder die maximalen Verluste berechnet werden (Bernal und Cardona 2018, S. 2-10).

Zur Verfügung gestellt wird zudem *CAPRA-GIS*, eine GIS-Anwendung mit der geografische Vektor- und Rasterdaten visualisiert und Wahrscheinlichkeiten sowie Risiken bezüglich Naturgefahren berechnet werden können. Verschiedene Dateien zu der Naturgefahr (z.B. Informationen zu Intensität und Frequenz), der Exposition (Georeferenzinformationen zu Gütern) und der Vulnerabilität (Informationen zum Verhalten der exponierten Strukturen bei Eintreten der ausgewählten Gefahren) bilden ein CAPRA GIS-Projekt und werden in der Anwendung miteinander verknüpft. Auch alle CAPRA Module haben

innerhalb der GIS-Anwendung eine grafische Benutzeroberfläche (Ordaz und Salgado 2017, S. 10f.). Ein Einblick in die grafische Benutzeroberfläche von CAPRA-GIS findet sich in Abbildung 14. Weitere Informationen zur aktuellen Version der CAPRA Software sind Bernal und Cardona (2018) zu entnehmen.




Abb. 14: Die grafische Benutzeroberfläche von CAPRA-GIS.
(Quelle: Ordaz und Salgado (2017, S. 11))

Weitere Open Source und Open Access Softwarepakete zur Risikobewertung sind beispielsweise *InaSafe* (QGIS Plugin zur Erstellung von Szenarien für die Auswirkungen von Naturgefahren), *OpenQuake* (Erdbebengefährdungs- und Risikomodellierung), *Kalypso* (Berechnung von Hochwassergefahren und -risiken) oder *TCRM* (Ereignissimulator für die Gefahr tropischer Wirbelstürme) (The World Bank 2014, S. 13). Eine Vorstellung und unabhängige Beurteilung dieser und mehr Tools finden sich in The World Bank (2014). Allerdings wird darin aufgrund des Veröffentlichungsjahrs meist nicht auf die aktuellste Version der jeweiligen Anwendung eingegangen.

3.2 Vorteile und Limitationen bisheriger Tools

Je nach Anwendungszweck sind manche Tools zur Gefahren- und Risikoanalysen mehr und manche weniger geeignet, da bei verschiedenen Projekten unterschiedliche Anforderungen an die Tools bestehen und spezifische Herausforderungen mit bestimmten Tools besonders gut überwunden werden können. Auch die verschiedenen Limitationen der einzelnen Tools sollten bei der Auswahl einer Software in Betracht gezogen werden. Auf die

Vorteile und Limitationen der in Kapitel 3.1 vorgestellten Tools, soll im Folgenden eingegangen werden.

RiskScape erweist sich als nützliches und flexibles Tool für die Risikoanalyse. Es kann dabei nicht nur dazu genutzt werden, das Katastrophenrisikomanagement in Neuseeland zu unterstützen, sondern ist ebenso für eine Vielzahl von weiteren Verwendungszwecken, über die Grenzen von Neuseeland hinaus, äußerst nützlich, da die Risikoanalysen stark auf den eigenen Verwendungszweck anpassbar sind und auch die Eingabedaten frei ausgewählt sowie vorverarbeitet werden können. Dabei können die Eingabedaten u.a. zur Gefahr und Exposition aus einer Vielzahl unterschiedlicher Formate, z.B. .csv, .shp, .tif, .asc, .hdf5, .nc, .geojson und .kml, zusammengeführt und zahlreiche Statistik- und Datenmanipulationsoperationen auf diese angewendet werden (RiskScape o.J., o.S.; Scheele et al. 2020, S. 1). Damit einher geht allerdings auch der Nachteil, dass bei Übergabe von Daten mit schlechter Qualität die Ergebnisse ebenso mangelhaft sind. Es werden also beispielsweise gute Daten zu Gütern benötigt, um die Verluste zuverlässig berechnen zu können. Einen solchen vollständigen Datensatz zur Verfügung zu haben, kann allerdings oft eine Herausforderung sein. Ebenso müssen die Vulnerabilitätsmodelle, die übergeben werden müssen, passend für den Verwendungszweck sein (Deligne et al. 2017, S. 18). Bei all dem kann es generell zu dem Problem kommen, dass keine passenden Daten gefunden werden oder diese nicht frei verfügbar sind. RiskScape kann dann nicht genutzt werden, da bislang keine Default-Daten zur Verfügung gestellt werden, die in solch einem Fall verwendet werden könnten. Allerdings ist in Aussicht, dass sich dies zukünftig ändert und beispielsweise nationale Datensätze, wie der nationale LINZ Gebäudedatensatz, innerhalb von RiskScape zur Nutzung bereitgestellt werden (Woods 2021, o.S.).

RiskScape ermöglicht zwar die Evaluierung mehrerer Gefahren gleichzeitig, was ein deutlicher Vorteil gegenüber anderen Tools ist, allerdings werden dabei keine zeitlich variierenden oder kaskadierenden Auswirkungen berücksichtigt. Zudem gibt es generell Einschränkungen bei der Bewertung von Schäden, da zwar die direkten Schäden gemessen werden können, z.B. der Schaden an kritischer Infrastruktur, wie sich dies allerdings weiter auswirkt – beispielsweise, dass wegen eines beschädigten Krankenhauses, andere Krankenhäuser verstärkt belastet werden – geht aus der Schadensanalyse nicht hervor (Deligne et al. 2017, S. 18).

Bislang ist RiskScape ein Tool, das nur über die Kommandozeile verwendet werden kann. Eine grafische Benutzeroberfläche gibt es nicht. So werden grundlegende Programmierkenntnisse für die Nutzung vorausgesetzt, was den Zugang zum Tool stark

einschränkt und es insbesondere für Anwender*innen ohne oder mit nur wenig Programmiererfahrung weniger zugänglich macht. Allerdings soll in Zukunft eine webbasierte grafische Benutzeroberfläche entwickelt werden, um die Modell- und Datenverwaltung so visuell zu unterstützen und eine breitere Anwendung des Tools zu ermöglichen (Paulik et al. 2023, S. 1088).

Im Gegensatz dazu hat Hazus dadurch, dass es auf einem GIS basiert und in einer Desktop-Anwendung verwendet wird, ein sehr nutzer*innenfreundliches grafisches Interface, das eine leichte Verwendung, auch ohne Programmierkenntnisse, ermöglicht. Allerdings ist hierbei zu beachten, dass eine kommerzielle ArcGIS Lizenz benötigt wird, um Hazus verwenden zu können. Die Software zur Risikomodellierung an sich ist zwar Open Source und auch kostenlos verfügbar, allerdings kann die Lizenzierung von ArcGIS für viele Nutzer*innen unerschwinglich teuer sei, sodass es sich bei Hazus folglich um eine open-closed Software handelt und deshalb nicht von einer breiten Nutzer*innenbasis verwendet werden kann. Zudem ist die Nutzung auf nur vier Naturgefahren – Erdbeben, Überschwemmungen, Tsunamis und Hurricanes – begrenzt (The World Bank 2014, S. 8f.). Darüber hinaus ist eine Nutzung für Anwendungsfälle außerhalb der USA nur beschränkt möglich: „[A]djusting hazard parameters and creating data inventories for areas outside the U.S. may require significant effort“ (FEMA o.J.c, o.S.).

Die Anwendung für Fälle innerhalb der USA wird dafür dadurch erleichtert, dass Datensätze für diverse Abfragen für jeden Staat zur Verfügung gestellt werden und somit nicht zwingend eigene Datensätze benötigt werden. Außerdem ist die Nutzung von Hazus nicht nur aufgrund der grafischen Benutzeroberfläche leicht verwendbar, sondern auch aufgrund der verschiedenen Analyselevel, zu erkennen in Abbildung 15, wobei auch mit dem Level *Basic* mit wenig Vorkenntnissen der Nutzer*innen erste Schätzungen bezüglich Verlusten aus verschiedenen Naturgefahren ohne großen Aufwand liefert. Gleichzeitig können Nutzer*innen mit ausgiebigen Vorkenntnissen und mehr Ressourcen, detaillierte Ergebnisse bezüglich möglicher Verluste, genaustens zugeschnitten auf das eigene Untersuchungsgebiet, berechnen lassen. Zudem sind auf der Website der FEMA ausführliche Benutzer*innen- und technische Handbücher verfügbar, die die Nutzung unterstützen und Auskunft über die Funktionsweise der Modelle geben (FEMA o.J.c, o.S.). Was allerdings nicht möglich ist und somit auch eine immense Limitation darstellt, ist die gleichzeitige Auswertung von Schäden mehrerer Gefahren und dessen Wechselwirkungen (Gallina et al. 2016, S. 126).




Abb. 15: Schematische Darstellung der verschiedenen Analyselevel von Hazus.
(Quelle: FEMA (o.J.c, o.S.))

Mit der Risikomodellierungsplattform CAPRA wiederum ist zumindest die Auswertung von Schäden mehrere Naturgefahren möglich, indem diese aggregiert werden. Allerdings werden auch hier mögliche Wechselwirkungen ignoriert (Bernal und Cardona 2018, S. 10ff.; Gallina et al. 2016, S. 126). Als Limitation wird zudem die Verwendung eher simpler Gefahrenmodelle in einigen der Module angesehen. Trotzdem liefern die Ergebnisse eine akzeptable Risikoeinschätzung und bieten eine ausreichend gute Basis für Entscheidungen. Darüber hinaus sollen in Zukunft weitere Module für Naturgefahren wie Hagelstürme oder Waldbrände hinzugefügt werden, sodass die Risiken einer breiten Reihe an Naturgefahren analysiert werden können. Die bereits vorhandenen Module werden zudem stets aktualisiert und mit den neusten Erkenntnissen aus der Wissenschaft verbessert. Dabei sollen zukünftig auch Schätzungen bezüglich des Klimawandels bei der Risikobewertung von hydrometeorologischen Gefahren eingearbeitet werden, was bislang nur bei wenigen Tools der Fall ist (Bernal und Cardona 2018, S. 12).

Mit der eigens konzipierten und kostenlos verwendbaren GIS-Anwendung CAPRA-GIS, ist die Nutzung des Tools leicht möglich, da es eine intuitive grafische Benutzeroberfläche für alle Module gibt (Ordaz und Salgado 2017, S. 10f.). Dennoch gibt es für Expert*innen die Möglichkeit, CAPRA ohne grafische Benutzeroberfläche als CAPRA Team PocketRC zu nutzen, was in der Ausführung ungefähr sechs Mal schneller ist als CAPRA-GIS (Ordaz und Salgado 2017, S. 20). Auch wenn die Entwicklung von CAPRA ursprünglich für die Risikoanalyse in Ländern in Mittelamerika ins Leben gerufen wurde, ist die Software weltweit einsetzbar. So gibt es unter anderem Anwendungsbeispiele aus Spanien, Kanada und Chile (Marulanda et al. 2022; Rincón et al. 2022; Salgado-Gálvez et al. 2014). Positiv ist zudem anzumerken, dass Risikoanalysen mit allen drei vorgestellten Software-Paketen in probabilistischer Form möglich sind.

4 Entwicklung des Gefahrenindex-Skripts

Im vorliegenden Kapitel wird zunächst auf die technischen Rahmenbedingungen und Entwicklungswerkzeuge zur Erstellung des Gefahrenindex-Skripts eingegangen. Anschließend wird der Gefahrenindex und die dahinterliegenden Berechnungen und Variablen beschrieben sowie die eingebundenen Datensätze vorgestellt.

4.1 Technische Rahmenbedingungen und Entwicklungswerkzeuge

Bevor mit der Entwicklung des Gefahren-Tools begonnen werden kann, müssen zunächst die technischen Rahmenbedingungen festgelegt und die Entwicklungswerkzeuge ausgewählt werden. Diese Auswahl wird in diesem Kapitel begründet.

4.1.1 Die Google-Earth-Engine API

Zur Entwicklung des Skripts zur Ermittlung des Gefahrenindex für einen beliebigen Ort, bestand die Notwendigkeit frei auf Klima- und geophysikalische Daten mit globaler Verfügbarkeit zuzugreifen. Aufgrund der Größe von Daten in globalem Ausmaß, musste zudem darauf geachtet werden, dass es mit der verfügbaren Hardware möglich ist, umfangreiche Berechnungen, die mit Ausführung des Skripts anfallen, durchzuführen. Unter diesen Anforderungen bietet sich die Verwendung von *Google Earth Engine* (GEE) an.

GEE ist eine cloudbasierte Plattform, die es Nutzer*innen ermöglicht Satellitenbilder und geografische Daten zu analysieren und zu visualisieren. Der Datenkatalog umfasst dabei mehrere Petabyte an Daten mit globalem Ausmaß und umfasst Aufnahmen der Erde, die mehr als vierzig Jahre zurückreichen. Zu einem Großteil besteht der Datenkatalog dabei aus Fernerkundungsbildern (z.B. gesamtes Landsat-, Sentinel-1- und Sentinel-2-Archiv), aber auch Klimaprognosen, Bodenbedeckungsdaten und andere ökologische, geophysikalische und sozioökonomische Datensätze werden zur Verfügung gestellt. Die Daten werden täglich aktualisiert, sodass Veränderungen und Trends auf globaler Ebene ermittelt werden können. Da die Infrastruktur cloud-basiert ist, können auch Analysen mit großen Datenmengen durchgeführt werden, ohne dass leistungsstarke Hardware notwendig ist. Dabei können die Analysen direkt über den webbasierten Earth Engine Code Editor durchgeführt werden. Die GEE-Funktionen können aber auch mit Hilfe der Earth Engine API direkt in andere Anwendungen oder Skripte integriert werden. Die API ist dabei für Python und JavaScript verfügbar. Eine vereinfachte Darstellung der GEE Systemarchitektur ist in Abbildung 16 zu finden (Google o.J.c, o.S.; Gorelick et al. 2017, S. 18).




Abb. 16: Vereinfachte Darstellung der Google Earth Engine Systemarchitektur.
(Quelle: Gorelick et al. (2017, S. 21))

Rasterdaten werden in GEE als sogenannte *Images* repräsentiert, die eine Methode darstellen, geografische Daten in einem zweidimensionalen Raster aus Pixeln oder Bildelementen zu speichern. Images bestehen aus einem oder mehreren Bändern, wobei Pixel in einem Band denselben Datentyp sowie dieselbe räumliche Auflösung und Projektion haben müssen. Zwischen den verschiedenen Bändern darf es allerdings im Bezug auf diese Merkmale Unterschiede geben. Ein Stack oder eine Reihe von Images werden als *Image Collection* bezeichnet. (Cardille et al. 2024, S. 20; Google o.J.d, o.S.; Gorelick et al. 2017, S. 19).

Eine Alternative zur GEE wäre beispielsweise *Sentinel Hub*, das ebenfalls cloud-basiert und über eine API zugänglich ist. Der Umfang des Datenkatalogs ist hier allerdings deutlich kleiner, sodass nicht alle benötigten Daten verfügbar gewesen wären. Hinzu kommt, dass der Umfang der erlaubten monatlichen Anfragen (beispielsweise zur Datenverarbeitung) unter der freien Version stark limitiert und somit nicht ausreichend für den Verwendungszweck ist, insbesondere da das Gefahrentool frei zur Verfügung gestellt werden soll (Sinergise Solutions o.J., o.S.). Auch von einer reinen Nutzung von geographischen Informationssystemen (GIS), wie beispielsweise *QGIS*, wurde aus verschiedenen Gründen abgesehen. Zunächst hätte die Datenbeschaffung hier manuell erfolgen müssen, was mit einem deutlichen höheren Zeitaufwand verbunden wäre und eine zukünftige Erweiterung des Tools mit aktualisierten oder neuen Datensätzen erschwert. Zudem bietet ein GIS weniger Automatisierungsmöglichkeiten, als es mit Hilfe von Python und der GEE

API der Fall ist. Außerdem werden bei der Arbeit mit einem GIS lokale Rechenressourcen genutzt, was die Verarbeitung großer Datenmengen oder komplexer Analysen deutlich verlangsamt, bzw. ab einer gewissen Größe schlicht unmöglich macht.

4.1.2 Auswahl der Programmiersprache und Entwicklungsumgebung

Da die Verwendung der API der Google Earth Engine lediglich mit Python sowie mit JavaScript möglich ist, da hier entsprechende Programmbibliotheken von Google zur Verfügung gestellt werden, war die Auswahl der Programmiersprache auf diese beiden Sprachen beschränkt (Cardille et al. 2024, S. 4). Aus folgenden Gründen wurde entschieden bei der Entwicklung eines Skripts zur Ermittlung des Gefahrenindex mit Python, anstelle von JavaScript, zu arbeiten:

- Geeignet für komplexe raumbezogene Analysen
- Python wird vermehrt im wissenschaftlichen Kontext verwendet
- Zahlreiche Programmbibliotheken zur Datenanalyse und -visualisierung (z.B. Numpy, Pandas, Geemap), die mit GEE verwendet werden können
- Benutzerfreundliche Syntax

Eine Limitation der Python API in der ersten Zeit nach der Bereitstellung von dieser war, dass keine visuellen Outputs möglich waren. Inzwischen stehen allerdings Packages zu Verfügung, die auch hier interaktives Mapping und das Visualisieren von Ergebnissen ermöglichen. Besonders hervorzuheben ist dabei das Package *geemap*, das auch im Rahmen dieser Arbeit zur Visualisierung verwendet wurde (Brandolini et al. 2021, S. 3; Wu 2020b, S. 1). Eine benutzerfreundliche Syntax ist deshalb von Vorteil, da Nutzer*innen so den Code leichter an ihre Bedürfnisse anpassen können – beispielsweise bei der Auswahl der Untersuchungsgebiete.

Als Entwicklungsumgebung wurde die webbasierte, interaktive Entwicklungsumgebung *Jupyter Notebook* gewählt. Dabei dient ein Hauptnotebook den Nutzer*innen als zentrales Skript, von dem aus alle Berechnungen gesteuert werden können. Für eine bessere Übersicht wird von diesem aus, auf in Python-Skripten (.py) definierte Funktionen, die zur Berechnung der einzelnen Gefahren-Variablen notwendig sind (s. Kapitel 4.3), zugegriffen. Die Verwendung von Jupyter Notebook in der vorliegenden Arbeit wird mit folgenden Vorteilen begründet:

- Benutzerfreundlichkeit
- Interaktivität & Ausführbarkeit von einzelnen Zellen
- Leichte Visualisierbarkeit von Daten und Ergebnissen
- Leichte Dokumentation aufgrund der Unterstützung von Markdown
- Open-Source

Insbesondere die leichte Visualisierbarkeit von Daten und Ergebnissen ist von Vorteil, da Nutzer*innen so beispielsweise ihre ausgewählten Untersuchungsgebiete auf einer Karte visuell kontrollieren können und auch ihre Ergebnisse direkt betrachten können. Außerdem können Markdown-Zellen dazu genutzt werden, den Code übersichtlich zu strukturieren sowie Code-Abschnitte, in denen User*innen den Code an ihre Bedürfnisse anpassen sollen (z.B. Wahl der Untersuchungsgebiete, Wahl der Normalisierungsgrundlage), hervorzuheben und gegebenenfalls genauer zu erläutern.

4.2 Beschreibung des Gefahrenindex

Der Gefahrenindex, der auf einem index-basierten, semi-quantitativen Ansatz beruht, zeigt an, wie hoch die Wahrscheinlichkeit des Eintritts der Naturgefahren Dürre, Überschwemmung und Erdbeben ist. Unter Dürre ist dabei laut Glaser und Erfurt (2020, S. 1183) ein „Zeitraum erheblichen Niederschlagsdefizits“, der zu Wasserknappheit führt, zu verstehen. Zu Überschwemmungen kann es wiederum bei einem Überschuss an Wasser kommen. Ein Erdbeben ist eine Massenbewegung von Felsgestein, Schutt oder Erde an einem Hang (FEMA 2023, 15-1). Zur Berechnung des Gefahrenindexes wurden elf verschiedene Variablen mit globaler bzw. nahezu globaler Datenverfügbarkeit und hoher räumlicher Auflösung, zumeist nach Owen et al. (2023), ausgewählt, die klimatische sowie geophysikalische Gegebenheiten anzeigen und Indikatoren für die genannten Naturgefahren darstellen. Eine genaue Beschreibung der ausgewählten Variablen und der dahinter stehenden Datensätze findet sich in Kapitel 4.3.

Der Gefahrenindex lässt sich für, von den Nutzer*innen ausgewählte, Untersuchungsgebiete berechnen. Für diese Untersuchungsgebiete wird jeweils der Mittelwert innerhalb der entsprechenden Grenzen der Gebiete für jeweils die einzelnen Gefahren-Variablen berechnet. Die Ergebniswerte der einzelnen Variablen werden daraufhin so normalisiert, dass die Werte zwischen null und eins liegen, wobei null keine Gefahr und eins eine hohe Gefahr für das entsprechende Naturphänomen anzeigt. Dabei wurde zur Normalisierung in den meisten Fällen folgende Formel verwendet:

$$\text{Normalisierung} = \frac{x - \min(x)}{\max(x) - \min(x)}$$

Formel 3: Normalisierung der Gefahren-Variablen.
(Quelle: Owen et al. (2023))

Lediglich bei Variablen bei denen hohe Werte eine geringere Gefahr anzeigen (PDSI, Bodenfeuchte an der Oberfläche und Spezifische Luftfeuchtigkeit (Q)), wurde mit folgender Formel umgekehrt normalisiert:

$$\text{Normalisierung} = \frac{\max(x) - x}{\max(x) - \min(x)}$$

Formel 4: Umgekehrte Normalisierung der Gefahren-Variablen.
(Quelle: Owen et al. (2023))

Da die Variablenwerte in der Regel auf der Landes-Ebene normalisiert werden, bezeichnen $\min(x)$ und $\max(x)$ dabei den minimalen und maximalen Wert innerhalb des Landes in denen die Untersuchungsgebiete liegen. Sollen Untersuchungsgebiete, welche in verschiedenen Länder liegen, miteinander verglichen werden, besteht die Möglichkeit die Werte auf der Ebene mehrerer Länder zu normalisieren. Die normalisierten Werte werden anschließend entsprechend Formel 5 summiert und durch die Variablenanzahl dividiert, um den Gefahrenindex für das jeweilige Untersuchungsgebiet zu berechnen. Der Gefahrenindex ist demnach der ungewichtete Durchschnitt der elf Variablen.

$$\text{Gefahrenindex} = \frac{\sum \text{var1} + \text{var2} \dots}{11}$$

Formel 5: Berechnung des Gefahrenindex.
(Quelle: Owen et al. (2023))

Um den Berechnungsprozess des Gefahrenindex klar darzustellen und die einzelnen Schritte erkenntlich zu machen, wurde eine schematische Darstellung diesbezüglich erstellt, die in Abbildung 17 zu finden ist.




Abb. 17: Schematische Darstellung der Berechnung des Gefahrenindex.
(Quelle: Eigene Darstellung nach Owen et al. (2023))

4.3 Variablen des Gefahrenindex

Es wurden elf verschiedene Variablen, die die Eintrittswahrscheinlichkeit für die Naturgefahren Dürre, Überschwemmung und Erdbeben anzeigen sollen, entsprechend Owen et al. (2023) zur Berechnung des Gefahrenindex einbezogen. Diese lassen sich in die Kategorien *Klima und Wetter* sowie *Geophysikalische Faktoren* einteilen.

Klima und Wetter:

- Durchschnittlicher Palmer Drought Severity Index (PDSI)
- Niederschlag: Veränderung der jährlichen Akkumulation
- Niederschlag: Interannueller Variationskoeffizient
- Niederschlag: Maximale monatliche Anomalie im März/April/Mai (P_{MAX})
- Temperatur: Jährliche maximale Oberflächentemperatur (TXx)
- Temperatur: Langfristige Anomalie (ΔT)
- Spezifische Luftfeuchtigkeit (Q)

Geophysikalische Faktoren:

- Abflussakkumulation
- Friktion
- Hangneigung
- Bodenfeuchte (Oberfläche)

Die dahinterstehenden Datensätze haben eine räumliche Auflösung zwischen $0,0008^\circ$ und $0,25^\circ$ und sind alle frei verfügbar sowie über die Google Earth Engine abrufbar. Eine Übersicht zu den einzelnen Variablen mit Informationen zum anzuzeigenden Phänomen, der räumlichen Auflösung, der Einheit der Daten, zum Betrachtungszeitraum sowie zur Datenquelle findet sich in Tabelle 6. Die km-Angabe der räumlichen Auflösung bezieht sich auf Regionen am Äquator.

Die Variablen und deren Berechnung sowie die dahinter stehenden Datensätze (wobei teilweise auf andere Datensätze, als auf die von Owen et al. (2023) verwendeten, zurückgegriffen wird), werden in den folgenden Unterkapiteln 4.3.1 bis 4.3.11 beschrieben. Einige der zum Einsatz kommenden Datensätze sind sogenannte *Reanalyse-Datensätze*. Laut ECMWF (2023, o.S.) sind Reanalyse-Datensätze „a blend of observations with past short-range weather forecasts rerun with modern weather forecasting models“. Sie füllen, auf eine über die Zeit hinweg konsistente Weise, Lücken in Messdaten und bereinigen Fehler und ermöglichen so global vollständige, oft langjährige Datensätze (ECMWF 2023, o.S.).

Tabelle 6: Übersicht über die Gefahren-Variablen und dazugehörige Informationen.
(Quelle: Eigene Darstellung nach Owen et al. (2023, S. 8)).

Variable	Phänomen	Räumliche Auflösung	Einheit	Zeitraum	Datenquelle
<i>Klima und Wetter</i>					
Durchschnittlicher PDSI	Dürre	~ 4,6 km / 0,04°	n/a	2000-2020	TerraClimate: Palmer Drought Severity Index
Niederschlag: Veränderung der jährlichen Akkumulation	Dürre/Überschwemmung	~ 5,7 km / 0,05°	mm/pen-tad	1981-2020	CHIRPS Pentad
Niederschlag: Interannueller Variationskoeffizient	Dürre/Überschwemmung	~ 5,7 km / 0,05°	mm/pen-tad	1990-2020	CHIRPS Pentad
Niederschlag: Maximale monatliche Anomalie im März/April/Mai (P_{Max})	Überschwemmung	~ 5,7 km / 0,05°	mm/pen-tad	2000-2020	CHIRPS Pentad
Temperatur: Jährliche maximale Oberflächentemperatur (TXx)	Dürre	~ 22,3 km / 0,2°	Kelvin	2010-2020	NCEP CFSV2
Temperatur: Langfristige Anomalie (ΔT)	Dürre	~ 27,8 km / 0,25°	Kelvin	1980-2020	ECMWF ERA5 Daily
Spezifische Luftfeuchtigkeit (Q)	Dürre	~ 11,1 km / 0,10°	Massenanteil	2000-2020	FEWS NET FLDAS
<i>Geophysikalische Faktoren</i>					
Abflussakkumulation	Überschwemmung	~ 0,09 km / 0,0008°	Anzahl Pixel	N/A	MERIT Hydro
Friktion	Erdrutsch	~ 0,93 km / 0,01°	min/m	N/A	Friction Surface
Hangneigung	Erdrutsch	~ 0,09 km / 0,0008°	m	N/A	Shuttle Radar Topography Mission (DHM)
Bodenfeuchte (Oberfläche)	Dürre	~ 10 km / 0,1°	mm	2015-2020	SMAP Global Soil Moisture

4.3.1. Durchschnittlicher PDSI

Die Werte zur Berechnung des durchschnittlichen Palmer Drought Severity Index (PDSI) wurden dem Datensatz *TerraClimate* entnommen. Dieser ist ein monatlicher globaler Datensatz zum Klima und zur klimatischen Wasserbilanz globaler Landoberflächen zwischen 1958-2015 mit einer hohen räumlichen Auflösung von $\sim 4,6 \text{ km} / 0,04^\circ$. Zur Erstellung des Datensatzes wurden räumlich hoch aufgelöste klimatologische Normalwerte aus dem WorldClim-Datensatz mit zeitlich variierenden Daten mit gröberer Auflösung aus den Datensätzen CRU Ts4.0 und JRA-55 mit Hilfe von Interpolation kombiniert. Des Weiteren wird zur Erstellung der Oberflächenwasserbilanz ein Wasserbilanzmodell hinzugezogen, das Referenzwerte für u.a. Evapotranspiration, Niederschlag, Temperatur und interpolierte Bodenwasserkapazität einbezieht. Die räumlich-zeitlichen Aspekte von TerraClimate wurden anhand von Stationsdaten sowie des jährlichen Abflusses von Wasserstandsmessern validiert (Abatzoglou et al. 2018, S. 1).

TerraClimate besteht aus insgesamt 14 verschiedenen Klima-Variablen, die in den einzelnen Bändern des Datensatzes gespeichert sind. Das für die Index-Variable des durchschnittlichen PDSI in den Jahren 2000-2020 relevante Band, das das Phänomen Dürre anzeigen soll, ist dabei der PDSI zum Ende des Monats (Bandname: *pdsi*). Der PDSI ist ein meteorologischer Dürreindex, der sich aus Daten zum Niederschlag, zur Temperatur sowie den Bodefeuchteverhältnissen berechnet. Je niedriger die Werte des Index, desto trockener die Verhältnisse und je höher, desto feuchter (Glaser und Erfurt 2020, S. 1185). Zur Berechnung der Variable wurden die Daten für die entsprechenden Jahre gefiltert und daraufhin der Mittelwert der gefilterten Image Collection mit Hilfe der Methode `ee.ImageCollection.mean()` berechnet. Das Ergebnis auf globaler Ebene ist in Abbildung 18 dargestellt.

Für die Normalisierung wird der maximale Wert zunächst auf null gesetzt. Werte über null sollen in die Variablenberechnung nicht miteinbezogen werden, da positive Werte feuchte Verhältnisse anzeigen und somit keine Gefahr für Dürre darstellen. Bei der anschließenden Normalisierung wird zunächst überprüft, ob der mittlere PDSI-Wert des Untersuchungsgebiets kleiner als null ist. In diesem Fall werden die Werte mit der umgekehrten Formel normalisiert, denn je niedriger der PDSI-Wert ist, desto wahrscheinlicher ist das Vorkommen von Dürre. In allen anderen Fällen, in denen der PDSI-Wert feuchte Verhältnisse anzeigt, wird der Gefahrenwert automatisch auf null gesetzt. Owen et al. (2023) hingegen, haben zur Normalisierung der vorliegenden Variable die reguläre Formel eingesetzt (s. Formel 3). Dies ist jedoch nicht korrekt, da so davon ausgegangen wird, dass höhere Werte eine höhere Gefahr für Dürre anzeigen.




Abb. 18: Durchschnittlicher PDSI 2000-2020. Niedrigere Werte zeigen dabei Trockenheit, höhere Feuchtigkeit an.
(Quelle: Eigene Darstellung)

4.3.2 Niederschlag: Veränderung der jährlichen Akkumulation

Hinter der Berechnung der Veränderung der jährlichen Akkumulation des Niederschlags stehen die Daten des Niederschlags-Datensatzes *Climate Hazards Group InfraRed Precipitation with Station data* (CHIRPS), der von der US-Behörde United States Geological Survey (USGS) und Wissenschaftler*innen des Climate Hazards Centers entwickelt wurde. Dies ist ein nahezu globaler Datensatz mit einer Ausdehnung von 50°S-50°N über alle Längengrade hinweg mit einer Datenverfügbarkeit zwischen 1981 und heute (Funk et al. 2015, S. 2). Die Erweiterung des Datensatzes bis 60°N ist bereits in der Betaversion verfügbar. Sobald die Entwicklung des erweiterten Datensatzes abgeschlossen und dieser über GEE verfügbar ist, soll die alte Version im Skript gegen die neue Version ausgetauscht werden, um für die Variablen, die mit Hilfe des CHIRPS-Datensatzes berechnet werden, eine globale Abdeckung sicherzustellen.

CHIRPS hat eine hohe räumliche Auflösung von $\sim 5,7 \text{ km} / 0,05^\circ$. Die Daten stehen beim verwendeten Datensatz in Pentaden zur Verfügung, wobei ein Kalendermonat aus sechs Pentaden besteht. Die ersten fünf dieser Pentaden beinhalten fünf Tagen und die letzte Pentade alle Tage ab dem 26. bis zum Ende des Monats, was dementsprechend drei bis sechs Tage sein können. CHIRPS beruht dabei auf dem Rasterdatensatz CHPclim, der mithilfe von raumbezogener Modellierung auf der Grundlage von Regression – *moving window regression* – und dem Interpolationsverfahren der *inversen*

Distanzgewichtung erstellt wurde sowie auf Satellitenbildern mit einer räumlichen Auflösung von 0,05° und in-situ Stationsdaten (Funk et al. 2015, S. 2).

Der Datensatz besteht aus der Variable *precipitation*, die die Niederschlagsmenge in Millimetern pro Pentade angibt. Im Rahmen der Variable der Veränderung der jährlichen Niederschlagsakkumulation wurden die Jahre 2009-2020 im Vergleich zu 1981-1990 betrachtet. Zur Berechnung der Veränderung wurde zunächst die jährliche Niederschlagsakkumulation berechnet, indem die Summe des Niederschlags in den jeweiligen Betrachtungszeiträumen gebildet und durch die jeweilige Anzahl der Jahre geteilt wurde. Im Anschluss wurden die Werte des Zeitraums 1981-1990 von den Werten des Zeitraums 2009-2020 subtrahiert. Diese Vorgehensweise ist auch in Formel 6 zu erkennen.

Veränderung der Niederschlagsakkumulation

$$= \bar{x}(\text{Niederschlag}_{2009-2020}) - \bar{x}(\text{Niederschlag}_{1981-1990})$$

Formel 6: Berechnung der Variable Niederschlag: Veränderung der jährlichen Akkumulation.
(Quelle: Owen et al. (2023))

Das Ergebnis der Berechnung der Veränderung der Niederschlagsakkumulation auf globaler Ebene ist in Abbildung 19 dargestellt. Negative Werte sind dabei als Zeiger für trockener werdende Verhältnisse zu interpretieren, positive als Zeiger für feuchter werdende Verhältnisse. Je kleiner die Werte, desto höher ist die Wahrscheinlichkeit des Auftretens von Dürre, je höher die Werte, desto wahrscheinlicher ist das Auftreten von Überschwemmungen.

Für die Normalisierung wurde zunächst geprüft, ob der mittlere Wert der Veränderung der jährlichen Niederschlagsakkumulation im Untersuchungsgebiet größer oder kleiner null ist. Ist er größer null, zeigt der Wert tendenziell Überschwemmungen an und es wird mit der regulären Formel normalisiert. Der minimale Wert des Gebiets der Normalisierungsgrundlage wird in diesem Fall auf null gesetzt. Ist er kleiner null, zeigt er tendenziell Dürren an und es wird mit der umgekehrten Formel normalisiert. Der maximale Wert wird in diesem Fall auf null gesetzt. Ist der mittlere Wert im Untersuchungsgebiet gleich null, wird der Gefahrenwert der Variable automatisch auf null gesetzt.




Abb. 19: Veränderung der jährlichen Niederschlagsakkumulation in mm.
(Quelle: Eigene Darstellung)

4.3.3 Niederschlag: Interannueller Variationskoeffizient

Der hinter dieser Variable stehende Datensatz ist der bereits in Kapitel 4.3.2 beschriebene Niederschlags-Datensatz CHIRPS, der die Niederschlagsmenge in Millimetern pro Pentade für die Jahre 1981 bis heute enthält.

Um den interannuellen Variationskoeffizienten aus den Niederschlagsdaten berechnen zu können, wird zunächst die Summe des Niederschlags für jedes Jahr zwischen 1990-2020 sowie die Standardabweichung dieser Werte, als auch der mittlere jährliche Niederschlag zwischen 1990-2020 berechnet. Die Berechnung des interannuellen Variationskoeffizienten erfolgt daraufhin, indem die Standardabweichung durch den Mittelwert des jährlichen Niederschlags geteilt wird, s. Formel 7.

$$\text{Interannueller Variationskoeffizient des Niederschlags} = \frac{\sigma}{\bar{x}}$$

Formel 7: Berechnung des interannuellen Variationskoeffizienten des Niederschlags. σ steht dabei für die Standardabweichung der jährlichen Niederschlagssumme, $\bar{x}$ für den Mittelwert des jährlichen Niederschlags. (Quelle: Owen et al. (2023))

Der Variationskoeffizient wird häufig als Maß für die Niederschlagsvariabilität verwendet (Harp und Horton 2023, S. 3). So gibt der berechnete interannuelle

Variationskoeffizient an, um wie viel die jährliche Niederschlagsmenge an einem Ort im Verhältnis zur Jahresgesamtmenge variiert. Ist der interannuelle Variationskoeffizient niedrig, zeigt er an, dass die jährlichen Niederschlagsmengen eng um den Mittelwert herum liegen. Ist er hoch, sind die jährlichen Niederschlagsmengen weniger konsistent und es besteht eine hohe Variabilität. Eine hohe Variabilität des jährlichen Niederschlags kann zu extremen Nässe- und Trockenereignissen führen, was die Wahrscheinlichkeit des Eintretens von Überschwemmungen bzw. Dürren erhöht (Pendergrass et al. 2017, S. 1). Das Ergebnis der Berechnung des interannualen Variationskoeffizienten des Niederschlags auf globaler Ebene ist in Abbildung 20 zu finden.




Abb. 20: Interannueller Variationskoeffizient des Niederschlags.
(Quelle: Eigene Darstellung)

4.3.4 Niederschlag: Maximale monatliche Anomalie im März/April/Mai (P_{Max})

Die benötigten Daten zur Berechnung der maximalen monatlichen Niederschlagsanomalie in den Monaten März/April/Mai finden sich in dem bereits in Kapitel 4.3.2 beschriebenen Niederschlags-Datensatz CHIRPS, der die Niederschlagsmenge in Millimetern pro Pentade für die Jahre 1981 bis heute enthält.

Zur Berechnung der Variable werden zunächst die Mittelwerte der monatlichen Niederschlagssummen für jeweils die Monate März, April und Mai zwischen den Jahren 2000-2020 ermittelt. Von den einzelnen monatlichen Niederschlagssummen im März, April und Mai zwischen 2000-2020 wird daraufhin die entsprechende monatliche mittlere

Niederschlagssumme subtrahiert, um so die jeweilige Anomalie zu erhalten. Die Anomalien werden demnach als Abweichungen vom jeweils monatlichen Durchschnittsniederschlag zwischen 2000-2020 berechnet. Da die Variable Überschwemmungen anzeigen soll, wird letztlich die maximale Anomalie der einzelnen Anomalie-Werte bestimmt. Abbildung 21 gibt eine globale Übersicht der maximalen monatlichen Niederschlagsanomalien zwischen März und Mai.




Abb. 21: Maximale monatliche Niederschlagsanomalie im März/April/Mai (P_{Max}) in mm.
(Quelle: Eigene Darstellung)

4.3.5 Temperatur: Jährliche maximale Oberflächentemperatur (TXx)

Hinter der Berechnung der jährlichen maximalen Oberflächentemperatur stehen die vom National Centers for Environmental Prediction (NCEP) entwickelten Daten des Klima-Modells *NCEP Climate Forecast System* (CFSv2), die im Jahr 2011 veröffentlicht wurden. Das Modell stellt die Wechselwirkung zwischen Erdatmosphäre, Ozeanen, Land und Meereis dar, indem es verschiedene Modelle bezüglich Atmosphäre, Ozean und Land verbindet, und wird viermal täglich zur Erstellung von Prognosen initialisiert (00:00, 06:00, 12:00 und 18:00 UTC). Die räumliche Abdeckung erstreckt sich über alle Längen- und Breitengrade, wodurch eine globale Verfügbarkeit gewährleistet ist. Die räumliche Auflösung beläuft sich dabei auf $\sim 22,3 \text{ km} / 0,2^\circ$. Die Daten sind zwischen 1779 und heute verfügbar (Saha et al. 2014, S. 1ff.).

Der Datensatz NCEP besteht aus 22 Bändern. Das Band, das für die Variable genutzt wird, ist das Band *Maximum_temperature_height_above_ground_6_Hour_Interval*, das die maximale Temperatur in einer Höhe von 2 m über dem Boden angibt. Für die Berechnung der Variable TXx, die die Wahrscheinlichkeit für Dürren anzeigen soll, wurde die jeweils maximale jährliche Temperatur zwischen den Jahren 2010 und 2020 ermittelt und von diesen Werten der Mittelwert bestimmt. Abbildung 22 gibt eine globale Übersicht der mittleren maximalen jährlichen Oberflächentemperatur.




Abb. 22: Jährliche maximale Oberflächentemperatur (TXx) in Kelvin.
(Quelle: Eigene Darstellung)

Owen et al. (2023) haben bei der vorliegenden Variable lediglich Werte, die die Oberflächentemperatur bei Tag (12:00 UTC) abbilden, in ihre Berechnung mit einbezogen. Da die Berechnung des Index in dem hier erstellten Skript aber global möglich sein soll und dabei unterschiedliche Zeitzonen berücksichtigt werden müssen, wurde entschieden, alle Werte der 6-stündigen Intervalle einzubeziehen.

4.3.6 Temperatur: Langfristige Anomalie (ΔT)

Hinter der Berechnung der langfristigen Temperaturanomalie stehen die atmosphärischen Reanalyse-Daten von ERA5, die das Klima mit globaler räumlicher Abdeckung widerspiegeln. Entwickelt wurde der Datensatz vom Copernicus Climate Change Service (C3S) am Europäischen Zentrum für mittelfristige Wettervorhersage (ECMWF). Der Datensatz

beinhaltet stündliche Schätzungen verschiedener atmosphärischer, landbasierter und ozeanischer Klimavariablen mit einer räumlichen Auflösung von $\sim 27,8 \text{ km} / 0,25^\circ$ und ist über die GEE zwischen 1979-2020 verfügbar. ERA5 basiert auf dem *Integrated Forecasting System* (IFS) Cy41r2 und nutzt die Prognosen dieses Modells (Hersbach et al. 2020, S. 1ff.).

Der verwendete Datensatz ERA5 besteht aus neun Bändern. Das Band, das für die Variable genutzt wird, ist das Band *mean_2m_air_temperature*, das die durchschnittliche Lufttemperatur in zwei Meter Höhe als Tagesmittel in Kelvin angibt. Die Temperaturanomalie, die die Wahrscheinlichkeit für Dürren anzeigen soll, wurde aus den Daten wie folgt berechnet, wobei als Normalperiode der Zeitraum von 1980-1992 gewählt wurde:

$$\text{Temperaturanomalie} = \bar{x}(\text{Temperatur}_{2008-2019}) - \bar{x}(\text{Temperatur}_{1980-1992})$$

Formel 8: Berechnung der Temperaturanomalie.
(Quelle: Owen et al. (2023))

In Abbildung 23 ist eine globale Übersicht der langfristigen Temperaturanomalie gegeben:




Abb. 23: Langfristige Temperaturanomalie (ΔT) in Kelvin.
(Quelle: Eigene Darstellung)

Owen et al. (2023) haben für diese Variable den alternativen Datensatz *NCEP/NCAR Reanalysis Data, Surface Temperature* genutzt, der eine längere Datenverfügbarkeit – von 1948 bis heute – hat. Aufgrund dessen erfolgte die Berechnung der Temperaturanomalie mit einer klassischen Normalperiode von 30 Jahren. Dieser alternative Datensatz wurde in der vorliegenden Arbeit nicht genutzt, da die räumliche Auflösung von diesem bei lediglich $\sim 278,3 \text{ km} / 2,5^\circ$ liegt. Da der hier genutzte Datensatz lediglich für eine kürzere zeitliche Periode verfügbar ist, wurde eine verkürzte Normalperiode von zwölf Jahren (1980-1992) verwendet. Laut WMO (2017, S. 17) ist dies möglich, da festgestellt wurde, dass „for most mean and sum parameters (not extreme parameters or higher-order statistical properties such as quantiles), 10–12 years of data provided a predictive skill similar to that from a standard 30-year period“. Zudem ist der Standardreferenzzeitraum für die Beurteilung langfristiger Klimaveränderungen laut Empfehlung der WMO (o.J., o.S.) der Zeitraum von 1961 bis 1990. Da das erste verfügbare Jahr des gewählten Datensatzes – mit Datenverfügbarkeit ab 01.01. – allerdings das Jahr 1980 ist, wird als Beginn der Normalperiode entsprechend das Jahr 1980 festgelegt.

4.3.7 Spezifische Luftfeuchtigkeit (Q)

Zur Berechnung der spezifischen Luftfeuchtigkeit Q, das ein Maß für den Wasserdampfgehalt der Luft ist, wurden die monatlichen Daten *Famine Early Warning Systems Network (FEWS NET) Land Data Assimilation System (FLDAS)*, verwendet, die von der NASA herausgegeben werden. Der Datensatz beinhaltet Vorhersagen der hydroklimatischen Bedingungen wie Bodenfeuchte, Evapotranspiration und Abfluss. Die Daten haben eine räumliche Auflösung von $\sim 11,1 \text{ km} / 0,10^\circ$ und sind zwischen 1982 und heute verfügbar. Es ist zudem eine globale räumliche Abdeckung gegeben ($60^\circ \text{ S}-90^\circ \text{ N}$, alle Längengrade). Hinter dem Datensatz steht u.a. das Land Surface Model (LSM) Noah 3.6.1, das den Austausch von Wasser- und Energieflüssen an der Schnittstelle zwischen Erdoberfläche und Atmosphäre simuliert (McNally et al. 2017, S. 1f.).

Der verwendete Datensatz FLDAS besteht aus 28 Bänden. Das Band, das für die Variable genutzt wird, ist das Band *Qair_f_tavg*, das die spezifische Luftfeuchtigkeit angibt. Für die Verwendung der spezifischen Luftfeuchtigkeit im Index, wurde der Mittelwert von Q zwischen den Jahren 2000-2020 berechnet. Das Ergebnis wird als Zeiger für die Höhe der Wahrscheinlichkeit des Vorkommens von Dürre verwendet. Abbildung 24 zeigt eine globale Übersicht der Höhe der spezifischen Luftfeuchtigkeit.




Abb. 24: Spezifische Luftfeuchtigkeit (Q) als Massenanteil.
(Quelle: Eigene Darstellung)

4.3.8 Abflussakkumulation

Für die Variable der Abflussakkumulation wurden die Daten des *MERIT Hydro* Datensatzes verwendet – ein globaler Hydrographie-Datensatz, der auf Grundlage des digitalen Höhenmodells (DHM) *MERIT DEM* und verschiedenen Datensätzen bezüglich Gewässern (G1WBM, GSWO und OpenStreetMap) vom Global Hydrodynamics Lab unter Dai Yamazaki an der Universität Tokyo entwickelt wurde. Für die Erstellung des Datensatzes wurde ein neuer Algorithmus entwickelt, der Gewässernetze nahezu automatisch extrahiert. Die Lage der Gewässernetze wurde zudem mit satellitengestützten globalen Daten abgeglichen. *MERIT Hydro* beinhaltet u.a. die Fließrichtung, die Abflussakkumulation, hydrologisch angepasste Höhen sowie Flussbettbreiten und hat dabei eine hohe räumliche Auflösung von $\sim 0,093 \text{ km} / 0.0008^\circ$ (Yamazaki et al. 2019, S. 1f.).

Der verwendete Datensatz *MERIT Hydro* besteht aus acht Bändern. Das Band, das für die Variable genutzt wird, ist das Band *upg*, das die Anzahl der flussaufwärts liegenden Pixel wiedergibt, die aufgrund ihrer Fließrichtung in ein Pixel entwässern, was der Abflussakkumulation (in Anzahl Pixel) entspricht (Jenson 1991, S. 32). Eine schematische Darstellung der Bestimmung der Abflussakkumulation, als Ableitung aus der Fließrichtung, findet sich in Abbildung 25.




Abb. 25: Schematische Darstellung der Bestimmung der Abflussakkumulation.
(Quelle: ESRI (o.J.))

Eine höhere Abflussakkumulation in einem Gebiet spiegelt eine erhöhte Überschwemmungsgefahr in diesem wider (Vojtek und Vojteková 2019, S. 8). Dementsprechend zeigt die vorliegende Variable die Wahrscheinlichkeit des Eintritts von Überschwemmungen an. Eine globale Übersicht über die Werte der Abflussakkumulation ist in Abbildung 26 verstärkt dargestellt. Bei der Erstellung der Abbildung wurde aufgrund der resultierenden Dateigröße eine geringere räumliche Auflösung von 1000 m gewählt.




Abb. 26: Abflussakkumulation (Anzahl Pixel).
(Quelle: Eigene Darstellung)

Owen et al. (2023) verwenden bei der Variable der Abflussakkumulation einen anderen Datensatz – den Datensatz *HydroSHEDS* – der vom World Wildlife Fund (WWF) in Zusammenarbeit mit dem USGS entwickelt wurde. Dieser Datensatz wurde in der vorliegenden Arbeit nicht genutzt, da er nur eine nahezu globale räumliche Datenabdeckung aufweist und Daten für Regionen über 60° N fehlen. Ein weiterer Nachteil dieses Datensatzes ist die geringere räumliche Auflösung der auf GEE verfügbaren Daten von ~ 0,46 km / 0,004° (Lehner et al. 2008, S. 1ff.).

4.3.9 Friktion

Die Werte für die Variable Friktion wurden dem globalen Datensatz *Friction Surface* entnommen, der von der Arbeitsgruppe Malaria Atlas Project am Telethon Kids Institute der University of Western Australia erstellt wurde. Dieser Datensatz beinhaltet die Geschwindigkeit, mit der sich Menschen durch jedes Pixel der Erdoberfläche bewegen können und hat dabei eine räumliche Auflösung von ~ 0,93 km / 0,01°. *Friction Surface* wurde aus einer Vielzahl georäumlicher Datensätze abgeleitet, beispielsweise von Open Street Map und Google. Dabei fließen Informationen wie Positionen und Eigenschaften von Straßen, Eisenbahnen, Flüssen, Gewässern, Bodenbedeckungsarten, topografische Bedingungen (Hangneigung und Höhe) und Landesgrenzen in den Datensatz ein (Weiss et al. 2018, S. 334).

Parameter, die dabei auch das Vorkommen von Erdbeben beeinflussen, sind laut Süzen und Kaya (2012, S. 344) u.a. die Bodenbedeckungsart, die Hangneigung und die Höhe. Bezüglich der Bodenbedeckungsart verringert beispielsweise eine hohe Vegetationsbedeckung (z.B. Laubbäume) und die damit einhergehende höhere Wurzelkohäsion die Wahrscheinlichkeit des Eintritts von Erdbeben. Höhere Auftretswahrscheinlichkeiten von Erdbeben gibt es dahingegen im Bereich von landwirtschaftlichen Flächen, Busch- und Grasflächen. Wird die Hangneigung betrachtet, nimmt die Erdbebenwahrscheinlichkeit mit dem Neigungswinkel zu, da die Scherspannung im Boden oder anderem nicht verfestigten Material entsprechend zunimmt, was Erdbeben begünstigt. Allgemein gesehen treten bei geringen Neigungen geringere Scherspannungen auf (Fiolleau et al. 2023, S. 1; Lee und Evangelista 2005, S. 3). Dementsprechend ist der Datensatz, aufgrund des Einfließens von für die Eintrittswahrscheinlichkeit von Erdbeben ausschlaggebender Parameter, geeignet, die Wahrscheinlichkeit des Vorkommens von Erdbeben anzuzeigen.

Die Werte für die Friktion wurden dem Band *friction* entnommen, das die geschätzte Bewegungsgeschwindigkeit in min/m beim Durchqueren eines Pixels beinhaltet.

Da der Datensatz zum Zeitpunkt der Ausarbeitung dieses Kapitels nicht funktionsfähig ist (s. Kapitel 6.2), fehlt die globale Übersicht über die Werte der Friktion.

4.3.10 Hangneigung

Als Hangneigung wird die maximale Änderungsrate der Höhenwerte eines Geländes bezeichnet. Wie bereits in Kapitel 4.4.9 beschrieben, ist die Hangneigung ein wichtiger Einflussfaktor für die Eintrittswahrscheinlichkeit von Erdrutschen, wobei eine stärkere Hangneigung die Eintrittswahrscheinlichkeit erhöht (Lee und Evangelista 2005, S. 2f.). Laut Budimir et al. (2015, S. 1) ist diese sogar „[t]he most common statistically significant covariate used in landslide logistic regression“. Aufgrund dessen fließt die Hangneigung, als separate Variable als Zeiger für Erdrutsche in den Gefahrenindex ein.

Der für diese Variable verwendete Datensatz ist das *Shuttle Radar Topography Mission (SRTM)* DHM mit einer räumlichen Auflösung von $\sim 0,09 \text{ km} / 0,0008^\circ$ und einer nahezu globalen Abdeckung (bis 60° N und S). Es wird von der Consultative Group on International Agricultural Research - Consortium for Spatial Information – einem Zusammenschluss verschiedener Forschungsorganisationen – herausgegeben. Die Daten des SRTM DHMs beruhen auf SRTM-Daten der NASA. Da die Originaldaten Datenlücken enthalten, wurden diese einer Nachbearbeitung unterzogen, um die Datenlücken durch Interpolationstechniken zu schließen. Das Ergebnis-DHM beinhaltet nahtlose, vollständige Höheninformationen für den Globus (Jarvis et al. 2008, S. 1f.).

Um die Hangneigung in Grad aus dem DHM zu berechnen, wurde die Funktion *ee.Terrain.slope* aufgerufen. Eine globale Übersicht über die Werte der Hangneigung ist in Abbildung 27 dargestellt.




Abb. 27: Hangneigung in Grad.
(Quelle: Eigene Darstellung)

4.3.11 Bodenfeuchte (Oberfläche)

Für die Variable der Bodenfeuchte an der Oberfläche wurde der von der NASA zur Verfügung gestellte Datensatz *NASA-USDA Enhanced Soil Moisture Active Passive (SMAP) Global soil moisture* eingebunden. Dieser globale Datensatz mit einer räumlichen Auflösung von $\sim 10 \text{ km} / 0,1^\circ$, beruht auf Daten der Weltraummission SMAP, bei der Messungen der Bodenfeuchte an der Erdoberfläche durchgeführt wurden, wobei zwischen gefrorenen und nicht gefrorenen Landoberflächen unterschieden wurde. Die gesammelten Daten wurden zur Generierung des eingebundenen Datensatzes dem sogenannten *Palmer two-layer soil moisture model* zugeführt (Entekhabi et al. 2010, S. 1). Laut Gebremichael und Hossain (2010, S. 280) ist dieses „a bookkeeping method that accounts for the water gained or lost in the soil profile by recording the amount of water withdrawn by evapotranspiration and replenished by precipitation“. Modellvorhersagen können durch das Einbinden von weltraumgestützten Beobachtungen für Bodenfeuchte erheblich verbessert werden (Entekhabi et al. 2010, S: 706). Der fertige Datensatz der NASA enthält u.a. Informationen bezüglich:

- Bodenfeuchte an der Oberfläche (mm)
- Bodenfeuchte im Untergrund (mm)
- Bodenfeuchteprofil (%)
- Anomalie der Bodenfeuchte an der Oberfläche
- Anomalie der Bodenfeuchte im Untergrund

Das Band, das für die vorliegende Variable genutzt wird, ist dabei das Band *ssm*, das Werte zur Bodenfeuchte an der Oberfläche in mm enthält. Der Betrachtungszeitraum beläuft sich auf die Jahre 2015-2020, wobei der Mittelwert der Bodenfeuchte für diesen Zeitraum berechnet wird. Laut Entekhabi et al. (2010, S. 704) sind „[s]oil moisture measurements [...] directly applicable to [...] drought monitoring“, weshalb die vorliegenden Daten geeignet sind, die Eintrittswahrscheinlichkeit der Naturgefahr Dürre anzuzeigen. Eine globale Übersicht über die Werte der Bodenfeuchte an der Oberfläche ist in Abbildung 28 zu finden.




Abb. 28: Bodenfeuchte an der Oberfläche in mm.
(Quelle: Eigene Darstellung)

Anhand der Abbildung lassen sich Datenlücken in u.a. Nordafrika, der arabischen Halbinsel und Nordchina feststellen. Bei der Nutzung des erstellten Skripts werden diese Datenlücken automatisch mit dem mittleren Wert innerhalb der Normalisierungsgrundlage gefüllt.

5 Aufbau und Anwendung des Gefahrenindex-Skripts

In diesem Kapitel wird zunächst der Aufbau des erstellten Gefahrenindex-Skripts erläutert, bevor ausgewählte Codeausschnitte vorgestellt werden. Außerdem werden einige exemplarische Anwendungen präsentiert, um die Plausibilität der gewählten Methodik zu unterstreichen.

5.1 Aufbau des Skripts und exemplarische Vorstellung von Codeausschnitten

Das entwickelte Skript zur Berechnung von Gefahrenindexwerten für jeden beliebigen Ort ist so aufgebaut, dass ein Hauptskript (Jupyter Notebook) den Nutzer*innen als *zentrales Skript* dient, von dem aus alle Berechnungen gesteuert werden können. Im Hauptskript sollen verschiedene Einstellungen getroffen werden, um das Skript auf den Verwendungszweck und die Untersuchungsgebiete der Nutzer*in anzupassen (für eine genaue Übersicht zu den zu treffenden Einstellungen s. Kapitel 7). Vom Hauptskript aus wird, um eine gute Übersichtlichkeit zu gewährleisten, auf in Python-Skripten (.py) definierte Funktionen, die zur Berechnung der einzelnen Gefahren-Variablen notwendig sind (s. auch Kapitel 4.3), zugegriffen. Zudem werden die zu verwendenden Daten mittels der GEE API aus dem Datenkatalog der GEE bezogen. Darauf aufbauende Berechnungen werden zudem in der Cloud der GEE durchgeführt. Schematisch dargestellt ist dieser Aufbau in Abbildung 29.

Im Folgenden wird zunächst der Inhalt des Hauptskripts genauer vorgestellt und die dazugehörigen Codeblöcke angefügt. Anschließend wird exemplarisch das Python-Skript des durchschnittlichen PDSI präsentiert und erläutert. Die weiteren Python-Skripte folgen dabei dem gleichen Aufbau, weshalb darauf verzichtet wird, diese ebenfalls im Detail vorzustellen. Zu den Herausforderungen, die im Laufe der Erstellung des Gefahrenindex-Skripts auftraten und für Informationen in welcher Form das *Error-Handling* erfolgte, s. Kapitel 6. Das vollständige Skript befindet sich außerdem im Anhang dieser Arbeit. In Kapitel 8.4 findet sich zudem der Link zum Code auf GitHub.




Abb. 29: Aufbau des Gefahrenindex-Skripts (N = Niederschlag, T = Temperatur).
(Quelle: Eigene Darstellung)

Im Hauptskript wird zunächst das *Untersuchungsgebiet* definiert. Hierfür kann entweder eine neue *GEE-Geometrie*, beispielsweise eine Bounding Box, ein Polygon oder ein Point, erstellt werden, zu erkennen in Codeblock 1, oder eine *GeoJSON-Datei* (Codeblock 2) bzw. eine *Shapefile-Datei* (Codeblock 3) hochgeladen werden.

```

vienna_bbox = ee.Geometry.BBox(16.2678922, 48.1195168, 16.5371291, 48.2618604)
vienna_point = ee.Geometry.Point(16.363449, 48.210033)
vienna_polygon = ee.Geometry.Polygon([
    [
        [16.1808, 48.3236],
        [16.3841, 48.3261],
        [16.5761, 48.3090],
        [16.5796, 48.2493],
        [16.5110, 48.1404],
        [16.3073, 48.0837],
        [16.2257, 48.1304],
        [16.1808, 48.3236]
    ]
])

```

Codeblock 1: Definieren des Untersuchungsgebiets als neue GEE-Geometrie.
(Quelle: Eigene Darstellung)

```

# Define path to JSON file
region_path = r'C:\...\LANDESGRENZEOGD.json'

# Convert GeoJSON to Earth Engine object
region_ee_object = geemap.geojson_to_ee(region_path)

# Get geometry of GEE object
region_gee_geometry_json = region_ee_object.geometry()

```

Codeblock 2: Definieren des Untersuchungsgebiets mittels Hochladen einer GeoJSON-Datei.
(Quelle: Eigene Darstellung)

```

# Load shapefile as geodataframe
region_gdf = gpd.read_file(r'C:\...\LANDESGRENZEOGDPolygon.shp')

# Define function to convert shapefile geometry to GEE geometry
def shp_to_ee_geom(shp_geom):
    geojson = mapping(shp_geom)
    return ee.Geometry(geojson)

# Extract the first row's geometry from the geodataframe, adjust as needed
region_geometry = region_gdf.loc[0, 'geometry']

# Convert shapefile polygon to GEE geometry
region_gee_geometry_shp = shp_to_ee_geom(region_geometry)

```

Codeblock 3: Definieren des Untersuchungsgebiets mittels Hochladen einer Shapefile-Datei.
(Quelle: Eigene Darstellung)

Im nächsten Schritt wird die *Normalisierungsgrundlage* mit Hilfe des GAUL-Datensatzes definiert (s. auch Kapitel 7) und ein Fishnet über die definierte Normalisierungsgrundlage gelegt (s. auch Kapitel 6.1). Optional kann das Fishnet entsprechend der genauen Grenze der Normalisierungsgrundlage geclippt werden. Der dazugehörige Code findet sich in Codeblock 4.

```
# Load GAUL dataset
all_countries = ee.FeatureCollection('FAO/GAUL_SIMPLIFIED_500m/2015/level0')

# Define country
country_name = "Austria"

# Filter dataset for specified country
country = all_countries.filter(ee.Filter.eq('ADM0_NAME', country_name))

# Create fishnet over specified country
country_fishnet = geemap.fishnet(country.geometry(), h_interval=0.3,
v_interval=0.3, delta=1)
# country_fishnet = geemap.fishnet(country.geometry(), rows=50, cols=50,
delta=1)

# Optional: clip country_fishnet to exact border outlines -> might lead to
computation timeout
country_fishnet_clip = country_fishnet.map(lambda tile:
tile.intersection(country.geometry(), ee.ErrorMargin(1)))
```

Codeblock 4: Definieren der Normalisierungsgrundlage und Erstellen des Fishnets.
(Quelle: Eigene Darstellung)

Um die *Gefahrenindexwerte* zu berechnen, wird zunächst eine Liste mit den definierten Untersuchungsgebieten erstellt. Daraufhin werden die maximalen und minimalen Werte der einzelnen Variablen innerhalb der Untersuchungsgrundlage berechnet, da diese Werte für das Normalisieren der Variablen gebraucht werden, s. Codeblock 5. Anschließend wird für jedes Untersuchungsgebiet in der erstellten Liste für jeweils jede der elf Variablen der normalisierte Variablenwert berechnet, zu erkennen in Codeblock 6. Um den finalen Gefahrenindexwert zu berechnen, werden die jeweiligen Variablenwerte aufsummiert und durch die Anzahl der Variablen geteilt (s. auch Kapitel 4.2). Die Ergebnisse werden abschließend in einem Dataframe gespeichert und als csv-Datei exportiert, dargestellt in Codeblock 7.

```

# Create list for regions of interest and list for region names
region_of_interest_list = [region_gee_geometry_json, region_gee_geometry_shp,
vienna_bbox, vienna_polygon, vienna_point]
region_of_interest_names_list = ['vienna_json', 'vienna_shp', 'vienna_bbox',
'vienna_polygon', 'vienna_point']

# Calculate min/max values of all variables for normalization reference
min_values = {}
max_values = {}
mean_values = {}

min_values["pdsi"], max_values["pdsi"] = pdsi_average.min_max(country_fishnet)
min_values["precip_change"], max_values["precip_change"] =
precipitation_ann_change.min_max(country_fishnet)
min_values["precip_coeff_variation"], max_values["precip_coeff_variation"] =
precipitation_coefficient_variation.min_max(country_fishnet)

```

Codeblock 5: Berechnung der minimalen und maximalen Variablenwerte innerhalb der Normalisierungsreferenz. Beispielhaft dargestellt für drei der elf Variablen.
(Quelle: Eigene Darstellung)

```

# Calculate normalized variable values for each region of interest
var_1_results = []
var_2_results = []
var_3_results = []

for region_of_interest in region_of_interest_list:
    var1 = pdsi_average.get_pdsi_region(region_of_interest,
min_values["pdsi"], max_values["pdsi"])
    var_1_results.append(var1)

    var2 =
precipitation_ann_change.get_precipitation_change_region(region_of_interest,
min_values["precip_change"], max_values["precip_change"])
    var_2_results.append(var2)

    var3 =
precipitation_coefficient_variation.get_precipitation_coefficient_variation_r
egion(region_of_interest, min_values["precip_coeff_variation"],
max_values["precip_coeff_variation"])
    var_3_results.append(var3)

```

Codeblock 6: Berechnung der normalisierten Variablenwerte für jedes Untersuchungsgebiet. Beispielhaft dargestellt für drei der elf Variablen.
(Quelle: Eigene Darstellung)

```

# Calculate hazard index values and create DataFrame of the results
data = {
    "Region of Interest": region_of_interest_names_list,
    "PDSI average": var_1_results,
    "precipitation change": var_2_results,
    "precipitation coefficient variation": var_3_results,
    "precipitation anomaly": var_4_results,
    "surface temperature max": var_5_results,
    "temperature anomaly": var_6_results,
    "specific humidity": var_7_results,
    "flow accumulation": var_8_results,
    #"friction": var_9_results,
    "slope": var_10_results,
    "ssm": var_11_results,
}

df = pd.DataFrame(data)

df["hazard index"] = df[[
    "PDSI average", "precipitation change", "precipitation coefficient
    variation", "precipitation anomaly", "surface temperature max",
    "temperature anomaly", "specific humidity", "flow accumulation",
    #"friction", "slope", "ssm"
]].mean(axis=1)

# Save the DataFrame as a csv file
df.to_csv('index_results.csv')

```

Codeblock 7: Berechnung der Gefahrenindexwerte und Erstellen einer Ergebnisdatei im csv-Format.
(Quelle: Eigene Darstellung)

Im Folgenden wird exemplarisch das Python-Skript bezüglich der Variable des durchschnittlichen PDSI vorgestellt. Alle Python-Skripte, auf die vom Hauptskript aus zugegriffen wird, folgen dabei dem gleichen Aufbau. Dabei bestehen die Python-Skripte immer aus drei verschiedenen Funktionen. In der *ersten Funktion*, die den anderen beiden Funktionen als Helferfunktion dient, werden die Datensätze zunächst geladen und entsprechend der jeweiligen Variable angepasst und aufbereitet. Im Python-Skript des mittleren PDSI wird der Datensatz so beispielsweise zunächst nach den Jahren 2000-2020 gefiltert, bevor das Band, das die Werte des PDSI beinhaltet, ausgewählt wird und aus diesem der Mittelwert für die Betrachtungsperiode berechnet wird. Der genaue Inhalt der ersten Funktion, exemplarisch für den mittleren PDSI, ist in Codeblock 8 zu erkennen.

```

def get_pdsi_average():

    # Load data
    terraclimate_dataset = ee.ImageCollection('IDAHO_EPSCOR/TERRACLIMATE')

    # Define observation Period
    terraclimate_2000_2020 = terraclimate_dataset.filterDate('2000-01-01',
'2021-01-01')

    # Select bands
    pdsi_2000_2020 = terraclimate_2000_2020.select('pdsi')

    # Get mean for observation period
    pdsi_average = pdsi_2000_2020.mean()

    return pdsi_average

```

Codeblock 8: Funktion zum Laden und Aufbereiten der Datensätze. Hier beispielhaft für den Datensatz TerraClimate zur Berechnung des mittleren PDSI.
(Quelle: Eigene Darstellung)

Mit einer *zweiten Funktion*, die in allen Python-Skripten leicht unterschiedlich definiert wird, kann der minimale und maximale Wert der Variable, innerhalb der im Hauptskript übergebenen Normalisierungsreferenz, berechnet werden. Dabei wird zunächst der minimale und maximale Variablenwert für jede Zelle des Fishnets einzelnen berechnet, um anschließend die gesamten minimalen und maximalen Werte zu ermitteln. Der genaue Inhalt der zweiten Funktion, exemplarisch für den mittleren PDSI, ist in Codeblock 9 zu erkennen.

Mit einer *dritten Funktion*, die ebenfalls in allen Python-Skripten leicht unterschiedlich definiert wird, wird der mittlere Variablenwert innerhalb des Untersuchungsgebiets berechnet und dieser Wert auf Grundlage der Normalisierungsreferenz normalisiert. Dieser Funktion werden im Hauptskript das Untersuchungsgebiet, als auch die in der zweiten Funktion berechneten minimalen und maximalen Variablenwerte übergeben, da diese für die Normalisierung gebraucht werden. Das besondere im Python-Skript des mittleren PDSI ist dabei, dass positive Werte automatisch auf null gesetzt werden, da diese feuchte Bedingungen anzeigen (s. Kapitel 4.3.1). Der genaue Inhalt der dritten Funktion, exemplarisch für den mittleren PDSI, ist in Codeblock 10 zu erkennen.

```

def min_max(normalization_reference):
    """
    Calculates the minimum and maximum average PDSI (2000-2020) within the
    given normalization reference.

    Args:
        normalization_reference (ee.FeatureCollection): The reference at
        which to normalize the variable.

    Returns:
        float: The minimum average PDSI within the normalization reference.
        float: The maximum average PDSI within the normalization reference.
    """

    pdsi_average = get_pdsi_average()

    # Define a function to compute min and max for each tile
    def get_min_max(tile):
        min_max = pdsi_average.reduceRegion(
            reducer=ee.Reducer.minMax(),
            geometry=tile.geometry(),
            scale=4638.3,
            maxPixels=1e9
        )
        return tile.set({'min_pdsi': min_max.get('pdsi_min'), 'max_pdsi':
min_max.get('pdsi_max')})

    # Apply the function over the fishnet tiles
    min_max_tiles = normalization_reference.map(get_min_max)

    # Aggregate the results
    min_pdsi_list = min_max_tiles.aggregate_array('min_pdsi').getInfo()
    max_pdsi_list = min_max_tiles.aggregate_array('max_pdsi').getInfo()

    min_pdsi_float = min(min_pdsi_list)
    max_pdsi_float = max(max_pdsi_list)

    print(f"Min PDSI: {min_pdsi_float }, Max PDSI: {max_pdsi_float}")

    return min_pdsi_float, max_pdsi_float

```

Codeblock 9: Funktion zur Berechnung der minimalen und maximalen Variablenwerte innerhalb der übergebenen Normalisierungsreferenz. Hier beispielhaft für die Variable des mittleren PDSI.
(Quelle: Eigene Darstellung)

```

def get_pdsi_region(region_of_interest, min_value, max_value):
    """
    Calculates the mean average PDSI (2000-2020) within the given region of
    interest and normalizes the value at the normalization reference level. Uses
    flipped normalization function, if values are smaller than 0, indicating dry
    conditions. Otherwise the normalized value is set to 0.

    Args:
        region_of_interest (ee geometry object): The region for which to
        calculate the hazard index.
        min_value (float): The minimum value of this variable within the
        normalization reference.
        max_value (float): The maximum value of this variable within the
        normalization reference.

    Returns:
        ee number object: The normalized average PDSI for the region of
        interest.
    """

    pdsi_average = get_pdsi_average()

    min_pdsi = ee.Number(min_value)
    max_pdsi = ee.Number(0)
    max_minus_min_pdsi = max_pdsi.subtract(min_pdsi)

    # Get mean pdsi for region of interest
    pdsi_region = pdsi_average.reduceRegion(
        reducer=ee.Reducer.mean(),
        geometry=region_of_interest,
        scale=90 # Originally 4638.3
    ).get('pdsi')

    pdsi_region = ee.Number(pdsi_region)

    # Normalize pdsi value for region of interest
    pdsi_region_normalized = ee.Algorithms.If(
        pdsi_region.lt(0),
        (max_pdsi.subtract(pdsi_region)).divide(max_minus_min_pdsi),
        ee.Number(0) # Set all positive values, which indicate wet conditions,
    to 0
    )

    return ee.Number(pdsi_region_normalized).getInfo()

```

Codeblock 10: Funktion zur Berechnung des mittleren Variablenwerts innerhalb des übergebenen Untersuchungsgebiets. Hier beispielhaft für die Variable des mittleren PDSI.
(Quelle: Eigene Darstellung)

5.2 Beispielhafte Anwendung und Ergebnisse

Für dieses Unterkapitel wurde das entwickelte Skript zur Berechnung des Gefahrenindex anhand praktischer Beispiele angewendet. Ziel ist es, die Funktionsweise und die Anwendbarkeit des Skripts zu demonstrieren sowie die erzielten Ergebnisse zu präsentieren. Für genauere Informationen zum dahinter stehenden Code, der über die in diesem Kapitel beschriebenen Codeausschnitte hinausgeht, s. Kapitel 5.1. Das vollständige Gefahrenindex-Skript ist außerdem im Anhang dieser Arbeit beigelegt. Weiters ist der Link zum Code auf GitHub in Kapitel 8.4 zu finden.

Zunächst wurden mit dem erstellten Skript die Gefahrenindexwerte für das Untersuchungsgebiet von Owen et al. (2023) berechnet und auf einer Karte dargestellt, um die Ergebnisse zu vergleichen. Für die Normalisierung des PDSI wurde hier jedoch, anders als im veröffentlichten Skript, die reguläre Formel zur Normalisierung gewählt, da Owen et al. (2023) dieses Vorgehen gewählt haben (s. Kapitel 4.3.1) und die Ergebnisse anderenfalls nicht vergleichbar wären. Das Untersuchungsgebiet erstreckt sich über Grenzregionen (Puffer von 100 km) in Südsudan, Äthiopien, Uganda, Kenia und Tansania. Über dieses wurde ein Gitternetz von Zellen mit einem Ausmaß von 0,25° gelegt. Der Gefahrenindexwert beläuft sich dabei auf den jeweils mittleren Wert einer Zelle. Die Höhe der von Owen et al. (2023) berechneten Gefahr, angegeben als Sextile, befindet sich in Abbildung 30.




Abb. 30: Gefahrenindexwerte in Grenzregionen.
(Quelle: Owen et al. (2023, S. 3))

Das von Owen et al. (2023) verwendete Gitternetz des Untersuchungsgebiets war dabei nicht verfügbar, jedoch die beispielhaft verwendeten Grenzstandorte als Punktdatensatz. Es wurde weiters so vorgegangen, dass entlang der Grenzen der untersuchten Länder zunächst ebenfalls ein Puffer von 100 km erstellt wurde. Um die beispielhaften Grenzstandorte wurde daraufhin ein Polygon gelegt, welches später als Cliprahmen für die mit einem Puffer erstellten Grenzgebiete diente. Über das geclippte Untersuchungsgebiet wurde mit Hilfe eines Fishnets des Packages geemap (mehr dazu in Kapitel 6.1) ebenfalls ein Gitternetz von $0,25^\circ$ gelegt. Auf diese Weise konnte das Untersuchungsgebiet von Owen et al. (2023) grob nachgeahmt werden. Für die Berechnung der Variablenwerte wurden die entsprechenden Funktionen anschließend mittels *map()* auf alle einzelnen Zellen des Fishnets angewendet und das Ergebnis als *Images* zurückgegeben, zu erkennen in Codeblock 11.

```
def get_variable_images(region_of_interest_fishnet):

    min_value, max_value = pdsi_average.min_max(normalization_reference)

    features_with_pdsi = region_of_interest_fishnet.map(lambda x:
pdsi_average.get_pdsi_region(x, min_value=min_value, max_value=max_value))

    pdsi_image = features_with_pdsi.reduceToImage(
        properties=['normalized_pdsi'],
        reducer=ee.Reducer.first()
    )
    return pdsi_image

all_variable_images = get_variable_images(region_of_interest_fishnet)
```

Codeblock 11: Anwendung der Funktionen zur Berechnung der Variablenwerte auf alle Fishnet-Zellen. Hier beispielhaft für die Variable des mittleren PDSI.
(Quelle: Eigene Darstellung)

Die Gefahrenindexwerte für die einzelnen Zellen des Fishnets wurden letztlich, wie in Kapitel 4.2 beschrieben, berechnet und das Ganze zum zur Veranschaulichung als tif-Datei exportiert. Das Ergebnis der Berechnung der Gefahrenindexwerte für das nachgeahmte Untersuchungsgebiet von Owen et al. (2023) mit dem eigens erstellten Skript ist in Abbildung 31 zu sehen.




Abb. 31: Gefahrenindexwerte als Sextile bei der Anwendung des erstellten Gefahrenindex-Skripts auf das Untersuchungsgebiet von Owen et al. (2023).
(Quelle: Eigene Darstellung)

Dabei ist zu erkennen, dass in den meisten Regionen eine ähnliche Verteilung von höheren und niedrigeren Gefahrenindexwerten vorliegt wie bei Owen et al. (2023). Lediglich in der östlichen Grenzregion von Äthiopien und in der nordöstlichen Grenzregion von Kenia sind etwas stärkere Abweichungen zu erkennen. Dies könnte damit begründet werden, dass zum Zeitpunkt der Berechnung der Datensatz zur Ermittlung der Variable Frik-tion nicht verfügbar war (s. Kapitel 6.2) und diese Variable deshalb nicht mit in die Index-werte einfließen konnte, was zu Verzerrungen der Ergebniswerte führen kann. Zudem können die berechneten Werte in anderen Sextilen liegen, da aufgrund der nicht vorhan-denen Verfügbarkeit, nicht das exakte Untersuchungsgebiet von Owen et al. (2023) ver-wendet werden konnte. Liegen so im verwendeten Gebiet höhere bzw. niedrigere maxi-male und minimale Gefahrenwerte als bei Owen et al. (2023), führt dies zu einer Verzer-rung der Sextile. Insgesamt ist jedoch eine zufriedenstellende Übereinstimmung der räum-lichen Verteilung der Gefahrenwerte gegeben.

Für eine exemplarische Anwendung, die über das Untersuchungsgebiet von Owen et al. (2023) hinausgeht, wurde das Land Österreich in ein Fishnet mit Zellen mit einer Größe von $0,1^\circ$ unterteilt, um den Gefahrenindexwert für jede einzelne Rasterzelle zu berechnen. So kann die räumliche Verteilung der Wahrscheinlichkeit für Naturgefahren innerhalb des Landes dargestellt werden. Die Ergebnisse dieser Anwendung finden sich in den Abbildungen 32 als Gefahrenindexwerte und in Abbildung 33 aufgeteilt in Sextile. Die in Abbildung 32 dargestellten Gefahrenindexwerte liegen dabei zwischen 0,197 und 0,470. Besonders hohe Gefahrenindexwerte sind dabei insbesondere im südwestlichen Vorarlberg, im südlichen Kärnten, im südlichen und nördlichen Burgenland, im östlichen Niederösterreich sowie in Wien zu finden.




Abb. 32: Die Gefahrenindexwerte für Österreich als Fishnet mit horizontalen und vertikalen Intervallen von $0,1^\circ$ Grad. Die Variable Friktion ist nicht integriert, da beim dahinterliegenden Datensatz zum Zeitpunkt der Erstellung der Grafik ein Fehler vorlag.
(Quelle: Eigene Darstellung)




Abb. 33: Die Gefahrenindexwerte als Sextile für Österreich als Fishnet mit horizontalen und vertikalen Intervallen von $0,1^\circ$ Grad. Die Variable Friktion ist nicht integriert, da beim dahinterliegenden Datensatz zum Zeitpunkt der Erstellung der Grafik ein Fehler vorlag.
(Quelle: Eigene Darstellung)

Die hohen Gefahrenwerte, die im südwestlichen Vorarlberg auftreten, werden vor allem von der Anomalie des Niederschlags angetrieben, was eine erhöhte Gefahr für Überschwemmungen anzeigt. Beim Blick auf die stärksten Hochwasserereignisse in Vorarlberg seit 1900 ist zu erkennen, dass zwei der drei Ereignisse (in den Jahren 1910 und 2005) genau in dieser Region rund um Montafon, Walgau und Klostertal auftraten. Das dritte Ereignis, welches außerhalb der erhöhten Gefahrenregion in Vorarlberg im Jahr 1999 auftrat, trat allerdings aufgrund von Bodenseehochwasser auf (Vorarlberg Wasserwirtschaft o.J., S. 15f.).

Die hohen Gefahrenwerte im Süden von Kärnten, aber auch die erhöhten Werte im Westen der Steiermark werden dabei insbesondere von der Veränderung der jährlichen Niederschlagsakkumulation getrieben. Die in Wien, Niederösterreich, Burgenland und der östlichen Steiermark vom interannuellen Variationskoeffizienten des Niederschlags, der Bodenfeuchte (Oberfläche) und der jährlichen maximalen Oberflächentemperatur. All diese Variablen zeigen in den vorliegenden Fällen eine höhere Wahrscheinlichkeit für Dürre an. Auch insgesamt wird der Gefahrenindexwert in diesen Bereichen stark von der Naturgefahr Dürre in die Höhe getrieben, da hier sieben von elf Variablen dieses Phänomen anzeigen.

Die Berechnungen, die vor allem die erhöhte Wahrscheinlichkeit für das Eintreten von Dürre anzeigen, decken sich mit vergangenen Dürreereignissen in Österreich, die vor allem in Ostösterreich in stärkerem Maße auftraten. So beispielsweise im Zuge der Hitze- welle in Europa im Jahr 2003, von der Ostösterreich besonders stark betroffen war, im Jahr 2015, in dem ein extrem trockener Sommer zu verzeichnen war, in dem es im Osten Österreichs bis zu 43 % weniger Niederschlag, als in einem durchschnittlichen Sommer gab oder im Sommer 2022 in dem es vor allem im südlichen Kärnten, der Steiermark, dem Burgenland und Wien sehr trockene Verhältnisse gab (Eybl et al., S. 1f.; GeoSphere Austria 2015, o.S.; Maraun und Roither 2023, S. 2).

6 Herausforderungen und Error-Handling

Bei der Erstellung des Skripts zur Berechnung des Gefahrenindex für jeden beliebigen Ort sind verschiedene Probleme und Herausforderungen aufgetreten, auf die in diesem Kapitel eingegangen werden soll. Dabei handelt es sich um verschiedene wiederkehrend auftretende Fehlermeldungen, als auch um Probleme mit einzelnen Datensätzen.

6.1 Skalierungs-Fehlermeldungen

Skalierungs-Fehlermeldungen treten u.a. auf, wenn die Ausführung der Berechnung zu groß ist oder die Berechnung zu lange dauert. Dabei können im Rahmen der GEE beispielsweise folgende Fehlertypen vorkommen:

- Computation timed out
- Too many concurrent aggregations
- User memory limit exceeded
- An internal error has occurred

Dies ist damit begründet, dass Rechenressourcen nicht unbegrenzt sind und für Nutzer*innen der GEE nur eine bestimmte Menge an Rechenkapazität zur Verfügung steht, damit die Ressourcen gerecht verteilt und die Server nicht überlastet werden. So gibt es u.a. bestimmte Limits bezüglich Rechenzeit und Speichernutzung (Cardille et al. 2024, S. 575; Google o.J.a, o.S.).

Da in dieser Arbeit mit globalen Datensätzen gearbeitet wird und zudem oft hunderte Bilder gleichzeitig verarbeitet werden sollen, sind Fehlermeldungen dieser Art vermehrt aufgetreten. Insbesondere die Fehler *Computation timed out* und *User memory limit exceeded* waren nur schwer zu vermeiden. Diese traten besonders häufig bei der Ermittlung der minimalen und maximalen Variablenwerte innerhalb eines oder mehrerer Länder, die für die Normalisierung gebraucht werden, auf. Da Skalierungs-Fehler im Allgemeinen am schwierigsten zu diagnostizieren und zu beheben sind, mussten verschiedene Lösungsansätze ausprobiert werden, bis die Fehler behoben werden konnten (Google o.J.a, o.S.). Dabei wurde hauptsächlich auf folgende drei Ansätze zurückgegriffen:

- Ausnutzen des Caches
- Exportmodus
- Arbeiten mit Fishnets

Da einige Operationen in GEE nach der ersten Ausführung zwischengespeichert werden, kann es teilweise helfen, eine Berechnung erneut auszuführen. Bei einer zweimaligen Ausführung kann es so gelegentlich zur erfolgreichen Berechnung kommen (Cardille et al. 2024, S. 278). Dies half allerdings nur in vereinzelt Fällen, weswegen dieser Lösungsansatz schnell verworfen wurde.

Beim Arbeiten mit dem Exportmodus wurde versucht, Ergebnisse von größeren Berechnungen via Google Drive zu exportieren, da der Exportmodus ein größeres Speicher- und Zeitkontingent als der interaktive Modus hat. So haben Berechnungen im interaktiven Modus ein Zeitlimit von fünf Minuten, wohingegen es beim Export kein Zeitlimit gibt, solange die Berechnungen angemessene Fortschritte machen (Cardille et al. 2024, S. 578). Mit dieser Herangehensweise ließ sich ein Teil der Fehlermeldungen vermeiden, allerdings trat für besonders große Berechnungen, beispielsweise wenn die minimalen und maximalen Variablenwerte für größere Länder wie Australien berechnet werden sollten, weiterhin der Fehler `User memory limit exceeded` auf.

Das Arbeiten mit Fishnets erwies sich als die effektivste Variante, die beschriebenen Fehlermeldungen im Rahmen der Berechnungen der minimalen und maximalen Variablenwerte zu umgehen. Dabei wird über eine Geometrie, im vorliegenden Fall ein Landesgrenzen-Polygon, ein sogenanntes *Fishnet*, also ein Raster aus Rechtecken, gelegt. Dabei kann das Fishnet entweder durch Festlegen horizontaler und vertikaler Intervalle in Grad (Parameter: `h_interval`, `v_interval`) erfolgen oder durch das Festlegen der Anzahl von Zeilen und Spalten (Parameter: `rows`, `cols`) (Wu 2020a, o.S.). Mit `imageCollection.map()` kann anschließend automatisch eine Funktion auf jede dieser Zellen einzeln angewendet werden. So wird die Berechnung in viele kleinere Berechnungen aufgeteilt und es werden so zunächst die minimalen und maximalen Werte für alle Zellen einzeln berechnet. Anschließend wird aus diesen Werten der jeweils gesamte minimale und maximale Wert bestimmt. Ein Beispiel wie ein solches Fishnet für Österreich aussehen kann, ist in Abbildung 34 zu finden.




Abb. 34: Beispieldarstellung eines Fishnets über Österreich mit $h_interval = 0.3$ und $v_interval = 0.3$.
(Quelle: Eigene Darstellung, BEV (2023, o.S.)).

Es wurde darauf verzichtet, das Fishnet entsprechend der Ländergrenzen zu clippen, da die Berechnungszeit dadurch wieder stark erhöht werden würde und dies in Testfällen erneut zur Fehlermeldung aufgrund überschrittenen Speichers führte.

6.2 Fehler bezüglich Datensätzen

Da die verwendeten Datensätze nicht lokal auf der eigenen Maschine gespeichert sind, sondern über die GEE bezogen werden, kann es jederzeit zu neu auftretenden Problemen bei der Nutzung der Datensätze kommen. Es besteht beispielsweise das Risiko, dass die Verfügbarkeit der Daten durch Serverausfälle oder Wartungsarbeiten beeinträchtigt wird. Außerdem können Datensätze jederzeit aus dem Datenkatalog der Google Earth Engine entfernt werden.

Bei der Nutzung der GEE kam es im Rahmen der vorliegenden Arbeit zu Problemen mit dem Datensatz *Friction Surface*. Ein Arbeiten mit diesem Datensatz war dabei über mehrere Wochen nicht möglich, da eine Beschädigung des Datensatzes vorlag. Folgende Fehlermeldung bezüglich der Störung trat dabei auf:

EEException: Asset 'Oxford/MAP/friction_surface_2019@1641990724602367' is corrupted

Auch ist nicht beeinflussbar, wann und wie oft die Daten des GEE Datenkatalogs aktualisiert werden oder wann/welche neue Daten hinzugefügt werden. Dies kann zu Problemen führen, wenn aktuelle Daten erforderlich sind, um genaue Analysen durchzuführen. So wäre es beispielsweise interessant gewesen, bereits auf die Beta-Version des CHIRPS-Datensatzes zugreifen zu können, um eine globale Abdeckung zu gewährleisten.

6.3 Weitere Fehlermeldungen

Werden Untersuchungsgebiete mit relativ kleiner Fläche ausgewählt, muss der Maßstab bei der Berechnung des mittleren Variablenwerts für das Gebiet gegebenenfalls angepasst werden, indem diesem eine Zahl zugewiesen wird, die klein genug ist. Wird dies nicht gemacht, besteht die Möglichkeit, dass der Variablenwert innerhalb des Untersuchungsgebiets nicht gespeichert ist und dem mittleren Variablenwert für das Untersuchungsgebiet *None* zugewiesen wird und infolgedessen ein *NoneType-Objekt* entsteht. Bei der Berechnung des normalisierten Werts führt dies wiederum dazu, dass ein *TypeError* entsteht, da es nicht möglich ist gemeinsame Berechnungen mit den Typen *NoneType* und *Float* durchzuführen.

Eine weitere Fehlermeldung entstand bei dem Versuch, die aus dem SRTM DHM berechnete Hangneigung auf globaler Ebene in der räumlichen Originalauflösung von 90 m als TIF in Google Drive zu exportieren. Dabei würde für den Export zu viel Speicher benötigt werden, der so in der frei verfügbaren Version nicht vorliegt. Es wurde folglich eine gröbere Auflösung gewählt und darauf verzichtet, die Daten in Originalauflösung herunterzuladen.

7 Anleitung zur Nutzung des Gefahrenindex-Skripts

In diesem Kapitel wird beschrieben, wie das erstellte Gefahrenindex-Skript für eigene Zwecke verwendet werden kann und worauf dabei zu achten ist. Voraussetzung für die Nutzung des Skripts ist die Installation der im Skript unter *Imports* angeführten Packages sowie ein Google Earth Engine Account, der entsprechend authentifiziert werden muss. Das vollständige Skript findet sich im Anhang dieser Arbeit. Weiters findet sich der Link zum Skript auf GitHub in Kapitel 8.4.

Bei der Nutzung des Skripts müssen zunächst die *Untersuchungsgebiete* definiert werden, für die der Gefahrenindex berechnet werden soll. Dabei können die Untersuchungsgebiete entweder innerhalb des Notebooks als GEE Geometry – beispielsweise als BoundingBox, Point oder Polygon – erstellt werden, indem die entsprechenden Koordinaten übergeben werden oder es werden lokale Dateien im Format GeoJSON oder Shapefile importiert. Zur Überprüfung können die übergebenen Untersuchungsgebiete anschließend in einer Karte visualisiert werden – beispielhaft dargestellt in Abbildung 35.




Abb. 35: Visualisierung eines Untersuchungsgebiets des Gefahrenindex.
(Quelle: Eigene Darstellung)

Anschließend muss die *Normalisierungsgrundlage* definiert werden. Dies kann beispielsweise auf Länderebene erfolgen. Als Grundlage dafür kann der von der UN veröffentlichte GAUL-Datensatz verwendet werden. Dieser beinhaltet Daten zu internationalen Grenzen und Verwaltungseinheiten (auf 500 m vereinfacht) (Google o.J.b, o.S.). So ist es möglich mit Hilfe des Ländernamens das entsprechende Land als Normalisierungs-

grundlage auszuwählen. Über die Normalisierungsgrundlage wird nachfolgend ein Fishnet gelegt, um Fehlermeldungen zu vermeiden (s. Kapitel 6.1). Entsprechend der Größe der Normalisierungsgrundlage müssen die Werte für die horizontalen und vertikalen Intervalle in Grad des Fishnets bzw. die Anzahl der Reihen und Spalten angepasst werden, da es anderenfalls ebenfalls zu Fehlermeldungen kommen kann. In Tabelle 7 finden sich passende Werte für die Intervalle in Grad für einige Beispielländer. Die Normalisierungsgrundlage kann daraufhin zur Überprüfung in einer Karte visualisiert werden.

Tabelle 7: $h_interval$ und $v_interval$ -Werte für ausgewählte Normalisierungsgrundlagen.
(Quelle: Eigene Darstellung)

Normalisierungsgrundlage	$h_interval$	$v_interval$
Australia	4	4
India	1	1
France	0.6	0.6
Spain	0.6	0.6
Austria	0.3	0.3

Sind die Untersuchungsgebiete sowie die Normalisierungsreferenz definiert, können die Index-Werte für die Untersuchungsgebiete berechnet werden. Dafür müssen die definierten Untersuchungsgebiete zunächst in einer Liste zusammengestellt sowie die Namen der Untersuchungsgebiete, so wie diese später in der Ergebnistabelle aufscheinen sollen, in einer weiteren Liste zusammengetragen werden. Mit der Ausführung des verbleibenden Teils des Skripts werden dann die normalisierten Werte der einzelnen Variablen sowie die Gefahrenindexwerte für die jeweiligen Untersuchungsgebiete berechnet, in einem Dataframe ausgegeben und als csv-Datei abgespeichert. Sollen einzelne Variablen nicht in die Indexberechnung miteinbezogen werden, müssen diese lediglich auskommentiert werden.

8 Schlussbetrachtung

In diesem Kapitel werden zunächst die Ergebnisse der vorliegenden Arbeit kurz zusammengefasst und diskutiert, bevor die Limitationen dieser Arbeit aufgezeigt werden. Anschließend wird ein Ausblick für zukünftige Forschung gegeben, die aufbauend auf dem entwickelten Skript zur Berechnung des Gefahrenindex erfolgen kann, um weitere Fortschritte im Bereich der Gefahrenbewertung zu ermöglichen.

8.1 Diskussion

Das zentrale Ziel dieser Arbeit war es, ein Skript zur Berechnung des Gefahrenindex für jeden beliebigen Ort nach Owen et al. (2023) zu entwickeln und frei zur Verfügung zu stellen. Die damit einhergehende zentrale Fragestellung, auf welche Art und Weise diese Entwicklung möglich ist, wurde umfassend untersucht und wesentliche Erkenntnisse zur Beantwortung dieser und auch der damit einhergehenden Arbeitsfragen, gewonnen. Diese sollen in diesem Kapitel kurz zusammengefasst und diskutiert werden.

Zur Beantwortung der ersten Arbeitsfrage wurden in der vorliegenden Arbeit zunächst verschiedene methodologischen Ansätze im Bereich der Naturgefahren- und Risikoanalyse vorgestellt. Dabei wurden unterschiedliche Analysearten präsentiert, bspw. singuläre Gefahrenanalysen, die sich von solchen abgrenzen, die mehrere Naturgefahren mit einbeziehen (mit bzw. ohne Berücksichtigung von Interaktionen), als auch Risikoanalysen, die darüber hinaus Vulnerabilitäten betrachten (s. Kapitel 2.4). Zur Bewertung des Gefahren- oder Risikoausmaßes stehen dabei qualitative, semi-quantitative, als auch quantitative Methoden zur Verfügung (s. Kapitel 2.4.1-2.4.3). Abhängig vom spezifischen Anwendungsfall können unterschiedliche Methoden zur Bewertung des Gefahren- oder Risikoausmaßes bevorzugt werden, da jeder Ansatz unterschiedliche Stärken und Schwächen aufweist (s. Kapitel 2.4.5).

In der vorliegenden Arbeit wurde zur Bewertung von mehreren Naturgefahren vom Index-basierten Ansatz, einem semi-quantitativen Ansatz (s. Kapitel 2.4.2), Gebrauch gemacht. Bei diesem werden verschiedene Faktoren bewertet, üblicherweise zwischen null und eins standardisiert und rechnerisch zu einem Indexwert zusammengefasst. Auf diese Art und Weise ist eine relative Rangfolge der Gefahrenintensität zwischen verschiedenen Untersuchungsgebieten möglich und es besteht eine geringere Subjektivität als bei rein qualitativen Methoden. Zudem ist diese Methode meist simpler anzuwenden, als es bei quantitativen Methoden der Fall ist. Wechselwirkungen wurden beim entwickelten Skript zum Gefahrenindex nicht berücksichtigt, da dazu eine umfangreichere Datenverfügbarkeit notwendig wäre. Außerdem soll der Index ausschließlich global konsistente Daten

einbeziehen. Des weiteren ist die Entscheidung damit zu begründen, dass das entwickelte Skript auf dem Gefahrenindex von Owen et al. (2023) beruht, die ebenfalls keine Interaktionen zwischen Naturgefahren miteinbeziehen und dass die Entwicklung des Skripts so einfacher möglich ist.

Auf die Beantwortung der Frage zum aktuellen Forschungsstand wurde in Kapitel 2.5 eingegangen, wobei verschiedene bedeutende Paper zum Themenbereich vorgestellt wurden. Dabei war auffällig, dass Interaktionen zwischen Gefahren bislang häufig ignoriert und diese lediglich aufsummiert werden, da eine Umsetzung solcher Methoden simpler ist. Allerdings kann das dazu führen, dass Gefahren bzw. Risiken unterschätzt werden und so Managementprioritäten verzerrt werden (s. Kapitel 2.4.5). Für ein aussagekräftiges Ergebnis zur Entscheidungsfindung, sind demnach Methoden vorzuziehen, die die Wechselwirkungen von Gefahren und ggf. Vulnerabilitäten berücksichtigen, allerdings lässt sich auch der Einsatz von anderen Methoden, etwa wegen ihrer Einfachheit, begründen.

Mit der Beantwortung der dritten Arbeitsfrage sollte ein Überblick über bereits bestehende Gefahren- und Risiko-Tools gegeben werden, als auch ein Bewusstsein dafür geschaffen werden, welche Stärken und Limitationen solche Tools aufweisen können. Dies ist u.a. in dem Sinne relevant, dass so auch die Stärken und Limitationen des eigens entwickelten Gefahrntools besser eingeschätzt und mögliche Verbesserungen in Zukunft gegebenenfalls realisiert werden können. Dies ist auch von entscheidender Bedeutung, um sicherzustellen, dass Tools die zukünftig entwickelt werden, den aktuellen Anforderungen gerecht werden und einen maximalen Nutzen für die Gefahren- und Risikomanagementpraxis bieten können.

Die Beantwortung der Arbeitsfrage bezüglich der besten frei verfügbaren Datensätze für die Realisierung des Tools war entscheidend, um fundierte Entscheidungen bezüglich der Datenbasis zu treffen. Dabei gilt es, eine Vielzahl von Kriterien zu berücksichtigen, einschließlich der Qualität, Aktualität und der Verfügbarkeit der Daten im Datenkatalog der GEE. Aber auch eine möglichst hohe räumliche Auflösung sowie eine (nahezu) globale Datenabdeckung war bei der Auswahl entscheidend. Durch die Analyse und Auswahl geeigneter Datensätze können nicht nur die Stärken und Potentiale des Tools maximiert werden, sondern auch potenzielle Einschränkungen und Herausforderungen erkannt werden. Dies ermöglicht es, das Skript effektiv zu gestalten und die spezifischen Anforderungen an das Skript zu erfüllen. Darüber hinaus bietet diese Auseinandersetzung die Möglichkeit, zukünftige Anpassungen im Hinblick auf die Datenintegration zu planen und umzusetzen, wie beispielsweise die Umstellung auf den erweiterten CHIRPS Datensatz, sobald dieser zur Verfügung steht.

Die Beantwortung der zentralen Forschungsfrage zur Entwicklung eines Open-Source-Tools für die Berechnung des Gefahrenindex, basierend auf dem Ansatz von Owen et al. (2023), war von zentraler Bedeutung für die praktische Entwicklung des Skripts. Die Erstellung eines Jupyter Notebooks, mit integrierten Python-Skripten, und die Nutzung der GEE API, haben dabei eine benutzer*innenfreundliche Methode zur Berechnung des Gefahrenindex für jeden beliebigen Ort ermöglicht. Der Aufbau des Skripts wurde in Kapitel 5.1 erläutert und es wurden exemplarisch Codeausschnitte vorgestellt. Der gewählte Ansatz bietet die Möglichkeit, das Skript den eigenen Bedürfnissen anzupassen, sowie die Reproduzierbarkeit der Ergebnisse zu gewährleisten. Es können nach Belieben Datensätze weggelassen oder neue Datensätze hinzugefügt werden, die möglicherweise als Zeiger für bislang nicht einbezogene Naturgefahren dienen. Auch die Grundlage der Normalisierung kann an die eigenen Bedürfnisse und Untersuchungsgebiete angepasst werden. In Kapitel 5.2 wurde zudem die Anwendbarkeit und Plausibilität des Skripts überprüft, indem das Skript beispielhaft auf das Untersuchungsgebiet von Owen et al. (2023) sowie auf die Fläche von Österreich angewendet wurde. So ließ sich feststellen, dass das Skript verlässliche Ergebnisse liefert. In Kapitel 7 wurde darüber hinaus erläutert, wie das Skript für eigene Zwecke zu nutzen ist.

Die Erstellung des Gefahrenindex-Skripts verdeutlicht außerdem die Potenziale, die in der Nutzung einer Cloud-Umgebung kombiniert mit frei verfügbaren Datensätzen, wie die GEE es bietet, stecken. Durch die hohe Rechenleistung können komplexe Analysen und Berechnungen durchgeführt werden, die auf einem lokalen Computer kaum realisierbar wären. Mit dem Zugriff auf eine Vielzahl von Datensätzen, darunter meteorologische Daten und geophysikalische Informationen, lassen sich detaillierte Gefahrenindizes erstellen, die für verschiedene Anwendungen, wie dem Katastrophenmanagement oder der Stadtplanung, von großer Bedeutung sein können.

8.2 Limitationen

Das entwickelte Skript zur Berechnung des Gefahrenindex für jeden beliebigen Ort stellt einen wichtigen Beitrag zur Naturgefahrenbewertung dar und kann auch als Teil einer Risikoanalyse zum Einsatz kommen. Trotzdem gibt es einige Limitationen, auf die im Zuge dieses Unterkapitels eingegangen werden soll.

Zunächst ist anzumerken, dass Klimawandelprognosen bislang nicht in das entwickelte Skript integriert sind. Obwohl Klimawandelmodelle zunehmend zeigen, dass Naturgefahren wie Dürre oder Überschwemmungen häufiger und intensiver werden, spiegeln die aktuellen Berechnungen des Gefahrenindex diese zukünftigen Entwicklungen nur

teilweise wider (Masson-Delmotte et al. 2023, S. 8). Dies könnte die Relevanz des Gefahrenindex in Zeiten des Klimawandels einschränken, da die ausgegebene Bewertung möglicherweise nicht die tatsächlichen Gefahren widerspiegelt, denen Untersuchungsgebiete zukünftig ausgesetzt sein könnten.

Eine weitere Limitation ist die Abhängigkeit des Gefahrentools von der GEE. Obwohl die GEE eine leistungsstarke Plattform mit einem umfangreichen Datenkatalog bietet, kann die Verfügbarkeit und Aktualität dieser Daten variieren. Änderungen im Datenkatalog oder technische Probleme könnten so die Nutzbarkeit des Skripts beeinträchtigen, wie dies auch während der Erstellung des Skripts hinsichtlich der Variable der Friktion der Fall war (s. Kapitel 6.2). Trotz der vielen Vorteile, die die GEE bietet, ist es wichtig, diesen Faktor zu berücksichtigen.

Weiters ist zu beachten, dass die in den Index einbezogenen Daten auf Reanalyse-Datensätzen beruhen. Laut ECMWF (2020) ist „the quality of a reanalysis [...] as good as the quality and density of the observational system it relies on, as it uses the combination of the weather model and the available observations to "infer" the state of the atmosphere at a given point in time“. Dies bedeutet, dass die Genauigkeit der Reanalyse-Daten stark vom Umfang und von der Qualität der verfügbaren Beobachtungsdaten abhängt. In Regionen mit dichter und qualitativ hochwertiger Datenabdeckung, sind die Ergebnisse der Reanalysen so zuverlässiger. Umgekehrt steigt die Unsicherheit in den Daten in Regionen mit spärlichen oder weniger präzisen Beobachtungen, was bei Analysen in diesen Gebieten besondere Vorsicht erfordert (Seneviratne et al. 2023, S. 1537).

Eine weitere Limitation bezüglich der Indexberechnung ist laut Owen et al. (2023, S. 6) „[t]he reliance on long-term temporal averages of satellite-derived products with coarse spatial resolutions [as it] inevitably overlooks short-term variations in exposure and long-term exposure trends“. Dies kann gegebenenfalls zu einer unzureichenden Darstellung der tatsächlichen Bedingungen führen. Auch feinere Details und äußerst kleinräumige Variationen können aufgrund der räumlichen Auflösung der herangezogenen Daten nicht immer erfasst werden. Dies ist ebenfalls der Fall, wenn die Fläche der Untersuchungsgebiete zu groß gewählt wird, da die Variablenwerte auf dem mittleren Wert innerhalb des Untersuchungsgebiets beruhen.

Des Weiteren werden bei der Berechnung des Gefahrenindex bislang lediglich drei Naturgefahren einbezogen: Dürre, Überschwemmung und Erdbeben. Folglich wird nicht die gesamte Bandbreite an potenziell relevanten Naturgefahren abdeckt. Für Regionen, die von zusätzlichen Gefahren bedroht sind, sollte die Auswahl der Variablen erweitert und so, durch das Einbeziehen weiterer Datensätze, die Indexberechnung angepasst werden.

Dabei besteht jedoch die Herausforderung, Datensätze ausfindig zu machen, die über die GEE verfügbar sind und gleichzeitig den Anforderungen an die globale Datenkonsistenz sowie die hohe räumliche Auflösung gerecht werden. Zudem wird der berechnete Indexwert aufgrund des hohen Anteils an Variablen, die Dürre anzeigen können (7 von 11 Variablen), maßgeblich von diesem Phänomen beeinflusst. In Gebieten, die eine hohe Anfälligkeit für Dürren aufweisen, ist der Gefahrenindexwert folglich höher, als in Gebieten mit einer hohen Anfälligkeit für Überschwemmungen oder Erdbeben. Diese Verzerrung muss bei der Nutzung des Gefahrenindex-Skripts beachtet werden.

Zusammenfassend lässt sich sagen, dass die beschriebenen Limitationen, wie die fehlende Integration von Klimawandelprognosen, die Abhängigkeit von der GEE und die Verwendung von Reanalyse-Datensätzen, bei der Anwendung des Skripts berücksichtigt werden sollten. Trotz dieser Einschränkungen bleibt das Skript ein hilfreiches Werkzeug, das durch zukünftige Anpassungen und Erweiterungen (s. Kapitel 8.3) weiter optimiert werden kann.

8.3 Fazit mit Ausblick für zukünftige Forschung

Durch die Entwicklung des Open-Source-Skripts können Entscheidungsträger*innen, Forscher*innen und Interessierte weltweit auf eine Methode zur Bewertung von Gefahren zugreifen, indem sie sich den Gefahrenindexwert für ihre spezifischen Untersuchungsgebiete ausgeben lassen und verschiedene Untersuchungsgebiete auf Basis einheitlicher Daten miteinander vergleichen. Darüber hinaus bietet das Veröffentlichen von Open-Source-Technologien die Möglichkeit, diese kontinuierlich zu verbessern und anzupassen. Dies fördert im vorliegenden Fall nicht nur die Innovation im Bereich der Gefahrenbewertung, sondern unterstützt auch die Entwicklung einer offenen und transparenten Forschungsgemeinschaft. So leistet die vorliegende Arbeit einen Beitrag für das Verständnis bezüglich des aktuellen Stands von Naturgefahren- und Risikobewertungen und bietet eine einfache Möglichkeit eine erste Einschätzung bezüglich des Gefahrenausmaßes innerhalb beliebiger Untersuchungsgebiete zu erhalten. Aufbauend auf der vorliegenden Arbeit kann das Skript zur globalen Berechnung des Gefahrenindex zudem in verschiedenen Bereichen ergänzt und erweitert werden. Das Gefahrenindex-Skript kann somit auch als Ausgangspunkt für weitere Entwicklungen gesehen werden.

Eine dieser möglichen Erweiterungen wäre es, eine grafische Benutzer*innenoberfläche (anstelle des reinen Skript-Formats) zu entwickeln. Mit dieser könnten Nutzer*innen beispielsweise mit Hilfe von Textfeldern oder Dropdown-Menüs verschiedene Einstellungen treffen, mit einem Upload-Formular die Geometrie der Untersuchungsgebiete

hochladen oder darüber hinaus auf einer interaktiven Karte Untersuchungsgebiete auswählen. So wären keinerlei Programmierkenntnisse zur Berechnung des Gefahrenindex notwendig und das Tool würde einer breiteren Nutzer*innenbasis zur Verfügung stehen. Das Skript könnte weiters durch eine mobile Anwendung ergänzt werden, um den Zugriff bei Feldarbeiten zu erleichtern.

Darüber hinaus könnten zukünftig bei Erweiterung des GEE-Datenkatalogs mehr Variablen in den Gefahrenindex einfließen, um die Aussagekraft des Index weiter zu erhöhen und gegebenenfalls weitere Naturgefahren miteinzubeziehen. Zukünftig könnte zudem darauf geachtet werden, dass je Naturgefahr eine ähnliche Anzahl an entsprechenden Variablen in den Index einfließt, um so eine ausgewogenere Berücksichtigung aller Naturgefahren zu gewährleisten. Außerdem könnte der Gefahrenindex um die Komponente der Exposition erweitert werden, indem beispielsweise Bevölkerungsdaten eingebunden werden. Diesbezüglich würde sich der Datensatz *Gridded Population of World Version 4* (GPWv4) anbieten, der die Verteilung der globalen Bevölkerung für die Jahre 2000, 2005, 2010, 2015 und 2020 modelliert und die geschätzte Anzahl an Personen pro Zelle mit einer räumlichen Auflösung von 1 km darstellt (Center For International Earth Science Information Network - CIESIN-Columbia University 2018).

Da unter dem Klimawandel Naturgefahren wie Dürre oder Überschwemmungen vermehrt auftreten, sollten die verwendeten Daten stets aktuell gehalten werden. Zudem könnten zukünftig auch Daten aus Klimawandelmodellen mit einbezogen werden. So stellen Pendergrass et al. (2017, S. 6) beispielsweise fest: „[P]recipitation variability simulated by climate models from daily and monthly to interannual and decadal timescales increases robustly over almost all land areas in response to anthropogenic warming in most models“. Dies kann wiederum zu einem vermehrten Auftreten von Überschwemmungen führen und ist deshalb ein wichtiger Faktor, den es – sowie weitere Ergebnisse aus Klimamodellen – zukünftig in Gefahrenanalysen einzubinden gilt.

In den letzten Jahren wurden zahlreiche Fortschritte und neue Erkenntnisse im Bereich der Risikobewertung erzielt, die auch die Gefahrenbewertung als integralen Bestandteil umfasst. Dennoch gibt es laut Geiß et al. (2023b, S. 777) „still a gap between science and practice that needs to be bridged in order to reduce the risk for people and societies“. Die vorliegende Arbeit soll einen Teil dazu beitragen diese Lücke zu schließen, indem das entwickelte Skript eine zugängliche Methode zur Berechnung des Gefahrenindex bereitstellt und somit die Anwendung wissenschaftlicher Erkenntnisse in der Praxis erleichtert und die Entscheidungsfindung bezüglich des Gefahren- und Risikomanagements unterstützt.

8.4 Datenverfügbarkeit

Das Jupyter Notebook und die dazugehörigen Python-Files, die zur Berechnung des Gefahrenindex für jeden beliebigen Ort verwendet werden können, sind im folgenden GitHub-Repository verfügbar: https://github.com/mainemaine01/natural_hazard_index

Literaturverzeichnis

- Abatzoglou, John T.; Dobrowski, Solomon Z.; Parks, Sean A.; Hegewisch, Katherine C. (2018): TerraClimate, a high-resolution global dataset of monthly climate and climatic water balance from 1958-2015. In: *Scientific data* 5, S. 170191. DOI: 10.1038/sdata.2017.191.
- Alfieri, Lorenzo; Bisselink, Berny; Dottori, Francesco; Naumann, Gustavo; Roo, Ad de; Salamon, Peter et al. (2017): Global projections of river flood risk in a warmer world. In: *Earth's Future* 5 (2), S. 171–182. DOI: 10.1002/2016EF000485.
- Bernal, Gabriel A.; Cardona, Omar-Dario (2018): NEXT GENERATION CAPRA SOFTWARE.
- Birkmann, J.; Böhm, H. R.; Buchholz, F.; Büscher, D.; Daschkeit, A.; Ebert, S. et al. (2013): Glossar Klimawandel und Raumentwicklung. 2. überarbeitete Fassung. Hannover: Akademie für Raumforschung und Landesplanung (E-Paper der ARL, 10). Online verfügbar unter <http://nbn-resolving.de/urn:nbn:de:0156-73571>.
- Birkmann, Jörn (2008): Globaler Umweltwandel, Naturgefahren, Vulnerabilität und Katastrophenresilienz. In: *RuR* 66 (1). DOI: 10.1007/BF03184043.
- Brandolini, Filippo; Domingo-Ribas, Guillem; Zerboni, Andrea; Turner, Sam (2021): A Google Earth Engine-enabled Python approach for the identification of anthropogenic palaeo-landscape features. In: *Open research Europe* 1, S. 22. DOI: 10.12688/open-reseurope.13135.2.
- Budimir, M. E. A.; Atkinson, P. M.; Lewis, H. G. (2015): A systematic review of landslide probability mapping using logistic regression. In: *Landslides* 12 (3), S. 419–436. DOI: 10.1007/s10346-014-0550-5.
- Bundesamt für Bevölkerungsschutz und Katastrophenhilfe (Hg.) (o.J.): Naturgefahren. Online verfügbar unter https://www.bbk.bund.de/DE/Themen/Kritische-Infrastrukturen/KRITIS-Gefahrenlagen/Naturgefahren/naturgefahren_node.html#vt-sprg-4, zuletzt aktualisiert am 12.04.2024, zuletzt geprüft am 12.04.2024.
- CAPRA (Hg.) (o.J.): CAPRA. About Us. Online verfügbar unter <https://ecapra.org/about-us>, zuletzt aktualisiert am 13.05.2024, zuletzt geprüft am 13.05.2024.
- Cardille, Jeffrey A.; Crowley, Morgan A.; Saah, David; Clinton, Nicholas E. (2024): Cloud-Based Remote Sensing with Google Earth Engine. Cham: Springer International Publishing.
- Carrão, Hugo; Naumann, Gustavo; Barbosa, Paulo (2016): Mapping global patterns of drought risk: An empirical framework based on sub-national estimates of hazard, exposure and vulnerability. In: *Global Environmental Change* 39, S. 108–124. DOI: 10.1016/j.gloenvcha.2016.04.012.
- Center For International Earth Science Information Network - CIESIN-Columbia University (Hg.) (2018): Gridded Population of the World, Version 4 (GPWv4): Population Count, Revision 11.
- Ciurean, R.; Gill, J.; Reeves, H. J.; O'Grady, S.; Aldridge, T. (2018): Review of multi-hazards research and risk assessments (British Geological Survey Open Report).
- Copernicus Climate Change Service (Hg.) (2024): Surface air temperature for January 2024. Online verfügbar unter <https://climate.copernicus.eu/surface-air-temperature-january-2024>, zuletzt aktualisiert am 20.08.2024, zuletzt geprüft am 22.08.2024.

CRED (Hg.) (o.J.): EM-DAT - The international disaster database. Online verfügbar unter <https://www.emdat.be/>, zuletzt aktualisiert am 05.04.2024, zuletzt geprüft am 16.04.2024.

Deligne, Natalia I.; Horspool, Nick; Canessa, Silvia; Matcham, Iain; Williams, George T.; Wilson, Grant; Wilson, Thomas M. (2017): Evaluating the impacts of volcanic eruptions using RiskScape. In: *J Appl. Volcanol.* 6 (1). DOI: 10.1186/s13617-017-0069-2.

Delmonaco, Giuseppe; Margottini, Claudio; Spizzichino, Daniele (2006): Report on new methodology for multi-risk assessment and the harmonisation of different natural risk maps (Deliverable 3.1).

Dikau, Richard; Weichselgartner, Juergen; Hufschmidt, Gabriele (2020): Gefahren - Risiken - Katastrophen. In: Hans Gebhardt, Rüdiger Glaser, Ulrich Radtke, Paul Reuber und Andreas Vött (Hg.): *Geographie. Physische Geographie und Humangeographie.* 3., [überarbeitete und erweiterte] Auflage. Berlin, Heidelberg: Springer (Lehrbuch), S. 1101–1142.

Dilley, Maxx; Chen, Robert S.; Deichmann, Uwe (2005): Natural Disaster Hotspots. A Global Risk Analysis. Washington, DC: World Bank. Online verfügbar unter <http://hdl.handle.net/10986/7376>.

Djordjevic, Milan; Radivojevic, Aleksandar; Dragovic, Ranko; Filipovic, Ivan (2016): Exposure to earthquakes - distribution and change of the world's population with regard to disposition of seismic activities. In: *J geographical I JC* 66 (3), S. 353–370. DOI: 10.2298/IJGI1603353D.

ECMWF (Hg.) (2020): Reanalysis Q&As. Online verfügbar unter <https://climate.copernicus.eu/reanalysis-qas>, zuletzt aktualisiert am 23.07.2024, zuletzt geprüft am 23.07.2024.

ECMWF (Hg.) (2023): Fact sheet: Reanalysis. Online verfügbar unter <https://www.ecmwf.int/en/about/media-centre/focus/2023/fact-sheet-reanalysis>, zuletzt geprüft am 08.07.2024.

Entekhabi, Dara; Njoku, Eni G.; O'Neill, Peggy E.; Kellogg, Kent H.; Crow, Wade T.; Edelstein, Wendy N. et al. (2010): The Soil Moisture Active Passive (SMAP) Mission. In: *Proc. IEEE* 98 (5), S. 704–716. DOI: 10.1109/JPROC.2010.2043918.

Eurpäische Kommission (Hg.) (o.J.): Applied multi risk mapping of natural hazards for impact assessment. Online verfügbar unter <https://cordis.europa.eu/project/id/511208/de>, zuletzt aktualisiert am 16.12.2011, zuletzt geprüft am 07.05.2024.

Eybl, Jutta; Godina, Reinhold; Lalk, Petra; Lorenz, Peter; Müller, Gabriele; Weilguni, Viktor: Trockenheit in Österreich im Jahr 2003. Ein hydrologischer Situationsbericht. Hg. v. Bundesministerium für Land und Forstwirtschaft, Umwelt und Wasserwirtschaft.

FEMA (Hg.) (o.J.a): Hazus User & Technical Manuals. Online verfügbar unter <https://www.fema.gov/flood-maps/tools-resources/flood-map-products/hazus/user-technical-manuals>, zuletzt aktualisiert am 11.04.2024, zuletzt geprüft am 10.05.2024.

FEMA (Hg.) (o.J.b): National Risk Index. Learn More. Online verfügbar unter <https://hazards.fema.gov/nri/learn-more>, zuletzt aktualisiert am 10.05.2024, zuletzt geprüft am 10.05.2024.

FEMA (Hg.) (o.J.c): What is Hazus? Online verfügbar unter <https://www.fema.gov/flood-maps/tools-resources/flood-map-products/hazus/about>, zuletzt aktualisiert am 28.03.2023, zuletzt geprüft am 10.05.2024.

FEMA (Hg.) (2022): Hazus Flood Technical Manual. Hazus 5.1.

FEMA (Hg.) (2023): National Risk Index. Technical Documentation.

Field, C. B.; Barros, V.; Stocker, T. F.; Qin, D.; Dokken, D. J.; Ebi, K. L. et al. (2012): Summary for Policymakers. In: IPCC (Hg.): Managing the risks of extreme events and disasters to advance climate change adaptation. Special report of the Intergovernmental Panel on Climate Change. Unter Mitarbeit von C. B. Field, V. Barros, T. F. Stocker, D. Qin, D. J. Dokken, K. L. Ebi et al. Cambridge: Cambridge University Press.

Fiolleau, Sylvain; Uhlemann, Sebastian; Falco, Nicola; Dafflon, Baptiste (2023): Assessing probability of failure of urban landslides through rapid characterization of soil properties and vegetation distribution. In: *Geomorphology* 423, S. 108560. DOI: 10.1016/j.geomorph.2022.108560.

Free Software Foundation (Hg.) (o.J.): What is free software? Online verfügbar unter <https://www.fsf.org/about/what-is-free-software>, zuletzt aktualisiert am 15.02.2024, zuletzt geprüft am 05.03.2024.

Funk, Chris; Peterson, Pete; Landsfeld, Martin; Pedreros, Diego; Verdin, James; Shukla, Shraddhanand et al. (2015): The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes. In: *Scientific data* 2, S. 150066. DOI: 10.1038/sdata.2015.66.

Gallina, Valentina; Torresan, Silvia; Critto, Andrea; Sperotto, Anna; Glade, Thomas; Marcomini, Antonio (2016): A review of multi-risk methodologies for natural hazards: Consequences and challenges for a climate change impact assessment. In: *Journal of Environmental Management* 168, S. 123–132. DOI: 10.1016/j.jenvman.2015.11.011.

Gebremichael, Mekonnen; Hossain, Faisal (2010): Satellite Rainfall Applications for Surface Hydrology. Dordrecht: Springer Netherlands.

Geiß, Christian; Priesmeier, Peter; Aravena Pelizari, Patrick; Soto Calderon, Angélica Rocio; Schoepfer, Elisabeth; Riedlinger, Torsten et al. (2023a): Benefits of global earth observation missions for disaggregation of exposure data and earthquake loss modeling: evidence from Santiago de Chile. In: *Nat Hazards* 119 (2), S. 779–804. DOI: 10.1007/s11069-022-05672-6.

Geiß, Christian; Schoepfer, Elisabeth; Riedlinger, Torsten; Taubenböck, Hannes (2023b): Editorial: novel tools for multi-risk assessment. In: *Nat Hazards* 119 (2), S. 773–778. DOI: 10.1007/s11069-023-06204-6.

GeoSphere Austria (Hg.) (2015): Werden Dürre-Perioden im Alpenraum häufiger? Online verfügbar unter <https://www.zamg.ac.at/cms/de/klima/news/werden-duerre-perioden-im-alpenraum-haeufiger>, zuletzt aktualisiert am 23.07.2024, zuletzt geprüft am 23.07.2024.

Gill, Joel C.; Malamud, Bruce D. (2016): Hazard interactions and interaction networks (cascades) within multi-hazard methodologies. In: *Earth Syst. Dynam.* 7 (3), S. 659–679. DOI: 10.5194/esd-7-659-2016.

Glaser, Rüdiger; Erfurt, Mathilde (2020): Dürre als globales Phänomen. In: Hans Gebhardt, Rüdiger Glaser, Ulrich Radtke, Paul Reuber und Andreas Vött (Hg.): Geographie. Physische Geographie und Humangeographie. 3., [überarbeitete und erweiterte] Auflage. Berlin, Heidelberg: Springer (Lehrbuch), S. 1183–1188.

GNS Science (Hg.) (o.J.): RiskScape. Online verfügbar unter <https://www.gns.cri.nz/research-projects/riskscape/>, zuletzt aktualisiert am 09.05.2024, zuletzt geprüft am 09.05.2024.

- Google (Hg.) (o.J.a): Debugging guide. Online verfügbar unter <https://developers.google.com/earth-engine/guides/debugging>, zuletzt geprüft am 13.07.2024.
- Google (Hg.) (o.J.b): FAO GAUL 500m Simplified. Global Administrative Unit Layers 2015, Country Boundaries. Online verfügbar unter https://developers.google.com/earth-engine/datasets/catalog/FAO_GAUL_SIMPLIFIED_500m_2015_level0, zuletzt aktualisiert am 26.03.2024, zuletzt geprüft am 20.08.2024.
- Google (Hg.) (o.J.c): Google Earth Engine. Online verfügbar unter <https://earthengine.google.com/>, zuletzt aktualisiert am 12.03.2024, zuletzt geprüft am 18.04.2024.
- Google (Hg.) (o.J.d): Image Overview. Online verfügbar unter https://developers.google.com/earth-engine/guides/image_overview, zuletzt aktualisiert am 06.10.2023, zuletzt geprüft am 25.06.2024.
- Gorelick, Noel; Hancher, Matt; Dixon, Mike; Ilyushchenko, Simon; Thau, David; Moore, Rebecca (2017): Google Earth Engine: Planetary-scale geospatial analysis for everyone. In: *Remote Sensing of Environment* 202, S. 18–27. DOI: 10.1016/j.rse.2017.06.031.
- Greiving, Stefan (2006): Integrated Risk Assessment of Multi-Hazards. A New Methodology. In: Philipp Schmidt-Thomé (Hg.): Natural and technological hazards and risks affecting the spatial development of European regions. Espoo: Geological Survey of Finland (Special paper / Geological Survey of Finland, 42), S. 75–82.
- Grünthal, G.; Thieken, A. H.; Schwarz, J.; Radtke, K. S.; Smolka, A.; Merz, B. (2006): Comparative Risk Assessments for the City of Cologne – Storms, Floods, Earthquakes. In: *Nat Hazards* 38 (1-2), S. 21–44. DOI: 10.1007/s11069-005-8598-0.
- Harb, Mostapha Mohammad; Dell'Acqua, Fabio (2017): Remote Sensing in Multirisk Assessment: Improving disaster preparedness. In: *IEEE Geosci. Remote Sens. Mag.* 5 (1), S. 53–65. DOI: 10.1109/MGRS.2016.2625100.
- Harp, Ryan D.; Horton, Daniel E. (2023): Observed Changes in Interannual Precipitation Variability in the United States. In: *Geophysical Research Letters* 50 (13), Artikel e2023GL104533. DOI: 10.1029/2023GL104533.
- Hersbach, Hans; Bell, Bill; Berrisford, Paul; Hirahara, Shoji; Horányi, András; Muñoz-Sabater, Joaquín et al. (2020): The ERA5 global reanalysis. In: *Quart J Royal Meteor Soc* 146 (730), S. 1999–2049. DOI: 10.1002/qj.3803.
- IPCC (Hg.) (2012): Managing the risks of extreme events and disasters to advance climate change adaptation. Special report of the Intergovernmental Panel on Climate Change. Unter Mitarbeit von C. B. Field, V. Barros, T. F. Stocker, D. Qin, D. J. Dokken, K. L. Ebi et al. IPCC. Cambridge: Cambridge University Press. Online verfügbar unter <https://search.ebscohost.com/login.aspx?direct=true&scope=site&db=nlebk&db=nlabk&AN=451743>.
- Jarvis, A.; Reuter, Hannes I.; Guevara, Edith; Nelson, Andy (2008): Hole-filled SRTM for the globe version 3, from the CGIAR-CSI SRTM 90m database. Hg. v. CGIAR-CSI.
- Jenson, Susan K. (1991): Applications of hydrologic information automatically extracted from digital elevation models. In: *Hydrological Processes* 5 (1), S. 31–44. DOI: 10.1002/hyp.3360050104.
- Kappes, M. S.; Keiler, Margreth; Glade, Thomas (2010): From single- to multi-hazard risk analyses: a concept addressing emerging challenges. Unter Mitarbeit von Thomas Glade, Nicola Casagli und Jean-Philippe Malet.

- Kappes, Melanie S.; Keiler, Margreth; Elverfeldt, Kirsten von; Glade, Thomas (2012): Challenges of analyzing multi-hazard risk: a review. In: *Nat Hazards* 64 (2), S. 1925–1958. DOI: 10.1007/s11069-012-0294-2.
- Kunz, Melanie; Hurni, Lorenz (2008): Hazard Maps in Switzerland. State-of-the-Art and Potential Improvements. In: Lorenz Hurni (Hg.): Mountain mapping and visualisation. Proceedings of the 6th ICA Mountain Cartography Workshop, 11 - 15 February 2008, Lenk, Switzerland. Zurich: ETH, Inst. of Cartography, S. 133–138.
- Lee, H.; Romero, J. (2023): Summary for Policymakers. In: IPCC (Hg.): IPCC, 2023: Climate Change 2023: Synthesis Report.
- Lee, Ryan; White, Christopher J.; Adnan, Mohammed Sarfaraz Gani; Douglas, John; Mahecha, Miguel D.; O'Loughlin, Fiachra E. et al. (2024): Reclassifying historical disasters: From single to multi-hazards. In: *The Science of the total environment* 912. DOI: 10.1016/j.scitotenv.2023.169120.
- Lee, S.; Evangelista, Digna G. (2005): Landslide Susceptibility Mapping using Probability and Statistics Models in Baguio City, Philippines.
- Lehner, Bernhard; Verdin, Kristine; Jarvis, Andy (2008): New Global Hydrography Derived From Spaceborne Elevation Data. In: *EoS Transactions* 89 (10), S. 93–94. DOI: 10.1029/2008EO100001.
- Lenz, Susanne (2009): Vulnerabilität kritischer Infrastrukturen. Bonn: Bundesamt für Bevölkerungsschutz und Katastrophenhilfe (Forschung im Bevölkerungsschutz, Bd. 4).
- Liu, Zhongqiang; Nadim, Farrokh; Garcia-Aristizabal, Alexander; Mignan, Arnaud; Fleming, Kevin; Luna, Byron Quan (2015): A three-level framework for multi-risk assessment. In: *Georisk: Assessment and Management of Risk for Engineered Systems and Geohazards* 9 (2), S. 59–74. DOI: 10.1080/17499518.2015.1041989.
- Maraun, Douglas; Roither, Laurenz (2023): Dürren im Klimawandel: Niederschlag und Bodenfeuchte. Hg. v. Climate Change Centre Austria.
- Marulanda, M. C.; La Llera, J. C. de; Cardona, O. D. (2022): A macroeconomic disaster risk analysis: The case study of Chile. In: *International Journal of Disaster Risk Reduction* 74, S. 102875. DOI: 10.1016/j.ijdr.2022.102875.
- Masson-Delmotte, V.; Zhai, P.; Pirani, A.; Connors, S. L.; Péan; Berger, C. S. et al. (2023): Summary for Policymakers. In: IPCC (Hg.): Climate Change 2021 – The Physical Science Basis: Cambridge University Press, S. 3–32.
- Masson-Delmotte, V.; Zhai, P.; Pörtner, H.-O.; Roberts, D.; Skea, J.; Shukla, P. R. et al. (2022): Summary for Policymakers. In: IPCC (Hg.): Global Warming of 1.5°C. An IPCC Special Report on the impacts of global warming of 1.5°C above pre-industrial levels and related global greenhouse gas emission pathways, in the context of strengthening the global response to the threat of climate change, sustainable development, and efforts to eradicate poverty: Cambridge University Press.
- McNally, Amy; Arsenault, Kristi; Kumar, Sujay; Shukla, Shraddhanand; Peterson, Pete; Wang, Shugong et al. (2017): A land data assimilation system for sub-Saharan Africa food and water security applications. In: *Scientific data* 4, S. 170012. DOI: 10.1038/sdata.2017.12.
- Meng, Yongchang; Deng, Ying; Shi, Peijun (2015): Mapping Forest Wildfire Risk of the World. In: Peijun Shi (Hg.): World Atlas of Natural Disaster Risk. Unter Mitarbeit von

- Roger Kasperson. 1st ed. Berlin, Heidelberg: Springer Berlin / Heidelberg (IHDP/Future Earth-Integrated Risk Governance Project Ser), S. 261–275.
- Ming, Xiaodong; Liang, Qiuhua; Dawson, Richard; Xia, Xilin; Hou, Jingming (2022): A quantitative multi-hazard risk assessment framework for compound flooding considering hazard inter-dependencies and interactions. In: *Journal of Hydrology* 607. DOI: 10.1016/j.jhydrol.2022.127477.
- Nachappa, Thimmaiah; Ghorbanzadeh, Omid; Gholamnia, Khalil; Blaschke, Thomas (2020): Multi-Hazard Exposure Mapping Using Machine Learning for the State of Salzburg, Austria. In: *Remote Sensing* 12 (17), S. 2757. DOI: 10.3390/rs12172757.
- Newhall, C.; Hoblitt, R. (2002): Constructing event trees for volcanic crises. In: *Bull Volcanol* 64 (1), S. 3–20. DOI: 10.1007/s004450100173.
- Ordaz, Mario; Salgado, Mario A. (2017): CAPRA: a flexible and open tool to assess seismic risk in a fully probabilistic manner. *Ispira*.
- Owen, Michael; Kruczkiewicz, Andrew; van den Hoek, Jamon (2023): Indexing climatic and environmental exposure of refugee camps with a case study in East Africa. In: *Sci Rep* 13 (1). DOI: 10.1038/s41598-023-31140-7.
- Paulik, Ryan; Horspool, Nick; Woods, Richard; Griffiths, Nick; Beale, Tim; Magill, Christina et al. (2023): RiskScape: a flexible multi-hazard risk modelling engine. In: *Nat Hazards* 119 (2), S. 1073–1090. DOI: 10.1007/s11069-022-05593-4.
- Pendergrass, Angeline G.; Knutti, Reto; Lehner, Flavio; Deser, Clara; Sanderson, Benjamin M. (2017): Precipitation variability increases in a warmer climate. In: *Sci Rep* 7 (1), S. 17966. DOI: 10.1038/s41598-017-17966-y.
- Pesaresi, Martino; Ehrlich, Daniele; Kemper, Thomas; Siragusa, Alice; Florczyk, Aneta J.; Freire, Sérgio; Corbane, Christina (2017): Atlas of the human planet 2017. Global exposure to natural hazards. Luxembourg: Publications Office (EUR, 28556).
- Pippo, Tommaso de; Donadio, Carlo; Pennetta, Micla; Petrosino, Carmela; Terlizzi, Francesco; Valente, Alessio (2008): Coastal hazard assessment and mapping in Northern Campania, Italy. In: *Geomorphology* 97 (3-4), S. 451–466. DOI: 10.1016/j.geomorph.2007.08.015.
- Pörtner, H.-O.; Roberts, D. C.; Poloczanska, E. S.; Mintenbeck, K.; Tignor, M.; Alegría, A. et al. (2023): Summary for Policymakers. In: IPCC (Hg.): *Climate Change 2022 – Impacts, Adaptation and Vulnerability*: Cambridge University Press, S. 3–34.
- Rincón, Daniela; Velandia, Juan Felipe; Tsanis, Ioannis; Khan, Usman T. (2022): Stochastic Flood Risk Assessment under Climate Change Scenarios for Toronto, Canada Using CAPRA. In: *Water* 14 (2), S. 1–28. DOI: 10.3390/w14020227.
- RiskScape (Hg.) (o.J.): Overview. What is RiskScape. Online verfügbar unter <https://riscscape.org.nz/docs/intro/overview.html>, zuletzt aktualisiert am 08.04.2024, zuletzt geprüft am 13.05.2024.
- Ritchie, Hannah; Rosado, Pablo; Roser, Max (2024): Natural Disasters. Where and from which disasters do people die? What can we do to prevent deaths from natural disasters? In: *Our World in Data*. Online verfügbar unter <https://ourworldindata.org/natural-disasters#wildfires>.
- Rocchi, Alessandro; Chiozzi, Andrea; Nale, Marco; Nikolic, Zeljana; Riguzzi, Fabrizio; Mantovan, Luana et al. (2022): A Machine Learning Framework for Multi-Hazard Risk

- Assessment at the Regional Scale in Earthquake and Flood-Prone Areas. In: *Applied Sciences* 12 (2), S. 583. DOI: 10.3390/app12020583.
- Saha, Suranjana; Moorthi, Shrinivas; Wu, Xingren; Wang, Jiande; Nadiga, Sudhir; Tripp, Patrick et al. (2014): The NCEP Climate Forecast System Version 2. In: *Journal of Climate* 27 (6), S. 2185–2208. DOI: 10.1175/JCLI-D-12-00823.1.
- Salgado-Gálvez, Mario A.; Carreño, Martha L.; Barbat, Alex H.; Cardona, Omar (2014): Probabilistic Seismic Risk Assessment of Lorca, Spain.
- Scheele, Finn; Simi, Titimanu; Tarry Nimau, Johnie; Williams, Shaun; Paulik, Ryan; Lin, ShengLin et al. (2020): Applying New Zealand's risk tools internationally: Case studies from Samoa and Vanuatu. In: *MATEC Web Conf.* 331, S. 1–11. DOI: 10.1051/matec-conf/202033101003.
- Schmidt, Jochen; Matcham, Iain; Reese, Stefan; King, Andrew; Bell, Rob; Henderson, Roddy et al. (2011): Quantitative multi-risk analysis for natural hazards: a framework for multi-risk modelling. In: *Nat Hazards* 58 (3), S. 1169–1192. DOI: 10.1007/s11069-011-9721-z.
- Seneviratne, S. I.; Zhang, X.; Adnan, M.; Badi, W.; Dereczynski, C.; Di Luca, A. et al. (2023): Weather and Climate Extreme Events in a Changing Climate. In: IPCC (Hg.): *Climate Change 2021 – The Physical Science Basis*: Cambridge University Press, S. 1513–1766.
- Simmons, David C.; Dauwe, Rudi; Gowland, Richard; Gyenes, Zsuzsanna; King, Alan G.; Riedstra, Durk; Schneiderbauer, Stefan (2017): Qualitative and quantitative approaches to risk assessment. In: Karmen Poljanšek (Hg.): *Science for disaster risk management 2017. Knowing better and losing less*. [S. I.]: European Commission (EUR, 28034 EN), S. 44–58.
- Sinergise Solutions (Hg.) (o.J.): Sentinel Hub. Online verfügbar unter <https://www.sentinel-hub.com/>, zuletzt aktualisiert am 24.07.2024, zuletzt geprüft am 27.07.2024.
- Statista (Hg.) (2024): Number of deaths from natural disaster events worldwide from 2000 to 2023. Online verfügbar unter <https://www.statista.com/statistics/510952/number-of-deaths-from-natural-disasters-globally/>, zuletzt aktualisiert am 04.03.2024, zuletzt geprüft am 04.03.2024.
- Süzen, Mehmet Lütfi; Kaya, Basak Şener (2012): Evaluation of environmental parameters in logistic regression models for landslide susceptibility mapping. In: *International Journal of Digital Earth* 5 (4), S. 338–355. DOI: 10.1080/17538947.2011.586443.
- Tarvainen, T.; Jarva, J.; Greiving, S. (2006): Spatial pattern of hazards and hazard interactions in Europe. In: Philipp Schmidt-Thomé (Hg.): *Natural and technological hazards and risks affecting the spatial development of European regions*. Espoo: Geological Survey of Finland (Special paper / Geological Survey of Finland, 42), S. 83–91.
- Terzi, Stefano; Torresan, Silvia; Schneiderbauer, Stefan; Critto, Andrea; Zebisch, Marc; Marcomini, Antonio (2019): Multi-risk assessment in mountain regions: A review of modelling approaches for climate change adaptation. In: *Journal of Environmental Management* 232, S. 759–771. DOI: 10.1016/j.jenvman.2018.11.100.
- The World Bank (Hg.) (2014): *Understanding Risk. Review of Open Source and Open Access Software Packages Available to Quantify Risk from Natural Hazards*. Washington, D.C.

Thierry, Pierre; Stieltjes, Laurent; Kouokam, Emmanuel; Nguéya, Pierre; Salley, Paul M. (2008): Multi-hazard risk mapping and assessment on an active volcano: the GRINP project at Mount Cameroon. In: *Nat Hazards* 45 (3), S. 429–456. DOI: 10.1007/s11069-007-9177-3.

Tilloy, Aloïs; Malamud, Bruce D.; Winter, Hugo; Joly-Laugel, Amélie (2019): A review of quantification methodologies for multi-hazard interrelationships. In: *Earth-Science Reviews* 196, S. 1–20. DOI: 10.1016/j.earscirev.2019.102881.

Tsiplakidis, John; Photis, Yorgos N. (2019): Multihazard Risk Assessment from Qualitative Methods to Bayesian Networks: Reviewing Recent Contributions and Exploring New Perspectives. In: Kostis Koutsopoulos, Rafael de Miguel González und Karl Donert (Hg.): *Geospatial Challenges in the 21st Century*. Cham: Springer International Publishing (Key Challenges in Geography), S. 401–429.

UNDRR (Hg.) (2007a): Disaster. Online verfügbar unter <https://www.undrr.org/terminology/disaster>, zuletzt aktualisiert am 16.04.2024, zuletzt geprüft am 16.04.2024.

UNDRR (Hg.) (2007b): Hazard. Online verfügbar unter <https://www.undrr.org/terminology/hazard>, zuletzt aktualisiert am 02.07.2024, zuletzt geprüft am 03.07.2024.

UNDRR (Hg.) (2007c): Vulnerability. Online verfügbar unter <https://www.undrr.org/terminology/vulnerability>, zuletzt aktualisiert am 12.04.2024, zuletzt geprüft am 12.04.2024.

UNDRR (Hg.) (2009): Disaster risk. Online verfügbar unter <https://www.undrr.org/terminology/disaster-risk>, zuletzt aktualisiert am 12.04.2024, zuletzt geprüft am 12.04.2024.

UNDRR (Hg.) (2017): Disaster risk assessment. Online verfügbar unter <https://www.undrr.org/terminology/disaster-risk-assessment>, zuletzt aktualisiert am 19.04.2024, zuletzt geprüft am 19.04.2024.

UNDRR (Hg.) (2021a): Hazard. Online verfügbar unter <https://www.prevention-web.net/understanding-disaster-risk/component-risk/hazard>, zuletzt aktualisiert am 11.04.2024, zuletzt geprüft am 11.04.2024.

UNDRR (Hg.) (2021b): Vulnerability. Online verfügbar unter <https://www.prevention-web.net/understanding-disaster-risk/component-risk/vulnerability>, zuletzt aktualisiert am 15.04.2024, zuletzt geprüft am 15.04.2024.

UNDRR; CRED (Hg.) (2020): Human cost of disasters. An overview of the last 20 years 2000-2019.

UNDRR; ISC (Hg.) (2020): Hazard Definition & Classification Review. Technical Report.

UNISDR (Hg.) (2007): Hyogo Framework for Action 2005-2015. Building the Resilience of Nations and Communities to Disasters.

UN-SPIDER (Hg.) (o.J.a): Disaster Risk Management. Online verfügbar unter <https://www.un-spider.org/risks-and-disasters/disaster-risk-management>, zuletzt aktualisiert am 12.04.2024, zuletzt geprüft am 12.04.2024.

UN-SPIDER (Hg.) (o.J.b): Risks and Disasters. Online verfügbar unter <https://www.un-spider.org/risks-and-disasters>, zuletzt aktualisiert am 11.04.2024, zuletzt geprüft am 11.04.2024.

v. Elverfeldt, Kristen; Glade, Thomas; Dikau, Richard (2008): Naturwissenschaftliche Gefahren- und Risikoanalyse. In: Carsten Felgentreff (Hg.): *Naturreisiken und Sozialkatastrophen*. Berlin, Heidelberg: Spektrum Akademischer Verlag, S. 31–46.

Vojtek, Matej; Vojteková, Jana (2019): Flood Susceptibility Mapping on a National Scale in Slovakia Using the Analytical Hierarchy Process. In: *Water* 11 (2), S. 364. DOI: 10.3390/w11020364.

Vorarlberg Wasserwirtschaft (Hg.) (o.J.): Alles Wasser. Arbeitsbehelf Fragen zum Hochwasserschutz.

Ward, Philip J.; Blauhut, Veit; Bloemendaal, Nadia; Daniell, James E.; Ruiter, Marleen C. de; Duncan, Melanie J. et al. (2020): Review article: Natural hazard risk assessments at the global scale. In: *Nat. Hazards Earth Syst. Sci.* 20 (4), S. 1069–1096. DOI: 10.5194/nhess-20-1069-2020.

Weiss, D. J.; Nelson, A.; Gibson, H. S.; Temperley, W.; Peedell, S.; Lieber, A. et al. (2018): A global map of travel time to cities to assess inequalities in accessibility in 2015. In: *Nature* 553 (7688), S. 333–336. DOI: 10.1038/nature25181.

WMO (Hg.) (o.J.): WMO Climatological Normals. Online verfügbar unter <https://community.wmo.int/en/activity-areas/climate-services/climate-products-and-initiatives/wmo-climatological-normals>, zuletzt aktualisiert am 10.09.2024, zuletzt geprüft am 10.09.2024.

WMO (Hg.) (2017): WMO Guidelines on the Calculation of Climate Normals. Online verfügbar unter https://library.wmo.int/doc_num.php?explnum_id=4166.

Woods, Richard (2021): RiskScape – risk modelling tool for NZ. Land Information New Zealand, 2021. Online verfügbar unter <https://www.youtube.com/watch?v=YFhm-LuqQsmE>.

Wu, Qiusheng (2020a): fishnet. Online verfügbar unter https://geemap.org/notebooks/117_fishnet/, zuletzt aktualisiert am 15.07.2024, zuletzt geprüft am 15.07.2024.

Wu, Qiusheng (2020b): geemap: A Python package for interactive mapping with Google Earth Engine. In: *JOSS* 5 (51), S. 2305. DOI: 10.21105/joss.02305.

Yamazaki, Dai; Ikeshima, Daiki; Sosa, Jeison; Bates, Paul D.; Allen, George H.; Pavelsky, Tamlin M. (2019): MERIT Hydro: A High-Resolution Global Hydrography Map Based on Latest Topography Dataset. In: *Water Resources Research* 55 (6), S. 5053–5073. DOI: 10.1029/2019WR024873.

Zhang, Tianjie; Wang, Donglei; Lu, Yang (2023): Machine learning-enabled regional multi-hazards risk assessment considering social vulnerability. In: *Sci Rep* 13 (1). DOI: 10.1038/s41598-023-40159-9.

Zschau, Jochen (2017): Where are we with multihazards, multirisks assessment capacities? In: Karmen Poljanšek (Hg.): Science for disaster risk management 2017. Knowing better and losing less. [S. l.]: European Commission (EUR, 28034 EN), S. 98–115.

Anhang

Anhang A: Skripte zu Berechnung des Gefahrenindex

Anhang A.1 natural_hazard_index.ipynb

Natural hazard index for any location

Author: Germaine Pötgen

-
- As of now the dataset for the variable friction is corrupted, so the corresponding code is commented out
 - Change the region of interest and the normalization reference according to your needs
 - Comment out index variables you don't want to include in the hazard index

Imports

```
import ee
import geemap
import pandas as pd
import geopandas as gpd
from shapely.geometry import mapping

from source import *
```

Authorize access to Google Earth Engine

```
# ee.Authenticate()
```

```
ee.Initialize()
```

Define region of interest

Change the region of interest according to your needs

Create a geometry to use as region of interest

```
vienna_bbox = ee.Geometry.BBox(16.2678922, 48.1195168, 16.5371291, 48.2618604)
vienna_point = ee.Geometry.Point(16.363449, 48.210033)
vienna_polygon = ee.Geometry.Polygon([
    [
        [16.1808, 48.3236],
        [16.3841, 48.3261],
        [16.5761, 48.3090],
        [16.5796, 48.2493],
        [16.5110, 48.1404],
        [16.3073, 48.0837],
        [16.2257, 48.1304],
        [16.1808, 48.3236]
    ]
])
```

```

Upload a geojson to use as region of interest
# Define path to JSON file
region_path = r'C:\Users\germa\Dokumente\MasterGeographie\4_Semester\SE_Kon
versatorium\Notebooks\LANDESGRENZEOGD.json'

# Convert GeoJSON to Earth Engine object
region_ee_object = geemap.geojson_to_ee(region_path)

# Get geometry of GEE object
region_gee_geometry_json = region_ee_object.geometry()

Upload a shapefile to use as region of interest
# Load shapefile as geodataframe
region_gdf = gpd.read_file(r'C:\Users\germa\Dokumente\MasterGeographie\4_Se
mester\SE_Konversatorium\Notebooks\LANDESGRENZEOGD\LANDESGRENZEOGDPolygon.s
hp')

# Define function to convert shapefile geometry to GEE geometry
def shp_to_ee_geom(shp_geom):
    geojson = mapping(shp_geom)
    return ee.Geometry(geojson)

# Extract the first row's geometry from the geodataframe, adjust as needed
region_geometry = region_gdf.loc[0, 'geometry']

# Convert shapefile polygon to GEE geometry
region_gee_geometry_shp = shp_to_ee_geom(region_geometry)

Visualize region of interest on map
Map = geemap.Map()
Map.addLayer(region_gee_geometry_shp, {'color': 'red'}, 'Vienna Polygon')
Map.centerObject(region_gee_geometry_shp)
Map

Define normalization reference

Change the normalization reference according to your needs. Choose from
countries in country_names_sorted.

Use Global Administrative Unit Layers (GAUL) dataset to get country borders
https://developers.google.com/earth-engine/datasets/catalog/FAO\_GAUL\_SIM-
PLIFIED\_500m\_2015\_level0

# Load GAUL dataset
all_countries = ee.FeatureCollection('FAO/GAUL_SIMPLIFIED_500m/2015/level0'
)

# Display country names to choose from
country_names = all_countries.aggregate_array('ADM0_NAME').getInfo()
country_names_sorted = sorted(country_names)

# Define country
country_name = "Austria"

# Filter dataset for specified country
country = all_countries.filter(ee.Filter.eq('ADM0_NAME', country_name))

```

Create fishnet over specified country

Adjust h_interval/v_interval (horizontal/vertical intervals in degrees) or number of rows/cols according to the size of the chosen country to avoid memory errors

```
country_fishnet = geemap.fishnet(country.geometry(), h_interval=0.3, v_interval=0.3, delta=1)
# country_fishnet = geemap.fishnet(country.geometry(), rows=50, cols=50, delta=1)
```

Optional: clip country_fishnet to exact border outlines -> might lead to computation timeout

```
country_fishnet_clip = country_fishnet.map(lambda tile: tile.intersection(country.geometry(), ee.ErrorMargin(1)))
```

Visualize normalization reference on map

```
Map = geemap.Map()
Map.addLayer(country_fishnet, {'color': 'red'}, 'Fishnet')
Map.centerObject(country_fishnet)
Map
```

Calculate natural hazard index value for region of interest

Create list for regions of interest and list for region names

```
region_of_interest_list = [region_gee_geometry_json, region_gee_geometry_shape, vienna_bbox, vienna_polygon, vienna_point]
region_of_interest_names_list = ['vienna_json', 'vienna_shp', 'vienna_bbox', 'vienna_polygon', 'vienna_point']
```

Calculate min/max values of all variables for normalization reference

Comment out index variables you don't want to include in the hazard index

```
min_values = {}
max_values = {}
mean_values = {}
```

```
min_values["pdsi"], max_values["pdsi"] = pdsi_average.min_max(country_fishnet)
min_values["precip_change"], max_values["precip_change"] = precipitation_annual_change.min_max(country_fishnet)
min_values["precip_coeff_variation"], max_values["precip_coeff_variation"] = precipitation_coefficient_variation.min_max(country_fishnet)
min_values["precip_anomaly"], max_values["precip_anomaly"] = precipitation_anomaly.min_max(country_fishnet)
min_values["surface_temp"], max_values["surface_temp"] = surface_temperature_max.min_max(country_fishnet)
min_values["temp_anomaly"], max_values["temp_anomaly"] = temperature_anomaly.min_max(country_fishnet)
min_values["humidity"], max_values["humidity"] = specific_humidity.min_max(country_fishnet)
min_values["flow"], max_values["flow"] = flow_accumulation.min_max(country_fishnet)
# min_values["friction"], max_values["friction"] = friction.min_max(country_fishnet)
min_values["slope"], max_values["slope"] = slope.min_max(country_fishnet)
```

```
min_values["ssm"], max_values["ssm"], mean_values["ssm"] = surface_soil_moi
sture.min_max(country_fishnet)
```

Calculate normalized variable values for each region of interest

```
var_1_results = []
var_2_results = []
var_3_results = []
var_4_results = []
var_5_results = []
var_6_results = []
var_7_results = []
var_8_results = []
var_9_results = []
var_10_results = []
var_11_results = []

for region_of_interest in region_of_interest_list:
    var1 = pdsi_average.get_pdsi_region(region_of_interest, min_values["pdsi"], max_values["pdsi"])
    var_1_results.append(var1)

    var2 = precipitation_ann_change.get_precipitation_change_region(region_of_interest, min_values["precip_change"], max_values["precip_change"])
    var_2_results.append(var2)

    var3 = precipitation_coefficient_variation.get_precipitation_coefficient_variation_region(region_of_interest, min_values["precip_coeff_variation"], max_values["precip_coeff_variation"])
    var_3_results.append(var3)

    var4 = precipitation_anomaly.get_precipitation_anomaly_region(region_of_interest, min_values["precip_anomaly"], max_values["precip_anomaly"])
    var_4_results.append(var4)

    var5 = surface_temperature_max.get_surface_temperature_max_region(region_of_interest, min_values["surface_temp"], max_values["surface_temp"])
    var_5_results.append(var5)

    var6 = temperature_anomaly.get_temperature_anomaly_region(region_of_interest, min_values["temp_anomaly"], max_values["temp_anomaly"])
    var_6_results.append(var6)

    var7 = specific_humidity.get_specific_humidity_region(region_of_interest, min_values["humidity"], max_values["humidity"])
    var_7_results.append(var7)

    var8 = flow_accumulation.get_flow_accumulation_region(region_of_interest, min_values["flow"], max_values["flow"])
    var_8_results.append(var8)

    # var9 = friction.get_friction_region(region_of_interest, min_values["friction"], max_values["friction"])
    # var_9_results.append(var9)

    var10 = slope.get_slope_region(region_of_interest, min_values["slope"], max_values["slope"])
```

```

var_10_results.append(var10)

var11 = surface_soil_moisture.get_surface_soil_moisture_region(region_o
f_interest, min_values["ssm"], max_values["ssm"], mean_values["ssm"])
var_11_results.append(var11)

Calculate hazard index values and save results in a csv file
data = {
    "Region of Interest": region_of_interest_names_list,
    "PDSI average": var_1_results,
    "precipitation change": var_2_results,
    "precipitation coefficient variation": var_3_results,
    "precipitation anomaly": var_4_results,
    "surface temperature max": var_5_results,
    "temperature anomaly": var_6_results,
    "specific humidity": var_7_results,
    "flow accumulation": var_8_results,
    #"friction": var_9_results,
    "slope": var_10_results,
    "ssm": var_11_results,
}

df = pd.DataFrame(data)

df["hazard index"] = df[[
    "PDSI average", "precipitation change", "precipitation coefficient vari
ation",
    "precipitation anomaly", "surface temperature max", "temperature anomal
y",
    "specific humidity", "flow accumulation", #"friction",
    "slope", "ssm"
]].mean(axis=1)

df

# Save the DataFrame as a csv file
df.to_csv('index_results.csv')

```

Anhang A.2: __init__.py

```

__all__ = ['pdsi_average', 'precipitation_ann_change', 'precipitation_coef-
ficient_variation', 'precipitation_anomaly', 'surface_temperature_max',
'temperature_anomaly', 'specific_humidity', 'flow_accumulation', 'fric-
tion', 'slope', 'surface_soil_moisture']

```

Anhang A.3: pdsi_average.py

```

import ee

def get_pdsi_average():

```

```

# Load data
terraclimate_dataset = ee.ImageCollection('IDAHO_EPSCOR/TERRACLIMATE')

# Define observation Period
terraclimate_2000_2020 = terraclimate_dataset.filterDate('2000-01-01',
'2021-01-01')

# Select bands
pdsi_2000_2020 = terraclimate_2000_2020.select('pdsi')

# Get mean for observation period
pdsi_average = pdsi_2000_2020.mean()

return pdsi_average

def min_max(normalization_reference):
    """
    Calculates the minimum and maximum average PDSI (2000-2020) within the
    given normalization reference.

    Args:
        normalization_reference (ee.FeatureCollection): The reference at
        which to normalize the variable.

    Returns:
        float: The minimum average PDSI within the normalization reference.
        float: The maximum average PDSI within the normalization reference.
    """

    pdsi_average = get_pdsi_average()

    # Define a function to compute min and max for each tile
    def get_min_max(tile):
        min_max = pdsi_average.reduceRegion(
            reducer=ee.Reducer.minMax(),
            geometry=tile.geometry(),
            scale=4638.3,
            maxPixels=1e9
        )
        return tile.set({'min_pdsi': min_max.get('pdsi_min'), 'max_pdsi':
min_max.get('pdsi_max')})

    # Apply the function over the fishnet tiles
    min_max_tiles = normalization_reference.map(get_min_max)

    # Aggregate the results
    min_pdsi_list = min_max_tiles.aggregate_array('min_pdsi').getInfo()

```

```

max_pdsi_list = min_max_tiles.aggregate_array('max_pdsi').getInfo()

min_pdsi_float = min(min_pdsi_list)
max_pdsi_float = max(max_pdsi_list)

print(f"Min PDSI: {min_pdsi_float }, Max PDSI: {max_pdsi_float}")

return min_pdsi_float, max_pdsi_float

def get_pdsi_region(region_of_interest, min_value, max_value):
    """
    Calculates the mean average PDSI (2000-2020) within the given region of
    interest and normalizes the value at the normalization reference level.
    Uses flipped normalization function, if values are smaller than 0, indicat-
    ing dry conditions. Otherwise the normalized value is set to 0.

    Args:
        region_of_interest (ee geometry object): The region for which to
        calculate the hazard index.
        min_value (float): The minimum value of this variable within the
        normalization reference.
        max_value (float): The maximum value of this variable within the
        normalization reference.

    Returns:
        ee number object: The normalized average PDSI for the region of in-
        terest.
    """

    pdsi_average = get_pdsi_average()

    min_pdsi = ee.Number(min_value)
    max_pdsi = ee.Number(0)
    max_minus_min_pdsi = max_pdsi.subtract(min_pdsi)

    # Get mean average pdsi for region of interest
    pdsi_region = pdsi_average.reduceRegion(
        reducer=ee.Reducer.mean(),
        geometry=region_of_interest,
        scale=90 # Originally 4638.3
    ).get('pdsi')

    pdsi_region = ee.Number(pdsi_region)

    # Normalize pdsi value for region of interest
    pdsi_region_normalized = ee.Algorithms.If(
        pdsi_region.lt(0),
        (max_pdsi.subtract(pdsi_region)).divide(max_minus_min_pdsi),

```

```

        ee.Number(0) # Set all positive values, which indicate wet conditions,
to 0
    )

    return ee.Number(pdsi_region_normalized).getInfo()

```

Anhang A.4: precipitation_ann_change.py

```

import ee

def get_precipitation_change():
    # Load data
    chirps_dataset = ee.ImageCollection('UCSB-CHG/CHIRPS/PENTAD')

    # Select bands
    chirps_precipitation = chirps_dataset.select('precipitation')

    # Define observation Period
    precipitation_1981_1990 = chirps_precipitation.filterDate('1981-01-01',
'1991-01-01')
    precipitation_2009_2020 = chirps_precipitation.filterDate('2009-01-01',
'2021-01-01')

    # Calculate precipitation sum between 1981-1990
    precipitation_1981_1990_sum = precipitation_1981_1990.sum()

    # Calculate mean annual precipitation between 1981-1990
    precipitation_1981_1990_annual = precipitation_1981_1990_sum.divide(10)

    # Calculate precipitation sum between 2009-2020
    precipitation_2009_2020_sum = precipitation_2009_2020.sum()

    # Calculate mean annual precipitation between 2009-2020
    precipitation_2009_2020_annual = precipitation_2009_2020_sum.divide(12)

    # Calculate change in annual accumulation
    annual_precipitation_change = precipitation_2009_2020_annual.sub-
tract(precipitation_1981_1990_annual)

    return annual_precipitation_change

def min_max(normalization_reference):
    """
    Calculates the minimum and maximum change in annual precipitation accu-
    mulation (2009-2020 compared to 1981-1990) within the given normalization
    reference.

```

```

    Args:
        normalization_reference (ee.FeatureCollection): The reference at
        which to normalize the variable.

    Returns:
        float: The minimum change in annual precipitation accumulation
        within the normalization reference.
        float: The maximum change in annual precipitation accumulation
        within the normalization reference.
    """

    annual_precipitation_change = get_precipitation_change()

    # Define a function to compute min and max for each tile
    def get_min_max(tile):
        min_max = annual_precipitation_change.reduceRegion(
            reducer=ee.Reducer.minMax(),
            geometry=tile.geometry(),
            scale=5566,
            maxPixels=1e10
        )
        return tile.set({'min_precipitation': min_max.get('precipita-
tion_min'), 'max_precipitation': min_max.get('precipitation_max')})

    # Apply the function over the fishnet tiles
    min_max_tiles = normalization_reference.map(get_min_max)

    # Aggregate the results
    min_precip_list = min_max_tiles.aggregate_array('min_precipita-
tion').getInfo()
    max_precip_list = min_max_tiles.aggregate_array('max_precipita-
tion').getInfo()

    min_annual_precip_change_float = min(min_precip_list)
    max_annual_precip_change_float = max(max_precip_list)

    print(f"Min precipitation accumulation change: {min_an-
nual_precip_change_float}, Max precipitation accumulation change: {max_an-
nual_precip_change_float}")

    return min_annual_precip_change_float, max_annual_precip_change_float

def get_precipitation_change_region(region_of_interest, min_value,
max_value):
    """

```

Calculates the mean change in annual precipitation accumulation (2009-2020 compared to 1981-1990) within the given region of interest and normalizes the value at the normalization reference level. Uses standard normalization function, if change in annual precipitation accumulation is positive (indicating flood). Uses flipped normalization function, if change is negative (indicating drought).

Args:

`region_of_interest` (ee geometry object): The region for which to calculate the hazard index.

`min_value` (float): The minimum value of this variable within the normalization reference.

`max_value` (float): The maximum value of this variable within the normalization reference.

Returns:

ee number object: The normalized change in annual precipitation accumulation for the region of interest.

```

"""
annual_precipitation_change = get_precipitation_change()

min_annual_precipitation_change = ee.Number(min_value)
max_annual_precipitation_change = ee.Number(max_value)

# Get mean annual precipitation change for region of interest
precip_change_region = annual_precipitation_change.reduceRegion(
    reducer=ee.Reducer.mean(),
    geometry=region_of_interest,
    scale=90, # Originally 5566
    maxPixels=1e10
).get('precipitation')

precip_change_region = ee.Number(precip_change_region)

# Normalize change in annual precipitation accumulation value for re-
# gion of interest
precip_region_normalized = ee.Algorithms.If(
    precip_change_region.gt(0),
    precip_change_region.divide(max_annual_precipitation_change), #
    ee.Algorithms.If(
        precip_change_region.lt(0),
        precip_change_region.divide(min_annual_precipitation_change), # Normalize for drought
        ee.Number(0)
    )
)

```

```
return ee.Number(precip_region_normalized).getInfo()
```

Anhang A.5: precipitation_coefficient_variation.py

```
import ee

def get_precipitation_coefficient_variation():
    # Load data
    chirps_dataset = ee.ImageCollection('UCSB-CHG/CHIRPS/PENTAD')

    # Select bands
    chirps_precipitation = chirps_dataset.select('precipitation')

    # Define function to calculate precipitation sum for a given year
    def sum_year(year):
        start_date = ee.Date.fromYMD(year, 1, 1)
        end_date = start_date.advance(1, 'year')
        one_year = chirps_precipitation.filterDate(start_date, end_date)
        return one_year.sum().set('year', year)

    years = ee.List.sequence(1990, 2020)

    # Calculate the annual precipitation sum for the years 1990-2020
    sum_year_images = years.map(lambda year: sum_year(ee.Number(year)))

    # Convert the list to an ImageCollection
    sum_year_imageCollection = ee.ImageCollection(sum_year_images)

    # Calculate the annual mean precipitation between 1990 and 2020
    precipitation_1990_2020_mean = sum_year_imageCollection.mean()

    # Calculate the standard deviation of the annual precipitation sum between 1990-2020
    annual_precipitation_sd = sum_year_imageCollection.reduce(ee.Reducer.stdDev())

    # Calculate the coefficient of variation
    precipitation_cv = annual_precipitation_sd.divide(precipitation_1990_2020_mean)

    return precipitation_cv

def min_max(normalization_reference):
    """
```

Calculates the the minimum and maximum interannual coefficient of variation regarding precipitation (1990-2020) within the given normalization reference.

Args:

normalization_reference (ee FeatureCollection): The reference at which to normalize the variable.

Returns:

float: The minimum interannual coefficient of variation regarding precipitation within the normalization reference.

float: The maximum interannual coefficient of variation regarding precipitation within the normalization reference.

```
"""
precipitation_cv = get_precipitation_coefficient_variation()

# Define a function to compute min and max for each tile
def get_min_max(tile):
    min_max = precipitation_cv.reduceRegion(
        reducer=ee.Reducer.minMax(),
        geometry=tile.geometry(),
        scale=5566,
        maxPixels=1e10
    )
    return tile.set({'min_precipitation_stdDev': min_max.get('precipitation_stdDev_min'), 'max_precipitation_stdDev': min_max.get('precipitation_stdDev_max')})

# Apply the function over the fishnet tiles
min_max_tiles = normalization_reference.map(get_min_max)

# Aggregate the results
min_cv_list = min_max_tiles.aggregate_array('min_precipitation_stdDev').getInfo()
max_cv_list = min_max_tiles.aggregate_array('max_precipitation_stdDev').getInfo()

min_cv_float = min(min_cv_list)
max_cv_float = max(max_cv_list)

print(f"Min precipitation cv: {min_cv_float}, Max precipitation cv: {max_cv_float}")

return min_cv_float, max_cv_float
```

```

def get_precipitation_coefficient_variation_region(region_of_interest,
min_value, max_value):
    """
        Calculates the mean interannual coefficient of variation regarding pre-
        cipitation (1990-2020) within the given region of interest and normalizes
        the value at the normalization reference level.

        Args:
            region_of_interest (ee geometry object): The region for which to
            calculate the hazard index.
            min_value (float): The minimum value of this variable within the
            normalization reference.
            max_value (float): The maximum value of this variable within the
            normalization reference.

        Returns:
            ee number object: The normalized interannual coefficient of varia-
            tion regarding precipitation for the region of interest.
    """

    precipitation_cv = get_precipitation_coefficient_variation()

    min_cv = ee.Number(min_value)
    max_cv = ee.Number(max_value)
    max_minus_min_cv = max_cv.subtract(min_cv)

    # Get mean precipitation coefficient of variation for region of inter-
    est
    mean_region_precip_cv = precipitation_cv.reduceRegion(
        reducer=ee.Reducer.mean(),
        geometry=region_of_interest,
        scale= 90, # Originally 5566
        maxPixels=1e10
    ).get("precipitation_stdDev")

    cv_region = ee.Number(mean_region_precip_cv)

    # Normalize precipitation coefficient of variation value for region of
    interest
    cv_normalized = (cv_region.subtract(min_cv)).divide(max_minus_min_cv)

    return ee.Number(cv_normalized).getInfo()

```

Anhang A.6: precipitation_anomaly.py

```

import ee

def get_precipitation_anomaly():

```

```

# Load data
chirps_dataset = ee.ImageCollection('UCSB-CHG/CHIRPS/PENTAD')

# Select bands
chirps_precipitation = chirps_dataset.select('precipitation')

# Define a function to calculate the precipitation sum for a given pe-
riod within a given year
def precipitation_sum(year, start_date, end_date):
    precipitation_month = chirps_precipitation.filterDate(year +
start_date, year + end_date)
    return precipitation_month.sum()

# ----- MARCH -----
precipitation_march_list = []

# Calculate the precipitation sum for March of each year from 2000 to
2020 and append the results to precipitation_march_list
for i in range(2000, 2021):
    precipitation_march_list.append(precipitation_sum(str(i), '-03-01',
'-03-31'))

precipitation_march_imageCollection = ee.ImageCollection(precipita-
tion_march_list)
precipitation_march_mean = precipitation_march_imageCollection.mean()

# ----- APRIL -----
precipitation_april_list = []

# Calculate the precipitation sum for April of each year from 2000 to
2020 and append the results to precipitation_april_list
for i in range(2000, 2021):
    precipitation_april_list.append(precipitation_sum(str(i), '-04-01',
'-04-30'))

precipitation_april_imageCollection = ee.ImageCollection(precipita-
tion_april_list)
precipitation_april_mean = precipitation_april_imageCollection.mean()

# ----- MAY -----
precipitation_may_list = []

# Calculate the precipitation sum for May of each year from 2000 to
2020 and append the results to precipitation_may_list
for i in range(2000, 2021):
    precipitation_may_list.append(precipitation_sum(str(i), '-05-01',
'-05-31'))

```

```

    precipitation_may_imageCollection = ee.ImageCollection(precipitation_may_list)
    precipitation_may_mean = precipitation_may_imageCollection.mean()

    # ----- Calculate Anomaly -----

    # Define a function to calculate the precipitation anomaly for each image in a given month_list and return a list of anomaly images
    def calculate_anomaly_collection(month_list, precipitation_month_mean):
        return month_list.map(lambda image: image.subtract(precipitation_month_mean))

    # Calculate precipitation anomaly for MAM and combine into a single ImageCollection
    anomaly_march = calculate_anomaly_collection(ee.ImageCollection(precipitation_march_list), precipitation_march_mean)
    anomaly_april = calculate_anomaly_collection(ee.ImageCollection(precipitation_april_list), precipitation_april_mean)
    anomaly_may = calculate_anomaly_collection(ee.ImageCollection(precipitation_may_list), precipitation_may_mean)

    anomaly_march_april_may_imageCollection = anomaly_march.merge(anomaly_april).merge(anomaly_may)

    # Calculate the maximum monthly precipitation anomaly
    anomaly_march_april_may_max = anomaly_march_april_may_imageCollection.max()

    return anomaly_march_april_may_max

def min_max(normalization_reference):
    """
    Calculates the minimum and maximum maximum monthly precipitation anomaly in MAM (March-April-May) season (2000-2020) within the given normalization reference.

    Args:
        normalization_reference (ee.FeatureCollection): The reference at which to normalize the variable.

    Returns:
        float: The minimum maximum monthly precipitation anomaly in MAM season within the normalization reference.
        float: The maximum maximum monthly precipitation anomaly in MAM season within the normalization reference.
    """

```

```

anomaly_march_april_may_max = get_precipitation_anomaly()

# Define a function to compute min and max for each tile
def get_min_max(tile):
    min_max = anomaly_march_april_may_max.reduceRegion(
        reducer=ee.Reducer.minMax(),
        geometry=tile.geometry(),
        scale=5566,
        maxPixels=1e10
    )
    return tile.set({'min_precipitation': min_max.get('precipitation_min'), 'max_precipitation': min_max.get('precipitation_max')})

# Apply the function over the fishnet tiles
min_max_tiles = normalization_reference.map(get_min_max)

# Aggregate the results
min_maxanomaly_list = min_max_tiles.aggregate_array('min_precipitation').getInfo()
max_maxanomaly_list = min_max_tiles.aggregate_array('max_precipitation').getInfo()

min_maxanomaly_float = min(min_maxanomaly_list)
max_maxanomaly_float = max(max_maxanomaly_list)

print(f"Min maximum precipitation anomaly: {min_maxanomaly_float}, Max maximum precipitation anomaly: {max_maxanomaly_float}")

return min_maxanomaly_float, max_maxanomaly_float

def get_precipitation_anomaly_region(region_of_interest, min_value, max_value):
    """
    Calculates the mean maximum monthly precipitation anomaly in MAM (March–April–May) season (2000–2020) within the given region of interest and normalizes the value at the normalization reference level.

    Args:
        region_of_interest (ee geometry object): The region for which to calculate the hazard index.
        min_value (float): The minimum value of this variable within the normalization reference.
        max_value (float): The maximum value of this variable within the normalization reference.

    Returns:
        ee number object: The normalized maximum monthly precipitation anomaly in MAM season for the region of interest
    """

```

```

"""

anomaly_march_april_may_max = get_precipitation_anomaly()

min_anomaly = ee.Number(min_value)
max_anomaly = ee.Number(max_value)
max_minus_min_anomaly = max_anomaly.subtract(min_anomaly)

# Get mean maximum monthly precipitation anomaly in MAM season for re-
# gion of interest
anomaly_region = anomaly_march_april_may_max.reduceRegion(
    reducer=ee.Reducer.mean(),
    geometry=region_of_interest,
    scale=90 # Originally 5566
).get("precipitation")

anomaly_region = ee.Number(anomaly_region)

# Normalize maximum monthly precipitation anomaly in MAM season value
# for region of interest
anomaly_normalized = (anomaly_region.subtract(min_anomaly)).di-
vide(max_minus_min_anomaly)

return ee.Number(anomaly_normalized).getInfo()

```

Anhang A.7: surface_temperature_max.py

```

import ee

def get_surface_temperature_max():
    # Load data
    cfs_dataset = ee.ImageCollection("NOAA/CFSV2/FOR6H")

    # Select bands
    max_temp = cfs_dataset.select('Maximum_tempera-
ture_height_above_ground_6_Hour_Interval')

    # Define a function to calculate the maximum temperature for a given
    year
    def max_year(year):
        start_date = ee.Date.fromYMD(year, 1, 1)
        end_date = start_date.advance(1, 'year')
        one_year = max_temp.filterDate(start_date, end_date)
        return one_year.max()

    years = ee.List.sequence(2010, 2020)

```

```

# Calculate the annual maximum temperature between 2010 and 2020
max_surface_temperature_2010_2020 = years.map(max_year)

# Convert the list to an ImageCollection
max_surface_temperature_2010_2020_imageCollection = ee.ImageCollection(
    max_surface_temperature_2010_2020)

max_surface_temperature_mean = max_surface_temperature_2010_2020_imageCollection.mean()

return max_surface_temperature_mean

def min_max(normalization_reference):
    """
    Calculates the minimum and maximum annual maximum surface temperature
    (2010-2020) within the given normalization reference.

    Args:
        normalization_reference (ee FeatureCollection): The reference at
        which to normalize the variable.

    Returns:
        float: The minimum annual maximum surface temperature within the
        normalization reference.
        float: The maximum annual maximum surface temperature within the
        normalization reference.
    """

    max_surface_temperature_mean = get_surface_temperature_max()

    # Define a function to compute min and max for each tile
    def get_min_max(tile):
        min_max = max_surface_temperature_mean.reduceRegion(
            reducer=ee.Reducer.minMax(),
            geometry=tile.geometry(),
            scale=22264,
            maxPixels=1e10
        )
        return tile.set({'min_Maximum_temperature_height_above_ground_6_Hour_Interval': min_max.get('Maximum_temperature_height_above_ground_6_Hour_Interval_min'), 'max_Maximum_temperature_height_above_ground_6_Hour_Interval': min_max.get('Maximum_temperature_height_above_ground_6_Hour_Interval_max')})

    # Apply the function over the fishnet tiles
    min_max_tiles = normalization_reference.map(get_min_max)

```

```

    # Aggregate the results
    min_surf_temp_list = min_max_tiles.aggregate_array('min_Maximum_temperature_height_above_ground_6_Hour_Interval').getInfo()
    max_surf_temp_list = min_max_tiles.aggregate_array('max_Maximum_temperature_height_above_ground_6_Hour_Interval').getInfo()

    min_surf_temp_float = min(min_surf_temp_list)
    max_surf_temp_float = max(max_surf_temp_list)

    # Print the overall results
    print(f"Min surface temperature: {min_surf_temp_float}, Max surface temperature: {max_surf_temp_float}")

    return min_surf_temp_float, max_surf_temp_float

def get_surface_temperature_max_region(region_of_interest, min_value, max_value):
    """
    Calculates the mean annual maximum surface temperature (2010-2020) within the given region of interest and normalizes the value at the normalization reference level.

    Args:
        region_of_interest (ee geometry object): The region for which to calculate the hazard index.
        min_value (float): The minimum value of this variable within the normalization reference.
        max_value (float): The maximum value of this variable within the normalization reference.

    Returns:
        ee number object: The normalized annual maximum surface temperature (2010-2020) for the region of interest.
    """

    max_surface_temperature_mean = get_surface_temperature_max()

    min_surface_temperature = ee.Number(min_value)
    max_surface_temperature = ee.Number(max_value)
    max_minus_min_surface_temperature = max_surface_temperature.subtract(min_surface_temperature)

    # Get mean surface temperature for region of interest
    surface_temperature_region = max_surface_temperature_mean.reduceRegion(
        reducer=ee.Reducer.mean(),
        geometry=region_of_interest,
        scale=90, # Originally 22264

```

```

        maxPixels=1e10
    ).get('Maximum_temperature_height_above_ground_6_Hour_Interval')

    surface_temperature_region = ee.Number(surface_temperature_region)

    # Normalize surface temperature value for region of interest
    surface_temperature_normalized = (surface_temperature_region.subtract(
        min_surface_temperature)).divide(max_minus_min_surface_temperature)

    return ee.Number(surface_temperature_normalized).getInfo()

```

Anhang A.8: temperature_anomaly.py

```

import ee

def get_temperature_anomaly():
    # Load data
    era_dataset = ee.ImageCollection(ee.ImageCollection("ECMWF/ERA5/DAILY"))

    # Select bands
    air_temperature = era_dataset.select('mean_2m_air_temperature')

    # Define observation Period
    air_temperature_1980_1991 = air_temperature.filterDate('1980-01-01',
        '1992-01-01')
    air_temperature_2008_2019 = air_temperature.filterDate('2008-01-01',
        '2020-01-01')

    # Calculate mean temperature
    air_temperature_1980_1991_mean = air_temperature_1980_1991.mean()
    air_temperature_2008_2019_mean = air_temperature_2008_2019.mean()

    # Calculate long-term temperature anomaly
    temperature_anomaly = air_temperature_2008_2019_mean.subtract(air_tem-
        perature_1980_1991_mean)

    return temperature_anomaly

def min_max(normalization_reference):
    """
    Calculates the minimum and maximum long-term temperature anomaly (cli-
    mate normal: 1980-1992) within the given normalization reference.

    Args:
        normalization_reference (ee FeatureCollection): The reference at
        which to normalize the variable.

```

```

Returns:
    float: The minimum long-term temperature anomaly within the normal-
ization reference.
    float: The maximum long-term temperature anomaly within the normal-
ization reference.
"""

temperature_anomaly = get_temperature_anomaly()

# Define a function to compute min and max for each tile
def get_min_max(tile):
    min_max = temperature_anomaly.reduceRegion(
        reducer=ee.Reducer.minMax(),
        geometry=tile.geometry(),
        scale=27830,
        maxPixels=1e9
    )
    return tile.set({'min_mean_2m_air_temperature':
min_max.get('mean_2m_air_temperature_min'), 'max_mean_2m_air_temperature':
min_max.get('mean_2m_air_temperature_max')})

# Apply the function over the fishnet tiles
min_max_tiles = normalization_reference.map(get_min_max)

# Aggregate the results
min_temperature_anomaly_list = min_max_tiles.aggregate_ar-
ray('min_mean_2m_air_temperature').getInfo()
max_temperature_anomaly_list = min_max_tiles.aggregate_ar-
ray('max_mean_2m_air_temperature').getInfo()

min_temperature_anomaly_float = min(min_temperature_anomaly_list)
max_temperature_anomaly_float = max(max_temperature_anomaly_list)

print(f"Min temperature anomaly: {min_temperature_anomaly_float}, Max
temperature anomaly: {max_temperature_anomaly_float}")

return min_temperature_anomaly_float, max_temperature_anomaly_float

def get_temperature_anomaly_region(region_of_interest, min_value,
max_value):
    """
    Calculates the mean long-term temperature anomaly (climate normal:
    1980-1992) within the given region of interest and normalizes the value at
    the normalization reference level.

```

Args:

```

        region_of_interest (ee geometry object): The region for which to
        calculate the hazard index.
        min_value (float): The minimum value of this variable within the
        normalization reference.
        max_value (float): The maximum value of this variable within the
        normalization reference.

    Returns:
        ee number object: The normalized long-term temperature anomaly for
        the region of interest.
    """

    temperature_anomaly = get_temperature_anomaly()

    min_temperature_anomaly = ee.Number(min_value)
    max_temperature_anomaly = ee.Number(max_value)
    max_minus_min_temperature_anomaly = max_temperature_anomaly.sub-
    tract(min_temperature_anomaly)

    # Get mean temperature anomaly for region of interest
    temperature_anomaly_region = temperature_anomaly.reduceRegion(
        reducer=ee.Reducer.mean(),
        geometry=region_of_interest,
        scale=90 # Originally 27830
    ).get("mean_2m_air_temperature")

    temperature_anomaly_region = ee.Number(temperature_anomaly_region)

    # Normalize temperature anomaly value for region of interest
    temperature_anomaly_region_normalized = (temperature_anomaly_re-
    gion.subtract(min_temperature_anomaly)).divide(max_minus_min_tempera-
    ture_anomaly)

    return ee.Number(temperature_anomaly_region_normalized).getInfo()

```

Anhang A.9: specific_humidity.py

```

import ee

def get_specific_humidity():
    # Load data
    fldas_dataset = ee.ImageCollection("NASA/FLDAS/NOAH01/C/GL/M/V001")

    # Select bands
    humidity = fldas_dataset.select('Qair_f_tavg')

```

```

# Define observation Period
humidity_2000_2020 = humidity.filterDate('2000-01-01', '2021-01-01')

specific_humidity_mean = humidity_2000_2020.mean()

return specific_humidity_mean

def min_max(normalization_reference):
    """
    Calculates the minimum and maximum average specific humidity (2000-
    2020) within the given normalization reference.

    Args:
        normalization_reference (ee.FeatureCollection): The reference at
        which to normalize the variable.

    Returns:
        float: The minimum average specific humidity within the normaliza-
        tion reference.
        float: The maximum average specific humidity within the normaliza-
        tion reference.
    """

    specific_humidity = get_specific_humidity()

    # Define a function to compute min and max for each tile
    def get_min_max(tile):
        min_max = specific_humidity.reduceRegion(
            reducer=ee.Reducer.minMax(),
            geometry=tile.geometry(),
            scale=11132,
            maxPixels=1e10
        )
        return tile.set({'min_Qair_f_tavg':
min_max.get('Qair_f_tavg_min'), 'max_Qair_f_tavg':
min_max.get('Qair_f_tavg_max')})

    # Apply the function over the fishnet tiles
    min_max_tiles = normalization_reference.map(get_min_max)

    # Aggregate the results
    min_humidity_list = min_max_tiles.aggregate_ar-
ray('min_Qair_f_tavg').getInfo()
    max_humidity_list = min_max_tiles.aggregate_ar-
ray('max_Qair_f_tavg').getInfo()

    min_humidity_float = min(min_humidity_list)

```

```

max_humidity_float = max(max_humidity_list)

print(f"Min specific humidity: {min_humidity_float}, Max specific hu-
midity: {max_humidity_float}")

return min_humidity_float, max_humidity_float

def get_specific_humidity_region(region_of_interest, min_value, max_value):
    """
    Calculates the mean average specific humidity (2000-2020) within the
    given region of interest and normalizes the value at the normalization ref-
    erence level.

    Args:
        region_of_interest (ee geometry object): The region for which to
        calculate the hazard index.
        min_value (float): The minimum value of this variable within the
        normalization reference.
        max_value (float): The maximum value of this variable within the
        normalization reference.

    Returns:
        ee number object: The normalized average specific humidity for the
        region of interest.
    """

    specific_humidity = get_specific_humidity()

    min_humidity = ee.Number(min_value)
    max_humidity = ee.Number(max_value)
    max_minus_min_humidity = max_humidity.subtract(min_humidity)

    # Get mean specific humidity for region of interest
    humidity_region = specific_humidity.reduceRegion(
        reducer=ee.Reducer.mean(),
        geometry=region_of_interest,
        scale=90 # Originally 11132
    ).get('Qair_f_tavg')

    humidity_region = ee.Number(humidity_region)

    # Normalize specific humidity value for region of interest
    humidity_region_normalized = (max_humidity.subtract(humidity_re-
    gion)).divide(max_minus_min_humidity)

    return ee.Number(humidity_region_normalized).getInfo()

```

Anhang A.10: flow_accumulation.py

```
import ee

def get_flow_accumulation():

    # Load data
    merit_hydro_dataset = ee.Image("MERIT/Hydro/v1_0_1")

    # Select bands
    flow_accumulation = merit_hydro_dataset.select('upg')

    return flow_accumulation


def min_max(normalization_reference):
    """
    Calculates the minimum and maximum flow accumulation within the given
    normalization reference.

    Args:
        normalization_reference (ee.FeatureCollection): The reference at
        which to normalize the variable.

    Returns:
        float: The minimum flow accumulation within the normalization ref-
        erence.
        float: The maximum flow accumulation within the normalization ref-
        erence.
    """

    flow_accumulation = get_flow_accumulation()

    # Define a function to compute min and max for each tile
    def get_min_max(tile):
        min_max = flow_accumulation.reduceRegion(
            reducer=ee.Reducer.minMax(),
            geometry=tile.geometry(),
            scale=92.77,
            maxPixels=1e10
        )
        return tile.set({'min_upg': min_max.get('upg_min'),
            'max_upg': min_max.get('upg_max')})

    # Apply the function over the fishnet tiles
    min_max_tiles = normalization_reference.map(get_min_max)

    # Aggregate the results
```

```

min_flow_list = min_max_tiles.aggregate_array('min_upg').getInfo()
max_flow_list = min_max_tiles.aggregate_array('max_upg').getInfo()

min_flow_float = min(min_flow_list)
max_flow_float = max(max_flow_list)

print(f"Min flow: {min_flow_float}, Max flow: {max_flow_float }")

return min_flow_float, max_flow_float

def get_flow_accumulation_region(region_of_interest, min_value, max_value):
    """
    Calculates the mean flow accumulation within the given region of interest and normalizes the value at the normalization reference level.

    Args:
        region_of_interest (ee geometry object): The region for which to calculate the hazard index.
        min_value (float): The minimum value of this variable within the normalization reference.
        max_value (float): The maximum value of this variable within the normalization reference.

    Returns:
        ee number object: The normalized flow accumulation for the region of interest.
    """

    flow_accumulation = get_flow_accumulation()

    # Change min/max float to Earth Engine number object
    min_flow = ee.Number(min_value)
    max_flow = ee.Number(max_value)
    max_minus_min_flow = max_flow.subtract(min_flow)

    # Get mean flow accumulation for region of interest
    flow_region = flow_accumulation.reduceRegion(
        reducer=ee.Reducer.mean(),
        geometry=region_of_interest,
        scale=90 # Originally 92.77
    ).get('upg')

    flow_region = ee.Number(flow_region)

    # Normalize flow accumulation value for region of interest
    flow_region_normalized = (flow_region.subtract(min_flow)).divide(max_minus_min_flow)

```

```
return ee.Number(flow_region_normalized).getInfo()
```

Anhang A.11: friction.py

```
import ee

def get_friction():
    # Load data
    oxford_friction_dataset = ee.Image("Oxford/Map/friction_surface_2019")

    # Select bands
    friction = oxford_friction_dataset.select('friction')

    return friction

def min_max(normalization_reference):
    """
    Calculates the minimum and maximum friction within the given normalization reference.

    Args:
        normalization_reference (ee.FeatureCollection): The reference at which to normalize the variable.

    Returns:
        float: The minimum friction within the normalization reference.
        float: The maximum friction within the normalization reference.
    """

    friction = get_friction()

    # Define a function to compute min and max for each tile
    def get_min_max(tile):
        min_max = friction.reduceRegion(
            reducer=ee.Reducer.minMax(),
            geometry=tile.geometry(),
            scale=927.67,
            maxPixels=1e10
        )
        return tile.set({'min_friction': min_max.get('friction_min'),
            'max_friction': min_max.get('friction_max')})

    # Apply the function over the fishnet tiles
    min_max_tiles = normalization_reference.map(get_min_max)
```

```

    # Aggregate the results
    min_friction_list = min_max_tiles.aggregate_array('min_friction').get-
Info()
    max_friction_list = min_max_tiles.aggregate_array('max_friction').get-
Info()

    min_friction_float = min(min_friction_list)
    max_friction_float = max(max_friction_list)

    print(f"Min friction: {min_friction_float}, Max friction: {max_fric-
tion_float }")

    return min_friction_float, max_friction_float

def get_friction_region(region_of_interest, min_value, max_value):
    """
    Calculates the mean friction within the given region of interest and
    normalizes the value at the normalization reference level.

    Args:
        region_of_interest (ee geometry object): The region for which to
        calculate the hazard index.
        min_value (float): The minimum value of this variable within the
        normalization reference.
        max_value (float): The maximum value of this variable within the
        normalization reference.

    Returns:
        ee number object: The normalized friction for the region of inter-
    est.
    """

    friction = get_friction()

    # Change min/max float to Earth Engine number object
    min_friction = ee.Number(min_value)
    max_friction = ee.Number(max_value)
    max_minus_min_friction = max_friction.subtract(min_friction)

    # Get mean friction for region of interest
    friction_region = friction.reduceRegion(
        reducer=ee.Reducer.mean(),
        geometry=region_of_interest,
        scale=90 # Originally 927.67
    ).get('friction')

    friction_region = ee.Number(friction_region)

```

```

    # Normalize friction value for region of interest
    friction_region_normalized = (friction_region.subtract(min_friction)).divide(max_minus_min_friction)

    return ee.Number(friction_region_normalized).getInfo()

```

Anhang A.12: slope.py

```

import ee

def get_slope():
    # Load data
    srtm_dataset = ee.Image("CGIAR/SRTM90_V4")

    # Select bands
    dem = srtm_dataset.select('elevation')

    # Calculate slope
    slope = ee.Terrain.slope(dem)

    return slope

def min_max(normalization_reference):
    """
    Calculates the minimum and maximum slope within the given normalization
    reference.

    Args:
        normalization_reference (ee.FeatureCollection): The reference at
        which to normalize the variable.

    Returns:
        float: The minimum slope within the normalization reference.
        float: The maximum slope within the normalization reference.
    """

    slope = get_slope()

    # Define a function to compute min and max for each tile
    def get_min_max(tile):
        min_max = slope.reduceRegion(
            reducer=ee.Reducer.minMax(),
            geometry=tile.geometry(),
            scale=90,
            maxPixels=1e11
        )

```

```

        return tile.set({'min_slope': min_max.get('slope_min'),
                          'max_slope': min_max.get('slope_max')})

    # Apply the function over the fishnet tiles
    min_max_tiles = normalization_reference.map(get_min_max)

    # Aggregate the results
    min_slope_list = min_max_tiles.aggregate_array('min_slope').getInfo()
    max_slope_list = min_max_tiles.aggregate_array('max_slope').getInfo()

    min_slope_float = min(min_slope_list)
    max_slope_float = max(max_slope_list)

    print(f"Min slope: {min_slope_float}, Max slope: {max_slope_float}")

    return min_slope_float, max_slope_float


def get_slope_region(region_of_interest, min_value, max_value):
    """
    Calculates the mean slope within the given region of interest and normalizes the value at the normalization reference level.

    Args:
        region_of_interest (ee geometry object): The region for which to calculate the hazard index.
        min_value (float): The minimum value of this variable within the normalization reference.
        max_value (float): The maximum value of this variable within the normalization reference.

    Returns:
        ee number object: The normalized slope for the region of interest.
    """

    slope = get_slope()

    min_slope = ee.Number(min_value)
    max_slope = ee.Number(max_value)
    max_minus_min_slope = max_slope.subtract(min_slope)

    # Get mean slope for region of interest
    slope_region = slope.reduceRegion(
        reducer=ee.Reducer.mean(),
        geometry=region_of_interest,
        scale=90
    ).get('slope')

    slope_region = ee.Number(slope_region)

```

```

    # Normalize slope value for region of interest
    slope_region_normalized = (slope_region.subtract(min_slope)).divide(max_minus_min_slope)

    return ee.Number(slope_region_normalized).getInfo()

```

Anhang A.13: surface_soil_moisture.py

```

import ee

def get_surface_soil_moisture():
    # Load data
    smap_dataset = ee.ImageCollection("NASA_USDA/HSL/SMAP10KM_soil_moisture")

    # Define observation Period
    smap_2015_2020 = smap_dataset.filterDate('2015-04-02', '2021-01-01')

    # Select bands
    surface_soil_moisture = smap_2015_2020.select('ssm')

    surface_soil_moisture_mean = surface_soil_moisture.mean()

    return surface_soil_moisture_mean

def min_max(normalization_reference):
    """
    Calculates the minimum, maximum and mean average surface soil moisture
    (2015-2020) within the given normalization reference.

    Args:
        normalization_reference (ee FeatureCollection): The reference at
        which to normalize the variable.

    Returns:
        float: The minimum average surface soil moisture within the normalization reference.
        float: The maximum average surface soil moisture within the normalization reference.
        float: The mean average surface soil moisture within the normalization reference.
    """

    surface_soil_moisture = get_surface_soil_moisture()

```

```

# Define a function to compute min, max and mean for each tile
def get_min_max_mean(tile):
    stats = surface_soil_moisture.reduceRegion(
        reducer=ee.Reducer.minMax().combine(
            reducer2=ee.Reducer.mean(),
            sharedInputs=True
        ),
        geometry=tile.geometry(),
        scale=10000,
        maxPixels=1e11
    )
    return tile.set({
        'min_ssm': stats.get('ssm_min'),
        'max_ssm': stats.get('ssm_max'),
        'mean_ssm': stats.get('ssm_mean')
    })

# Apply the function over the fishnet tiles
min_max_mean_tiles = normalization_reference.map(get_min_max_mean)

# Aggregate the results
min_ssm_list = min_max_mean_tiles.aggregate_array('min_ssm').getInfo()
max_ssm_list = min_max_mean_tiles.aggregate_array('max_ssm').getInfo()
mean_ssm_list = min_max_mean_tiles.aggregate_array('mean_ssm').get-
Info()

min_ssm_float = min(min_ssm_list)
max_ssm_float = max(max_ssm_list)
mean_ssm_float = sum(mean_ssm_list) / len(mean_ssm_list)

print(f"Min ssm: {min_ssm_float}, Max ssm: {max_ssm_float }, Mean ssm:
{mean_ssm_float }")

return min_ssm_float, max_ssm_float, mean_ssm_float

def get_surface_soil_moisture_region(region_of_interest, min_value,
max_value, mean_value):
    """
    Calculates the mean average surface soil moisture (2015-2020) within
    the given region of interest and normalizes the value at the normalization
    reference level.

    Args:
        region_of_interest (ee geometry object): The region for which to
        calculate the hazard index.
        min_value (float): The minimum value of this variable within the
        normalization reference.

```

max_value (float): The maximum value of this variable within the normalization reference.

Returns:

ee number object: The normalized average surface soil moisture for the region of interest.

"""

```
surface_soil_moisture = get_surface_soil_moisture()

min_ssm = ee.Number(min_value)
max_ssm = ee.Number(max_value)
max_minus_min_ssm = max_ssm.subtract(min_ssm)

# Get mean ssm for region of interest
ssm_region = surface_soil_moisture.reduceRegion(
    reducer=ee.Reducer.mean(),
    geometry=region_of_interest,
    scale=90 # Originally 10000
).get('ssm')

# Assign mean value to ssm_region if value is null to fill data gaps
ssm_region = ee.Algorithms.If(ssm_region, ssm_region, mean_value)

ssm_region = ee.Number(ssm_region)

# Normalize ssm value for region of interest
ssm_region_normalized = (max_ssm.subtract(ssm_region)).divide(max_minus_min_ssm)

return ee.Number(ssm_region_normalized).getInfo()
```