

---

# Abschlussbericht Umwelt 4.0

Nutzung digitaler Geländemodelle und Copernicus-Daten

Projektjahr 4

Lara Weber<sup>1</sup>, Dr. Michael Rudolf<sup>2</sup>, Marc Saghir<sup>1</sup>

Prof. Dr.-Ing. Dorota Iwaszczuk<sup>1</sup>, Prof. Dr. Andreas Henk<sup>2</sup>, Dr. Benjamin Homuth<sup>3</sup>

<sup>1</sup>Technische Universität Darmstadt, Fachgebiet Fernerkundung und Bildanalyse

<sup>2</sup>Technische Universität Darmstadt, Fachgebiet Ingenieurgeologie

<sup>3</sup>Hessisches Landesamt für Naturschutz, Umwelt und Geologie



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT



Für eine lebenswerte Zukunft



Hessisches Ministerium für  
Digitalisierung und Innovation



digitales.hessen

---

# 1 Inhaltsverzeichnis

---

<b>1</b>	<b>Inhaltsverzeichnis</b>	<b>i</b>
<b>2</b>	<b>Zusammenfassung</b>	<b>1</b>
<b>3</b>	<b>Kurze Darstellung</b>	<b>1</b>
3.1	Aufgabenstellung	1
3.2	Planung und Ablauf Projektjahr 2025	2
3.2.1	AP 25-1 Klassifizierung von Bodenbewegungsgebieten	2
3.2.2	AP 25-2 Anwendung von Machine-Learning / KI-Verfahren	2
3.2.3	AP 25-3 Erstellung von Trainingsdatensätzen	3
3.2.4	AP 25-4 Anwendung SBAS-Verfahren zur Erweiterung des Bodenbewegungsdienstes	3
3.2.5	AP 25-5 Anwendungsausweitung und Visualisierung	4
3.2.6	AP 25-6 Berichterstellung, Datenabgabe und Datenintegration zur Veröffentlichung	4
<b>4</b>	<b>Eingehende Darstellung</b>	<b>5</b>
4.1.1	AP 25-1 Klassifizierung von Bodenbewegungsgebieten	5
4.1.2	AP 25-2 Anwendung von Machine-Learning / KI-Verfahren	10
4.1.3	AP 25-3 Erstellung von Trainingsdatensätzen	20
4.1.4	AP 25-4 Anwendung SBAS-Verfahren zur Erweiterung des Bodenbewegungsdienstes	23
4.1.5	AP 25-5 Anwendungsausweitung und Visualisierung	24
4.1.6	AP 25-6 Berichterstellung, Datenabgabe und Datenintegration zur Veröffentlichung	26
<b>5</b>	<b>Ausblick</b>	<b>26</b>
<b>6</b>	<b>Literaturverzeichnis</b>	<b>27</b>

---

## 2 Zusammenfassung

---

Im Projekt „Umwelt 4.0 – Cluster I“ wurden Bodenbewegungen in Hessen analysiert, um deren Ursachen zu identifizieren und die Ergebnisse für Behörden sowie der Öffentlichkeit aufzubereiten. In den vorherigen Projektjahren (2022–2024) wurden aus Fernerkundungsdaten bereits anomale Regionen mit erhöhten Bodenbewegungsraten extrahiert und besonders auffällige Gebiete analysiert. Ein zentrales Ergebnis dieser Arbeiten ist eine landesweite Differenzenkarte, die rund 5.000 potenzielle Bodenbewegungsgebiete in Hessen enthält, jedoch bislang weitgehend unklassifiziert ist.

In diesem Projektjahr (2025) wurde ein Teil der zuvor identifizierten Anomalien manuell in 19 Klassen klassifiziert um als Trainingsdaten für Machine-Learning verwendet zu werden. Um diesen Prozess zu automatisieren, wurden drei verschiedene Machine-Learning Verfahren eingesetzt: Random-Forest, U-Net und YOLO (You Only Look Once).

Das Random-Forest-Modell wurde ausschließlich auf den geologischen Attributen der Anomalien trainiert, um die Aussagekraft bzw. Diskriminierungsfähigkeit der Attribute der Differenzenkarte zu bewerten. Die Ergebnisse zeigten jedoch, dass diese ohne visuellen Kontext nicht ausreichend diskriminativ sind. Daher wurde im nächsten Schritt ein U-Net, sowohl auf der Differenzenkarte als auch auf den Attributen, trainiert. Die Ergebnisse waren im Vergleich zum rein Attribut-basierten Ansatz eine deutliche Verbesserung, jedoch war ein zentrales Problem dabei, dass die verfügbare Datenmenge für das Training eines Machine-Learning Modells zu gering ist. Deshalb lag im weiteren Verlauf des Projektes der Schwerpunkt auf der Identifikation von Rutschungen, anstatt wie zuvor, den 19 verschiedenen Klassen.

Um potenzielle neue Rutschungen in Hessen zu identifizieren, wurde ein YOLO-Modell auf dem jüngsten Digitalen Geländemodell (DGM), sowie einer existierenden Rutschungsdatenbank trainiert. Durch Methoden der künstlichen Datenerweiterung konnte die Performance von YOLO bis zu 87% Recall und 82% Precision auf den Testdaten erreichen. Durch die landesweite Inferenz des Modells, wurden rund 5.000 Anomalien, die potenzielle Rutschungen in Hessen darstellen, identifiziert und zur weiteren Evaluation mit den Polygonen der bestehenden Differenzenkarte verschnitten. Weitere falsch-positive Ergebnisse wurden durch fachlich begründete Ausschlusskriterien eliminiert. Insgesamt konnte die Anzahl auf etwa 200 potenziell interessante Anomalien reduziert werden. Im Vergleich zu den ursprünglichen 5.000 unklassifizierten Anomalien, stellt dies eine erhebliche Reduktion der Datenmenge dar und schränkt die nötige manuelle Überprüfung auf eine überschaubare und relevante Datenmenge ein.

Bei der manuellen Überprüfung wurde jedoch festgestellt, dass die KI eher allgemein unebenes Terrain, ähnlich dem von Bewegungsgebieten, erkennt. Dies funktioniert auf verschiedenen Skalen recht gut. Allerdings ist der Ursprung dieses unebenen Terrains in der Kulturlandschaft Hessens sehr oft nicht auf natürliche Prozesse zurückzuführen. Auch hier fallen die Artefakte durch die DEM Erstellung (Koregistrierungsfehler und Rauschen) besonders stark ins Gewicht und erzeugen eine hohe Zahl von falsch-positiven Ergebnissen.

---

## 3 Kurze Darstellung

---

### 3.1 Aufgabenstellung

Aufbauend auf den Ergebnissen aus den Projektjahren 2022-2024 wurden im Jahr 2025 vertiefende Analysen mit den bestehenden, sowie neuen Datensätzen durchgeführt. Hierfür wurde das Projekt in verschiedene Arbeitspakete unterteilt, welche im Folgenden kurz dargestellt werden (Tabelle 3). Die Hauptaufgabe im letzten Projektjahr bestand in der Untersuchung der Einsatzmöglichkeiten von Machine-Learning-Verfahren zur Detektion und Klassifikation von Bodenbewegungen, insbesondere Rutschungen, in Hessen.

## Jahr 4 - 2025

AP 25-1	Klassifizierung von Bodenbewegungsgebieten	Durchführung einer manuellen Klassifizierung an einer Auswahl der zuvor im Projekt identifizierten Anomalien.  Die im Projekt zuvor extrahierten Anomalien sollen mittels verschiedener KI- und Bildanalyseverfahren gefiltert und klassifiziert werden, um potenziell unbekannte bzw. unklassifizierte Bodenbewegungen zu identifizieren und klassifizieren.
AP 25-2	Anwendung von Machine-Learning / KI-Verfahren	Aufbereitung der in Arbeitspaket 1 klassifizierten Bodenbewegungen in ein maschinenlesbares Format.
AP 25-3	Erstellung von Trainingsdatensätzen	Regionale Berechnung der Bodenbewegungen anhand des SBAS-Verfahrens.
AP 25-4	Anwendung des SBAS-Verfahrens zur Erweiterung des Bodenbewegungsdienstes	Bewertung der Einsatzmöglichkeiten der Datensätze für weitere Anwendungen sowie alternative Darstellungsformen.
AP 25-5	Anwendungsausweitung und Visualisierung	Erstellung des Abschlussberichts sowie Weitergabe der erzielten Ergebnisse an die Projektpartner und – sofern möglich – Bereitstellung für die Öffentlichkeit.
AP 25-6	Berichterstellung, Datenabgabe und Datenintegration zur Veröffentlichung	

Tabelle 1: Übersicht der Arbeitspakete und deren Inhalt

## 3.2 Planung und Ablauf Projektjahr 2025

### 3.2.1 AP 25-1 Klassifizierung von Bodenbewegungsgebieten

**Beschreibung:** Im bisherigen Projektverlauf wurden mehrere tausend potenzielle Bodenbewegungen in Hessen erkannt. Diese können nur zu einem gewissen Grad manuell überprüft werden. Daher wurde in der bisherigen Projektlaufzeit der Fokus auf Gebiete mit konkreter, bekannter Gefährdung gelegt. Es bleiben jedoch noch viele auffällige Bodenbewegungsgebiete unbeachtet, welche ebenfalls klassifiziert werden müssen. Dies muss sowohl manuell für prägnante Anomalien, als auch über KI-Verfahren für die große Masse an Bodenbewegungsgebieten erfolgen. Diese Arbeiten werden in Zusammenarbeit mit dem Fachgebiet Ingenieurgeologie der TU Darmstadt und dem HLNUG durchgeführt.

#### **Einzelschritte und Zeitplanung:**

- Manuelle Klassifikation von Bodenbewegungsgebieten (Zeitaufwand: 4 Monate)

**Zeitaufwand insgesamt:** 4 Monate

**Partner:** HLNUG, Fachgebiet Ingenieurgeologie TU Darmstadt

**Zielerreichung:** Es wurden im Projekt insgesamt 1430 Anomalien manuell klassifiziert. Nach Abschluss der Arbeiten in AP25-2 konnten 200 weitere Anomalien manuell klassifiziert werden.

### 3.2.2 AP 25-2 Anwendung von Machine-Learning / KI-Verfahren

**Beschreibung:** In Arbeitspaket 2 sollen verschiedene Bildanalyseverfahren mittels Machine-Learning auf die bisher klassifizierten Bodenbewegungen angewendet werden, um die verbleibenden, noch nicht klassifizierten Gebiete zu evaluieren. Hierfür sollen auch 2 weitere flächige Datensätze eingebunden werden, die bisher nicht Teil des Projekts waren. Dies sind zum einen (multispektrale) Luftbilder als auch Bodenbedeckungsdaten (Landbedeckung und Landnutzung), die mit in den Workflow eingebunden werden sollen. Vor allem für (Luft-) Bilder gibt es bereits vortrainierte KI-Modelle, welche erfolgreich zur Objekterkennung verwendet werden.

---

Dies erfolgt parallel in Zusammenarbeit mit den Fachgebieten Ingenieurgeologie und Fernerkundung und Bildanalyse der TU Darmstadt und dem HLNUG.

**Einzelschritte und Zeitplanung:**

- Test verschiedener Machine-Learning / KI – Modelle zur automatischen Detektion und Klassifizierung von Bodenbewegungen (Zeitaufwand: 3 Monate)
- Einbinden weiterer flächiger Datensätze (Zeitaufwand: 3 Monate)
- Anwendung getesteter und trainierter KI-Modelle auf den Bodenbewegungsdatensatz (Zeitaufwand: 2 Monate)

**Zeitaufwand insgesamt:** 8 Monate

**Partner:** HLNUG, Fachgebiet Ingenieurgeologie und Fachgebiet Fernerkundung und Bildanalyse TU Darmstadt

**Zielerreichung:** Zur Segmentierung und Klassifizierung der Daten wurden drei verschiedene Machine-Learning-Verfahren angewendet. Neben der Differenzenkarte wurde auch das DGM und geologische Parameter in die Modelle und die Evaluation integriert.

### **3.2.3 AP 25-3 Erstellung von Trainingsdatensätzen**

**Beschreibung:** Um die automatische Klassifizierung von Bodenbewegungsgebieten durchführen zu können, müssen für die KI-Modelle Trainingsdatensätze erstellt werden. Die in Arbeitspaket 3 erstellten Trainingsdatensätze werden in Arbeitspaket 2 verwendet. Die Arbeiten in Arbeitspaket 3 erfolgen in Zusammenarbeit mit den Fachgebieten Ingenieurgeologie und Fernerkundung und Bildanalyse der TU Darmstadt und dem HLNUG.

**Einzelschritte und Zeitplanung:**

- Erstellung von Trainingsdatensätzen (Zeitaufwand: 3 Monate)

**Zeitaufwand insgesamt:** 3 Monate

**Partner:** HLNUG, Fachgebiet Ingenieurgeologie und Fachgebiet Fernerkundung und Bildanalyse TU Darmstadt

**Zielerreichung:** Die im Arbeitspaket 1 klassifizierten Anomalien wurden in maschinenlesbarer Form aufbereitet und in Arbeitspaket 2 als Trainingsdatensätze verwendet.

### **3.2.4 AP 25-4 Anwendung SBAS-Verfahren zur Erweiterung des Bodenbewegungsdienstes**

**Beschreibung:** Ziel des Arbeitspaketes 4 ist es, das SBAS-Verfahren zur Erweiterung des Datensatzes des Bodenbewegungsdienstes in weiteren Regionen und zu erweiterten Zeiträumen durchzuführen. Sinnvolle Regionen werden im Laufe des Projektes durch die Partner ausgesucht. Nach Auswahl dieser Regionen erfolgt eine Berechnung der Bodenbewegungen anhand des SBAS-Verfahrens. So kann die Datendichte der InSAR Messungen im ländlichen Raum erhöht werden und auch für die dortigen Nutzer (Öffentlichkeit, hessische Behörden, etc.) einen erheblichen Mehrwert für vielfältige Fragestellungen, bei denen Bodenbewegungen eine Rolle spielen, darstellen. Mit den bisherigen Daten ist dies hauptsächlich nur für die urbanen Räume von Hessen möglich. Des Weiteren sollen die berechneten Bodenbewegungen mittels Langzeitmessungen (z.B. GRSN-Stationen) validiert werden. Diese Arbeiten werden in Zusammenarbeit mit den Fachgebieten Ingenieurgeologie und Fernerkundung und Bildanalyse der TU Darmstadt und dem HLNUG durchgeführt.

**Einzelschritte und Zeitplanung:**

- Auswahl der Regionen (Zeitaufwand: 1 Monat)
- Berechnung der Bodenbewegung anhand des SBAS-Verfahrens für die ausgewählten Regionen und Zeiträume (Zeitaufwand: 3 Monate)

- 
- Auswertung und Validierung der Ergebnisse (Zeitaufwand: 2 Monate)

**Zeitaufwand insgesamt:** 5 Monate

**Partner:** HLNUG, Fachgebiet Ingenieurgeologie und Fachgebiet Fernerkundung und Bildanalyse TU Darmstadt

**Zielerreichung:** Aufgrund von Zugriffsbeschränkungen der vorgesehenen Software war die Berechnung von Bodenbewegungen in dem geplanten Umfang nicht möglich. Da die Machine-Learning-Aufgaben zeitaufwändiger als ursprünglich geplant waren, wurde beschlossen, AP25-2 zeitlich auszuweiten mit den Ressourcen, die in AP25-4 nicht eingesetzt werden konnten.

### 3.2.5 AP 25-5 Anwendungsausweitung und Visualisierung

**Beschreibung:** In Arbeitspaket 5 soll evaluiert werden, ob die Datensätze für andere Anwendungen verwendet werden können bzw. ob weitere Daten in das Projekt integriert werden können, so z.B. die Erhebung von in-situ Messdaten zu Bodenbewegungen/ Erschütterungen. Als potentielle erweiterte Anwendungen sind Bereiche, die durch menschliche Aktivitäten geprägt sind (Steinbrüche, Halden und Deponien), denkbar. Bisher wurden diese Gebiete nicht vorrangig bearbeitet, da die menschliche Aktivität mögliche natürliche Prozesse überlagert. Zusätzlich sollen, neben der Darstellung in Viewern, weitere Formen der Visualisierung der Datensätze geprüft werden (3D-Ansichten, GST-Viewer, Augmented Reality, etc.). Diese Arbeiten werden durch das HLNUG durchgeführt.

#### **Einzelschritte und Zeitplanung:**

- Potentialanalyse zur Anwendungsausweitung (Zeitaufwand: 3 Monate)
- Visualisierungstests (Zeitaufwand: 3 Monate)

**Zeitaufwand insgesamt:** 6 Monate

**Partner:** HLNUG

**Zielerreichung:** Zur Einrichtung einer in-situ Messstation wurden entsprechende Messgeräte angeschafft. Aufgrund der späten Mittelverfügbarkeit und entsprechender Lieferzeiten, konnten die Messgeräte gekauft, jedoch noch nicht im Gelände installiert werden. Als potentielle weitere Anwendungen wurde die Bestimmung von Abbau- und Einlagerungsmengen von Steinbrüchen, Halden und Deponien, sowie Daten zur Überwachung von Setzungen von Deponien identifiziert. Weitere Formen der Visualisierung der Datensätze sind möglich und sollen in 2026 weiterverfolgt werden (3D-Ansichten, GST-Viewer).

### 3.2.6 AP 25-6 Berichterstellung, Datenabgabe und Datenintegration zur Veröffentlichung

**Beschreibung:** Im abschließenden Arbeitspaket 6 soll der Endbericht ausgearbeitet und die erstellten Ergebnisse zwischen den Partnern ausgetauscht und soweit möglich öffentlich zur Verfügung gestellt werden. Diese Arbeiten werden in Zusammenarbeit mit den Fachgebieten Ingenieurgeologie und Fernerkundung und Bildanalyse der TU Darmstadt und dem HLNUG durchgeführt.

#### **Einzelschritte und Zeitplanung:**

- Berichterstellung und Zurverfügungstellung entsprechender Daten zur Veröffentlichung (Zeitaufwand: 1 Monat)

**Zeitaufwand insgesamt:** 1 Monat

**Partner:** HLNUG, Fachgebiet Ingenieurgeologie und Fachgebiet Fernerkundung und Bildanalyse TU Darmstadt

**Zielerreichung:** Im Dezember 2025 wurde dieser Bericht erstellt und die prozessierten Daten zwischen den Projektpartnern ausgetauscht.

---

## 4 Eingehende Darstellung

---

### 4.1.1 AP 25-1 Klassifizierung von Bodenbewegungsgebieten

Im bisherigen Projektverlauf wurden mehrere tausend potenzielle Bodenbewegungen in Hessen erkannt. Diese können nur zu einem gewissen Grad manuell überprüft werden. Daher wurde in der bisherigen Projektlaufzeit der Fokus auf Gebiete mit konkreter, bekannter Gefährdung gelegt. Es bleiben jedoch noch viele auffällige Bodenbewegungsgebiete unbeachtet, welche ebenfalls klassifiziert werden müssen. Dies muss sowohl manuell für prägnante Anomalien, als auch über KI-Verfahren für die große Masse an Bodenbewegungsgebieten erfolgen.

Für die manuelle Klassifikation wurden Bilddatensätze erstellt, welche mittels der eigens dafür entwickelten Software U4App ausgewertet wurde (siehe Zwischenbericht Projektjahr 2 & 3 des Umwelt 4.0 – Cluster I). Die Software erlaubt einen schnellen Vergleich der unterschiedlichen Klassifikationsmerkmale und somit einfache, direkte Klassifizierung der Gruppen in der Geodatenbank. Neben den in den Datengrundlagen genannten Geodaten, wurden hier noch zusätzlich Luftbilder, Bing-Maps und Google-Maps Daten integriert. Für jede anomale Region können bis zu drei manuelle Klassen festgelegt werden. Dies soll zum einen ermöglichen, dass für einzelne Anomalien einzelne Ursachen hinterlegt werden können und zum anderen eine Wertung möglicher Ursachen erlauben, falls die Ursache unklar ist. Darüber hinaus kann ein Freitextkommentar hinterlegt werden, in dem die Begründung für die Entscheidung dargelegt wird. Auch können einzelne Gruppen als „unklar“ und mit „weitere Untersuchungen notwendig“ markiert werden, sodass besonders interessante Kandidaten in der Datenbank hervorgehoben werden können.

Es wurden im Projekt insgesamt 1430 Anomalien manuell klassifiziert. Nach Abschluss der Arbeiten in AP25-2 konnten 198 weitere Anomalien manuell klassifiziert werden. Die klassifizierten Anomalien sind in einer GeoPackage-Datei und damit in einem GIS-lesbaren Format abgelegt.

Mittels der KI wurden aus dem DEM und DGM verschiedene Bereiche extrahiert, welche ähnlich zu bekannten Bewegungsanomalien sind. Hierbei wurden 198 Bereiche als mögliche Bewegungsanomalien erkannt. Sie verteilen sich relativ regelmäßig über ganz Hessen (Abbildung 1). In stärker bewaldeten und hügeligen Regionen kommen sie etwas häufiger vor. Die gefundenen Anomalien wurden danach nochmals manuell plausibilisiert und somit geprüft, ob durch den KI-gestützten Workflow eine Verbesserung der Datengrundlage möglich ist. Bei der Plausibilisierung wurde jeder Anomalie eine Hauptkategorie zugeordnet und in ca. 25 % der Fälle eine zusätzliche Nebenkategorie (Abbildung 2). Bei letzterer kann es sich um eine alternative Erklärung der Anomalie handeln oder um zwei verschiedene Anomalien innerhalb einer Region.

Der überwiegende Anteil der Anomalien ist nicht-natürlichen Ursprungs (ca. 85 %). Eine Vielzahl der erkannten Anomalien liegt in Bereichen mit stark unebenem Terrain. Dies kommt zwar insbesondere im Ablagerungsbereich von großen Hangrutschungen vor, ist aber im vorliegenden Datensatz auch in stark bewaldeten Regionen anzutreffen. Auch die scheinbar unregelmäßige Topographie, welche durch die Entfernung von Gebäuden in bebauten Gebieten entsteht, ergibt eine große Anzahl von falsch-positiven Ergebnissen. Allerdings, konnten auch mehrere Anomalien detektiert werden, welche eindeutig natürlichen Ursprungs sind. Unter anderem stark erodierte Bachläufe oder einige wenige, kleine Hangrutschungen, welche in der letzten Projektphase nicht erkannt wurden.

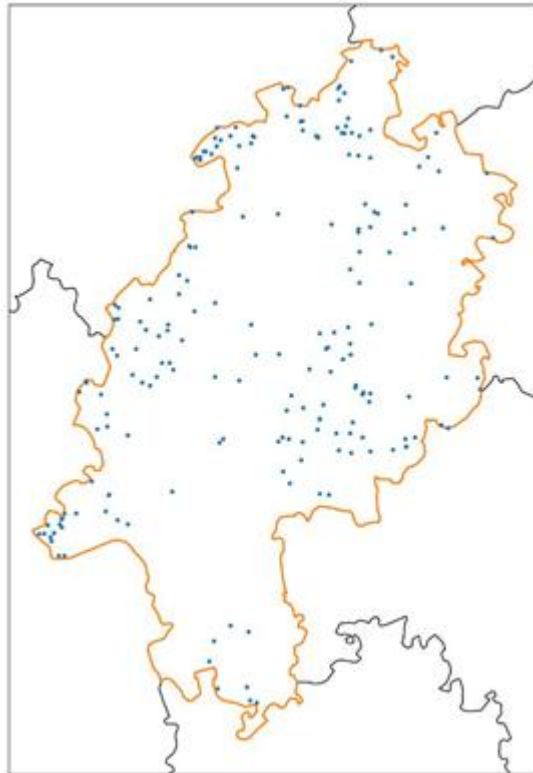


Abbildung 1 Karte von Hessen mit den gefundenen Anomalien als blaue Punkte

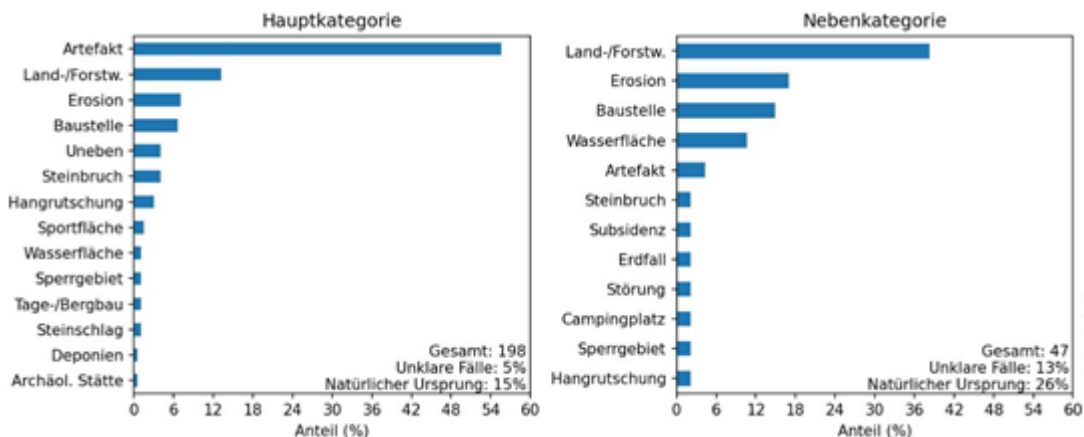


Abbildung 2 Häufigkeiten der gefundenen Anomalien

### Anthropogene Anomalien

Über 55% der gefundenen Anomalien sind Artefakte, vor allem in bewaldeten Regionen und an steilen Hängen. Starke Vegetation sorgt für höheres Rauschen in der Bestimmung der wahren Erdoberfläche, welches sich in scheinbaren kleinen Hügeln äußert. Dies sind vermutlich Baumstümpfe oder nicht korrekt bestimmbare Baumstämme, welche bei der DEM Erstellung unvollständig entfernt werden (Abbildung 3, links). In ähnlicher Weise entstehen Artefakte auf landwirtschaftlich genutzten Flächen, allerdings ist dort das „Rauschen“ etwas schwächer ausgeprägt, oder weist eine Vorzugsorientierung auf, welche durch die Bodenbearbeitung (Pflügen) entsteht. Weitere Artefakte entstehen aus der Entfernung von Gebäuden bei der DEM Erstellung (Abbildung 3, rechts). Beide Artefaktarten wurden auch bei der ersten Analyse als häufigste Anomalien gefunden. Prinzipiell fallen auch Wasserflächen unter diese Art der Anomalie, wurden hier allerdings getrennt kategorisiert.

Die zweithäufigste Hauptkategorie und häufigste Nebenkategorie sind Anomalien, die aufgrund der land- oder forstwirtschaftlichen Nutzung von Grundstücken entstehen (Abbildung 4). Hierbei handelt es sich häufig um

Bodenbearbeitung oder Lagerung von landwirtschaftlichen Produkten auf Freiflächen. In den bewaldeten Regionen fallen hier die Anlage von Forstwegen, Rückegassen oder die Rodung von Flächen als Hauptursache auf.




Abbildung 3 Artefakte im Datensatz. Links: Verrauschte Region aufgrund der Vegetation. Rechts: Interpolationsfehler aufgrund der Entfernung von Gebäuden aus der DEM Wolke




Abbildung 4 Anomalien aufgrund von land- oder forstwirtschaftlicher Nutzung. Links: Anlage von Feldern mit streifenförmigen Pflugspuren (teilweise auch als Artefakte kategorisiert). Rechts: Leicht abschüssiges Gelände, welches als Viehweide, Lagerplatz und Forst verwandt wird



Abbildung 5 Verschiedene Anomalien unklaren Ursprungs mit stark unebener Topographie

Ähnlich verhält es sich mit allgemein unebenem Terrain (Abbildung 5). Als solche wurden Flächen klassifiziert, welche nicht eindeutig durch eine bestimmte Nutzung oder andere natürliche Prozesse entstanden sein könnten. Oft handelt es sich um Abhänge oder bewaldete Terrassen, welche eine leicht strukturierte Topographie haben, allerdings nicht klar zuzuordnen sind. Es könnte sich bei manchen um erosiv entstandene Einschnitte handeln, deren Abfluss mittlerweile nicht mehr vorhanden ist, ebenso kommen nicht renaturierte Abbauf Flächen, kleinere Abgrabungen oder sonstiges Unland in Frage. Weitere nicht-natürliche Anomalien sind Baustellen, Steinbrüche, Sportflächen (hier vor allem Golfplätze), Tage-/Bergbau und Deponien.

## Natürliche Anomalien

Als häufigste natürliche Anomalie wurden erosive Prozesse erkannt. Diese sorgen sehr häufig entlang von Bächen (Abbildung 6, links) oder Abhängen (Abbildung 6, rechts) für unebenes Terrain. Dieses wird scheinbar vom Algorithmus als mögliche Bodenbewegung erkannt und dementsprechend markiert.




Abbildung 6 Verschiedene Anomalien unklaren Ursprungs mit stark unebener Topographie


Im Datensatz wurden vier Anomalien als mögliche Hangrutschungen klassifiziert. Allerdings ist keine davon eindeutig im Differenzenplan als solche zu erkennen. Eine Anomalie liegt zwar neben mehreren Hangrutschungen, unterscheidet sich aber in der Topographie nicht wesentlich von der Umgebung. Ebenfalls wurden zwei Anomalien identifiziert, welche möglicherweise durch kleinräumige Rutschungen bzw. Steinschlag entstanden sind.

## Liste der Hangrutschungen



### Anomalie neben bekannten Rutschungen bei Malsfeld

Westlich der Anomalie liegen mehrere kleine Rutschungen am Rande des Strauchgrabens. Diese sind jeweils ca. 45×30 m und ca. 50×100 m groß. Die Anomalie ist etwa ca. 250×60 m groß und erstreckt sich über einen Bacheinschnitt sowie ein größeres Feld.



### Anomalie auf bekannter Rutschung am Hohen Meissner

Die Anomalie wird durch die Größe des Bildausschnitts für die KI-Klassifizierung begrenzt und erstreckt sich vermutlich weiter als diese über eine Fläche von >1 km<sup>2</sup>. Sie ist durch mehrere hangparallele Geländekanten gegliedert und wird von mehreren Senkungsmulden und Erdfällen überzogen (violette Flächen und rote Punkte).



#### **Kleine Anomalie auf Feld bei Geilshausen**

Die ca. 50×15 m große Anomalie liegt am Rande eines Felds in der Nähe eines Hangs bei Geilshausen. Laut Differenzenplan wurde Material auf der hangzugewandten Seite abgetragen und unterhalb abgelagert. Allerdings ist die Topographie nicht wirklich stark ausgeprägt und daher eine natürliche Ursache eher unwahrscheinlich. Laut Luftbildbefund könnte es sich um eine temporäre Nassstelle oder um eine Abgrabung durch den Landwirt handeln.




#### **Anomalie auf Ostheimer Hute**

Die Anomalie erstreckt sich auf 200×150 m auf den südwestlich ausgerichteten Steilhängen der Ostheimer Hute. Dies ist ein Naturschutzgebiet, welches durch Bewidungsmaßnahmen auf Kalkmagerrasen aufrechterhalten wird. Daher liegt die Vermutung nahe, dass es sich bei den hangparallelen Terrassen um Viehtrittterrassen (engl. terracettes) handelt, welche durch die Beweidung über mehrere Jahrhunderte entstanden sind.



#### **Unebenes Terrain neben Hirschberg**

Die Anomalie liegt westlich des Hirschbergs, am Rand der ehemaligen Braunkohletagebaue und erstreckt sich auf 160×100 m. Ein kleiner Bereich am nördlichen Rand der Anomalie zeigt entlang einer sichelförmigen Geländekante Materialzuwachs (hellblau), welcher vermutlich durch herabfallendes Gestein verursacht wurde. Aufgrund der Lage in der Nähe der Tagebaue ist von einer nicht-natürlichen Ursache auszugehen.



#### **Unebenes Terrain in der Nähe des Forsthauses Kammerforst**

Die Anomalie liegt auf 650×450 m Fläche wo sich mehrere Forstwege schneiden. Der überwiegende Teil ist bewaldet und daher ist eine Kategorisierung als Artefakt möglich. Im Zentrum der Anomalie, westlich der Wegkreuzung, liegt ein kleines Gebiet (70×50 m) mit stark unebenem Terrain und Bodenbewegungen. Es könnte sich hier um einen offenen gelassenen Steinbruch handeln, an dem kleinere Steinschläge oder Rutschungen auftreten und so im DEM Spuren hinterlassen. Allerdings könnten diese auch aufgrund der steilen

Topographie entlang der Kanten als Artefakte der Befliegung auftreten.

Zusammenfassend ist festzustellen, dass die KI Klassifizierung nur wenige neue Erkenntnisse erbracht hat. Es scheint, dass der Algorithmus eher allgemein unebenes Terrain, ähnlich dem von Bewegungsgebieten, erkennt. Dies funktioniert auf verschiedenen Skalen recht gut. Allerdings ist der Ursprung dieses unebenen

Terrains in der Kulturlandschaft Hessens sehr oft nicht auf natürliche Prozesse zurückzuführen. Auch hier fallen die Artefakte durch die DEM Erstellung (Koregistrierungsfehler und Rauschen) besonders stark ins Gewicht und erzeugen eine hohe Zahl von falsch-positiven Ergebnissen.

#### 4.1.2 AP 25-2 Anwendung von Machine-Learning / KI-Verfahren

##### Auswahl der Methodik

Mit dem Ziel, die zuvor im Projekt identifizierten Anomalien zu klassifizieren, wurden im Rahmen dieses Arbeitspakets drei verschiedene Machine-Learning Verfahren angewandt: Random Forest, U-Net und Yolo. Um die Performance der einzelnen Modelle zu verbessern, kamen sowohl externe Datensätze als auch Methoden der künstlichen Datenerweiterung, zum Einsatz. Das beste Ergebnis wurde mit dem Yolov11-Modell erzielt und somit zur abschließenden Evaluation verwendet.

##### Random Forest

Random Forest (Breiman, 2001) ist ein etabliertes Machine-Learning-Verfahren in der Fernerkundung. Es besteht aus mehreren einzelnen Entscheidungsbäumen, wobei jeder mit zufällig ausgewählten Daten und Merkmalen trainiert wird. Die einzelnen Bäume treffen Vorhersagen, die am Ende zu einer Mehrheitsentscheidung zusammengefasst werden.

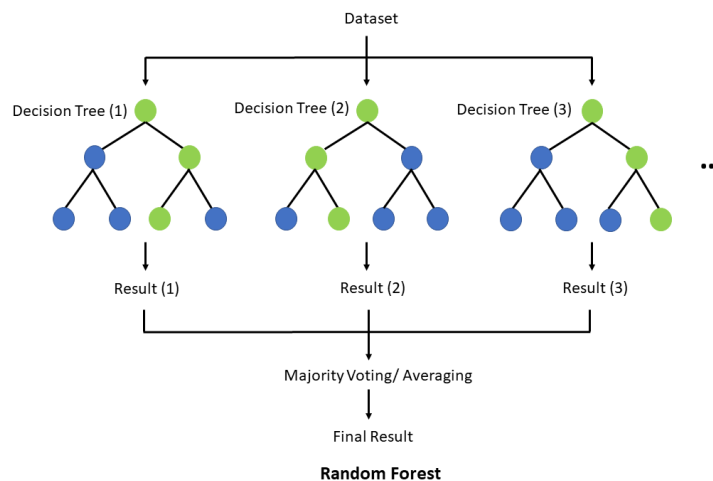


Abbildung 7 Schematische Übersicht eines Random Forest Modells

Quelle: [https://de.wikipedia.org/wiki/Random\\_Forest](https://de.wikipedia.org/wiki/Random_Forest)

Um aus den vorhandenen Daten den Informationsgehalt für ein KI-Modell abschätzen zu können wurde initial ein Random Forest Modell mit den Maschinenlesbaren Attributen der Differenzenkarte trainiert (Abbildung 7 Schematische Übersicht eines Random Forest Modells

Quelle: [https://de.wikipedia.org/wiki/Random\\_Forest](https://de.wikipedia.org/wiki/Random_Forest) (Abbildung 7). Dabei wurden keine visuellen Informationen miteinbezogen. Die vorhandenen Trainingsdaten wurden in einem Verhältnis 80/20 in Trainings- und Testdatensatz aufgeteilt. Eine Auswertung der Klassifikation auf den Testdaten (Abbildung 8) zeigt, dass das unbalancierte Verhältnis der vorhandenen Klassen in den Trainingsdaten einen stärkeren Einfluss auf das Ergebnis hat als die Attribute selbst. Außerdem wird aus diesem Ergebnis auch klar, dass die Attribute allein nicht ausreichend diskriminativ sind um als Klassifikationsgrundlage zu dienen.

```
Random Forest 80/20 Split Classification Report
=====
precision    recall
-----
  Alllast      0.00    0.00
  Artefakt     0.71    0.38
  Aufschüttung 0.00    0.00
  Baustelle    0.35    0.73
  Deponie      0.20    0.14
  Erdfall      0.00    0.00
  Erosion      0.00    0.00
  Freizeitanlage 0.00    0.00
  Gewässer     0.00    0.00
  Hebung       0.00    0.00
  Industrie    0.00    0.00
  Landwirtschaft 0.55    0.43
  Rutschung    0.00    0.00
  Steinbruch   0.00    0.00
  Steinschlag  0.00    0.00
  Unbekannt    1.00    0.67
```

Abbildung 8 Ergebnisse auf den Testdaten mit Random Forest

Deshalb wurde dieser Ansatz nicht weiterverfolgt.

### U-Net

Das U-Net (Ronneberger, 2015) ist ein in der Bildanalyse etabliertes neuronales Netzwerk zur Segmentierung (Abbildung 9). Die Architektur hat eine U-förmige Struktur, entlang derer die Inputbilder verarbeitet werden. Im ersten Schritt werden durch Faltungen und Downsampling abstrakte globale Kontextinformationen aus den Bildern extrahiert. Im zweiten Schritt wird durch Upsampling die räumliche Auflösung schrittweise wiederhergestellt, wobei lokale Kontextinformationen rekonstruiert werden. Mithilfe sogenannter Skip-Connections werden dabei Merkmalskarten erstellt, die Informationen aus dem Downsampling-Pfad mit dem Upsampling-Pfad verknüpfen. Auf diese Weise kombiniert U-Net globale und lokale Kontextinformation und was eine pixelgenaue Segmentierung ermöglicht.

Insbesondere zur Detektion von Rutschungen mit Fernerkundung wurde in der Literatur bereits ResNet (Kaiming He, 2016) (eine Implementierung von U-Net) erfolgreich auf digitalen Geländemodellen (DGM) und Multispektralbildern eingesetzt.

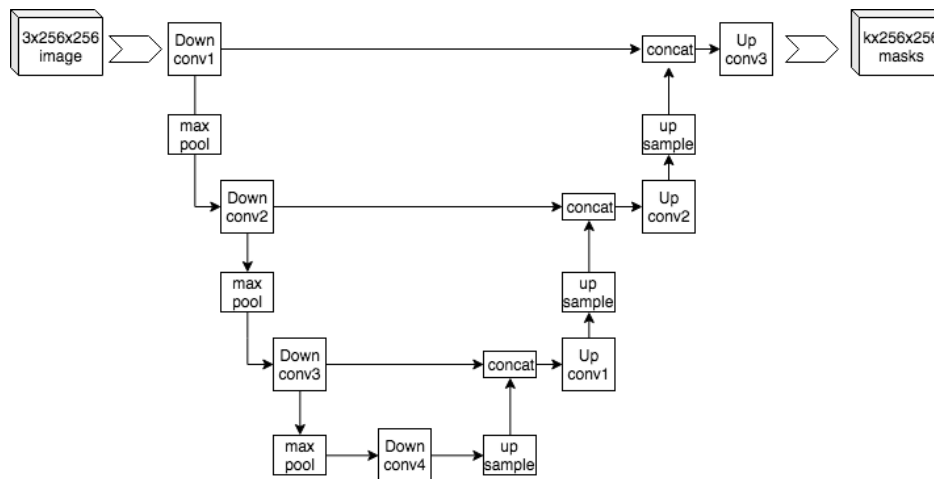


Abbildung 9 Schematische Übersicht eines U-Net Modells

Quelle: <https://en.wikipedia.org/wiki/U-Net>

Eine Open-Source-Anwendung unter MIT-Lizenz, die U-Net verwendet, ist das von Microsoft Research entwickelte Building Damage Assessment (BDA)-Framework<sup>1</sup>. Dabei handelt es sich um einen Deep-Learning-Ansatz zur automatisierten Erkennung und Klassifikation von Gebäudeschäden nach Naturkatastrophen auf Basis von Fernerkundungsdaten. Ziel des Frameworks ist es, Veränderungen zwischen einem Zustand vor und nach einem Ereignis zu erfassen. Als Trainingsdaten dienen Satellitenbilder unterschiedlicher Qualität mit manuellen Annotationen. Das Modell ist so konzipiert, dass es bereits mit etwa 10 % manuell klassifizierter Daten trainiert werden kann und auch auf begrenzten Rechenressourcen lauffähig ist.

Diese Eigenschaften machen den BDA-Ansatz besonders geeignet für die Detektion von Bodenbewegungen. Ein vortrainiertes Modell hat den Vorteil, bereits gewisse Kontextinformationen erlernt zu haben und kann dadurch auch mit kleinen Datenmengen weitertrainiert werden. Im Gegensatz zu rein attributbasierten Klassifikatoren, wie beispielsweise Random Forest, ist ein bildbasiertes Modell in der Lage, lokale Nachbarschaften sowie geometrische Zusammenhänge zu berücksichtigen. Zusätzlich können Attributinformationen als ergänzender Input in das Modell integriert werden. Aus diesen Gründen wurde das BDA-Modell als Grundlage für das Training verwendet.

Abbildung 10 zeigt eine schematische Übersicht des verwendeten Frameworks. Zunächst wurde das vortrainierte BDA-Modell ausschließlich mit der Differenzkarte trainiert. In einem zweiten Schritt wurden die extrahierten Polygonattribute als zusätzliche Eingangsgrößen in das Modell eingebunden.

<sup>1</sup> <https://github.com/microsoft/building-damage-assessment>

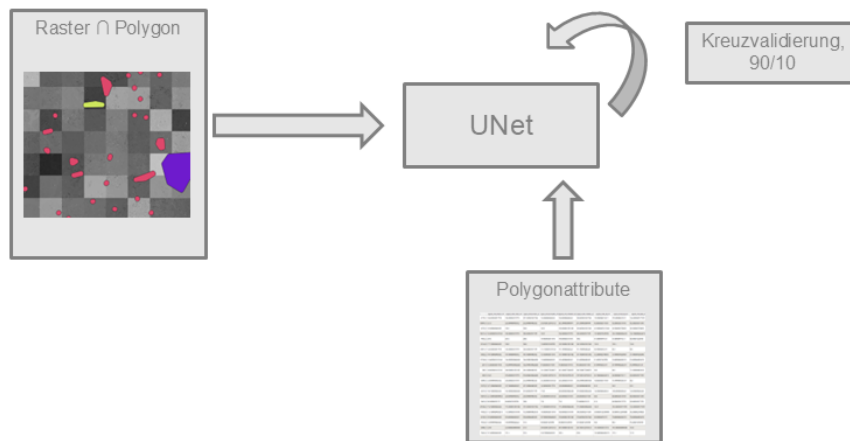


Abbildung 10 Schematische Übersicht des Frameworks

Zur Evaluation des Modells wurde eine 5-fache Kreuzvalidierung (Aufteilung 90/10) eingesetzt. Dabei wurde der Datensatz in fünf gleich große Teile aufgeteilt und in jedem Durchlauf 90 % der Daten als Trainingsdaten verwendet und die verbleibenden 10 % als Testdaten (vgl. Abbildung 11). Dieses Vorgehen ermöglicht eine maximale Ausnutzung der Trainingsdaten bei einer begrenzten Datenmenge.

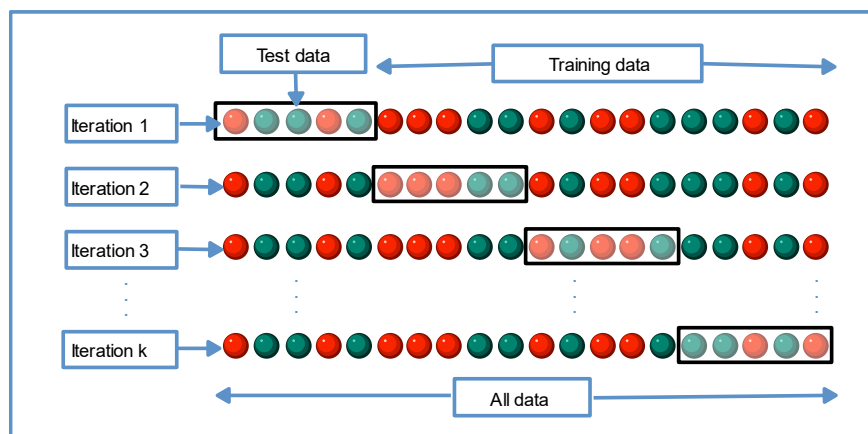


Abbildung 11 Schematische Übersicht der Kreuzvalidierung

Quelle: [https://en.wikipedia.org/wiki/Cross-validation\\_%28statistics%29](https://en.wikipedia.org/wiki/Cross-validation_%28statistics%29)

Die Evaluation der Ergebnisse hat, ähnlich wie beim Random Forest Modell, gezeigt, dass die Anzahl der Klassen zu hoch und die Anzahl der Trainingsbeispiele pro Klasse zu gering war, um eine stabile Modellanpassung zu ermöglichen (vgl. Abbildung 12). In den Ergebnissen ist ein ausgeprägtes Overfitting zu beobachten. Abbildung 12 zeigt deutlich, dass der Loss beim Training sinkt und die Accuracy steigt, jedoch auf den Testdaten ist genau das Gegenteil zu beobachten. Der Einsatz von Data Augmentation durch Spiegelung der Bilder führte lediglich zu geringen Verbesserungen, insbesondere bei Klassen mit nur 1–10 Trainingsbeispielen, was einfach zu wenig ist um überhaupt für Machine Learning verwendet zu werden.

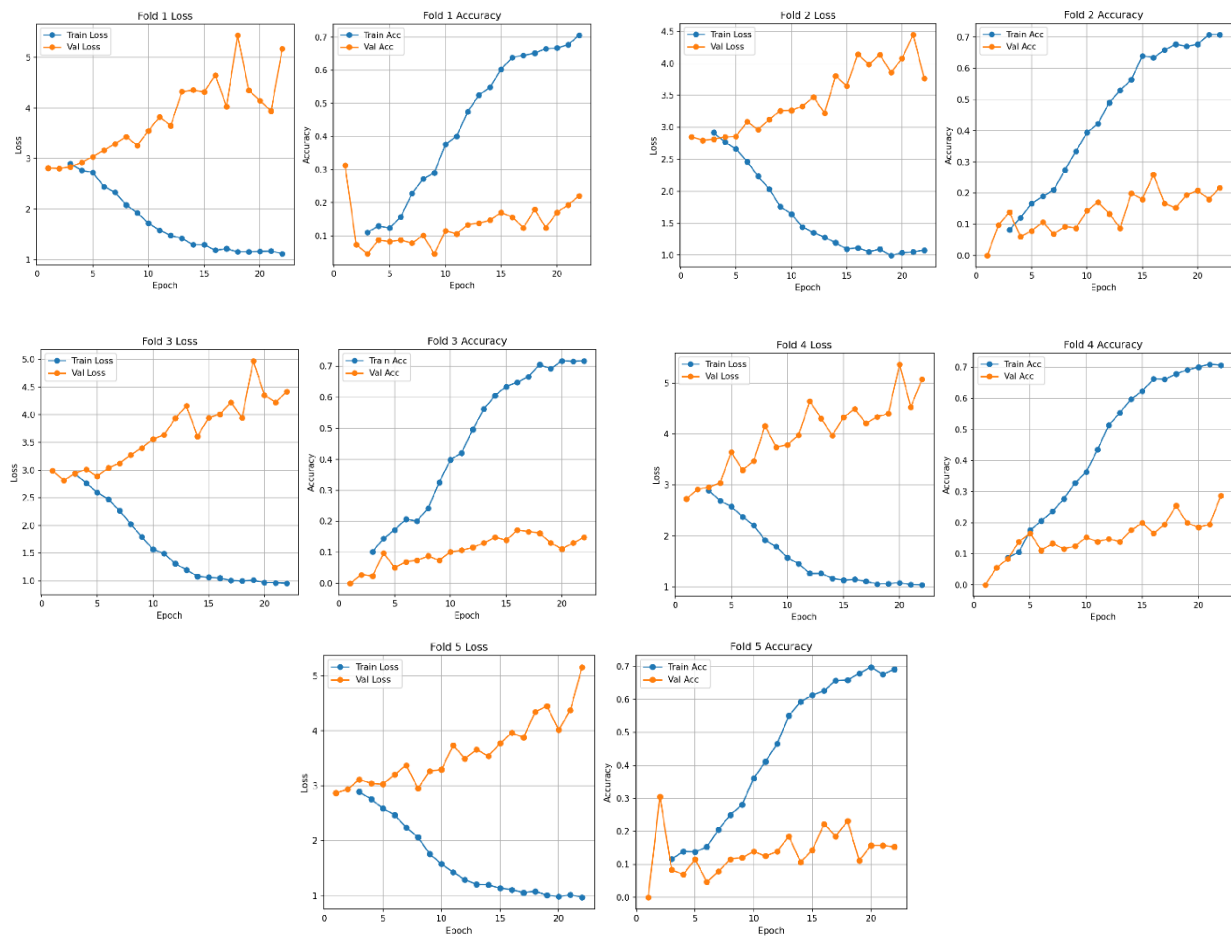


Abbildung 12 Ergebnisse der Kreuzvalidierung auf dem von Microsoft-BDA vortrainierten U-Net

Aus diesen Beobachtungen wurde geschlossen, dass eine Reduktion der Klassenanzahl sowie eine abstraktere Gruppierung der Klassen erforderlich ist. Als möglicher Lösungsansatz wurde die Verwendung eines kleineren Modells sowie eine schrittweise Klassifikation mit einer geringeren Anzahl an Klassen vorgeschlagen. Zusätzlich sollte der visuelle Input gezielt aufbereitet werden, um Unterschiede in den Merkmalen der Trainingsdaten für das Modell deutlicher hervorzuheben. Aus diesen Gründen wurde beschlossen den Ansatz so in der Form nicht weiterzuverfolgen, sondern auf das neuere Modell YOLO umzusteigen.

## YOLO

YOLO (You Only Look Once) (Joseph Redmon, 2016) ist ein von Ultralytics<sup>2</sup> entwickeltes Open-Source-Modell für Aufgaben der Objektdetektion und Bildsegmentierung im Bereich der Computer Vision. Die Architektur basiert auf tiefen Convolutional Neural Networks, verarbeitet jedoch im Gegensatz zu U-Net-Ansätzen das gesamte Bild in einem einzigen Vorwärtsschritt, anstatt es in Teilbereiche zu unterteilen.

Das Framework ermöglicht die Nutzung vortrainierter Modelle als auch das Training von Grund auf. Abhängig von den Anforderungen und der Größe des verfügbaren Datensatzes können verschiedene Modellgrößen (*Nano, Small, Medium, Large und Extra Large*) verwendet werden. Kleinere Modelle benötigen weniger Rechenressourcen, konvergieren schneller und eignen sich besonders für kleine Datensätze, da größere Modelle in diesem Fall nicht ausreichend mit Trainingsdaten versorgt werden würden. YOLO unterstützt sowohl die Objektdetektion, bei der Bounding Boxes vorhergesagt werden, als auch die Segmentierung, bei der Objektkonturen erzeugt

<sup>2</sup> <https://www.ultralytics.com/>

werden. Zum Zeitpunkt der Durchführung dieses Projekts war YOLOv11 die aktuellste verfügbare Version des Modells.

Da die beiden zuvor untersuchten Machine-Learning-Ansätze gezeigt haben, dass eine Erlernung der 19 Bodenbewegungs-Klassen auf Basis der vorhandenen Daten nicht möglich ist, wurde der Anwendungsfall für das YOLO-Modell auf die Klassifizierung von Rutschungen beschränkt. Die Trainingsdaten wurden entsprechend der Beschreibung in Kapitel 0 aufbereitet. Das Training erfolgte auf Basis des jüngsten DGMs von Hessen sowie der Rutschungsdatenbank vom HLNUG (mit 1640 Rutschungen).

ID	Model, #Epoch	#Daten	Augmentation	Recall $TP/(TP+FN)$	Precision $TP/(TP+FP)$
D12	detect, nano, 300* <i>*best result at 178</i>	1x	-	0.57	0.47
S10	segment, nano, 300	1x	-	0.65	0.49
D13	detect, nano, 500	2x	flips & rotation	0.79	0.69
S13	segment, nano, 300	2x	flips & rotation	0.74	0.70
S19	segment, nano 500	2x	flips & rotation	0.80	0.73
S111	segment, nano, 500	3x	flips & Rotation, zoom	0.87	0.82
S110	segment, small, 500* <i>*best result at 382</i>	3x	flips & rotation, zoom	0.87	0.82

Tabelle 1 Übersicht der Ergebnisse mit YOLOv11

Zur Datenerweiterung wurden zufällige Spiegelungen, Rotationen und Zoom-Operationen eingesetzt. Ohne die Einbindung der Schummerung konnten jedoch keine sinnvollen Ergebnisse erzielt werden, da Rutschungen im reinen DGM visuell nicht ausreichend erkennbar waren (vgl. Abbildung 19). Daher wurden verschiedene Schummerungseinstellungen getestet, jedoch zwischen den einzelnen Schummerungen war visuell kein großer Unterschied sichtbar. Die Standardeinstellung mit *Azimuth: 315, Höhe: 45, Z-Faktor: 1* erwies sich als am geeignetsten, da sie zudem mit dem Attribut *Sichtbarkeit* der Rutschungsdatenbank übereinstimmt, welches auf derselben Einstellung basiert.




Abbildung 13 Konfusionsmatrix: Train-, Validierung- und Test-Datensatz (von links nach rechts) für S111

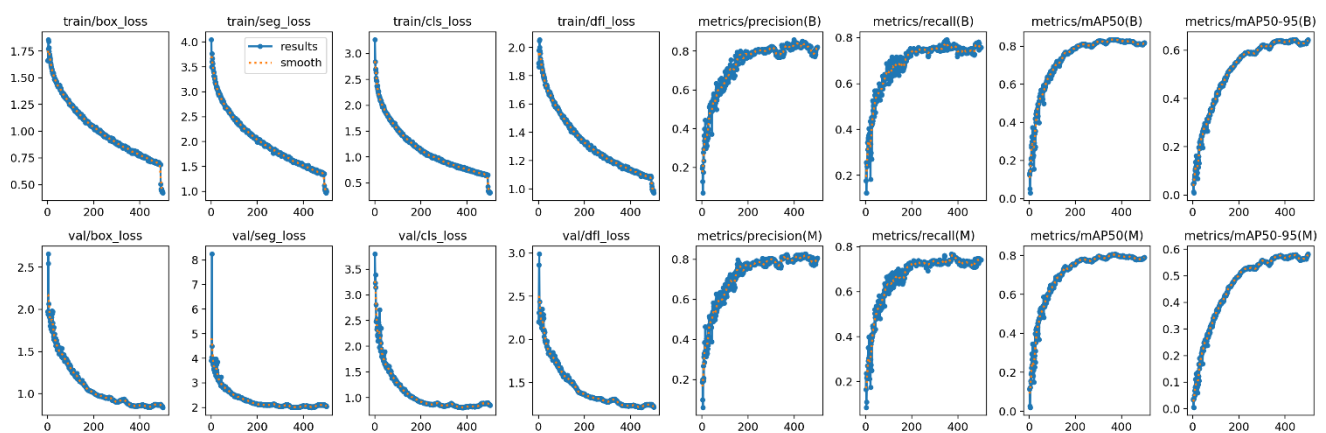


Abbildung 14 Metriken für S111

Eine Auswahl der Ergebnisse sind in Tabelle 1 zusammengefasst, sowie in Abbildung 15 und Abbildung 16 dargestellt. Die Ergebnisse zeigen deutlich, dass die künstliche Datenerweiterung einen positiven Einfluss auf die Ergebnisse hat, ohne dabei Overfitting zu erzeugen, da die Werte auf den Testdaten sich im Vergleich zu den Trainings- und Validierungsdaten nicht verschlechtern (vgl. Abbildung 13 und Abbildung 14). Basierend auf den quantitativen Ergebnissen wurde die Konfiguration S111 für die abschließende Inferenz und Evaluation ausgewählt.

### Inferenz:

Basierend auf den ausgewerteten Recall- und Precision-Werten wurde die Konfiguration S111 ausgewählt und für die Inferenz verwendet. Hierzu wurde das DGM von Hessen in Kacheln unterteilt, entsprechend der Kachelgröße der Trainingsdaten.

Das bereits trainierte Modell verarbeitet diese Kacheln iterativ und führt eine Segmentierung der erkannten Rutschungen durch. Die erkannten Rutschungen werden als Polygone gespeichert, die jeweils ein Attribut Confidence beinhalten, die die Unsicherheit des Modells angeben. Da das Modell selbst keine geographischen Koordinaten berücksichtigt, wurden im Anschluss den segmentierten Polygonen entsprechende Koordinaten zugewiesen. Das Ergebnis ist ein Shapefile, das die detektierten Objekte als georeferenzierte Polygone enthält.




Abbildung 15 Beispielergebnisse der Validierungsdaten auf KI\_3. Links: Ground-Truth, Rechts: Prediction

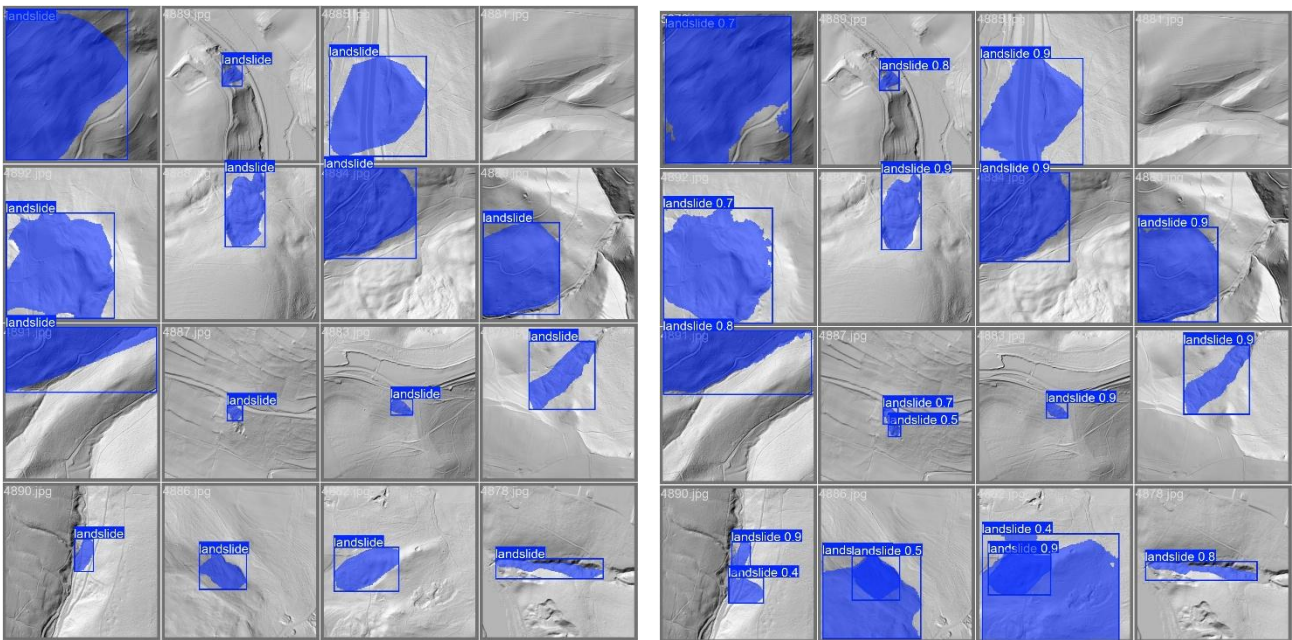


Abbildung 16 Beispielergebnisse des Testdatensatzes auf KI\_3. Links: Ground-Truth, Rechts: Prediction

---

## Evaluation

Die Machine-Learning-Modelle wurden auf den Testdatensätzen sowohl quantitativ als auch qualitativ bewertet. Dabei wurde untersucht, wie gut die Modelle die Zielklassen erkennen und wie zuverlässig ihre Vorhersagen sind.

### Quantitativ

Zur quantitativen Bewertung wurden die Metriken Recall und Precision verwendet:

$$\text{Recall} = \text{TP}/(\text{TP} + \text{FN})$$

$$\text{Precision} = \text{TP}/(\text{TP} + \text{FP})$$

wobei:

- TP = True Positives
- FN = False Negatives
- FP = False Positives

Eine weitere Metrik, die aus den YOLO-Ergebnissen berechnet wurde, ist die Confidence jeder Vorhersage. Auf dem Testdatensatz wird dafür die Ground-Truth Bounding Box oder Segmentierung als Referenz genutzt. Die *Confidence* der Testdaten wird berechnet als:

$$\text{Confidence}_{\text{Test}} = \text{Pr}(\text{Object}) \times \text{IoU}(\text{Prediction}, \text{Ground Truth})$$

- $\text{Pr}(\text{Object})$  ist die vom Modell vorhergesagte Wahrscheinlichkeit, dass sich überhaupt ein Objekt in der vorhergesagten Region befindet.
- IoU (Intersection over Union) misst, wie gut die vorhergesagte Bounding Box bzw. Segmentierung mit der Ground Truth übereinstimmt.

Bei der Inferenz stehen keine Ground-Truth-Daten zur Verfügung. Daher kann keine IoU berechnet werden. Die Confidence basiert hier ausschließlich auf der vom Netzwerk vorhergesagten Objektwahrscheinlichkeit:

$$\text{Confidence}_{\text{Inference}} = \sigma(z)$$

Dabei ist:

- $z$  der rohe Netzwerk-Output (Logit) für die Objektwahrscheinlichkeit
- $\sigma(\cdot)$  die Sigmoid-Funktion, die definiert ist als:

$$\sigma(z) = \frac{1}{1 + e^{-z}}$$

### Qualitativ

Zur qualitativen Bewertung der Ergebnisse wurden die Vorhersagen zunächst stichprobenartig visuell angeschaut. Dabei fiel insbesondere das Auftreten kachelförmiger Artefakte in den Polygonen auf (vgl. Abbildung 17). Diese entstehen dadurch, dass das Modell keine geographischen Koordinaten berücksichtigt. Wird eine größere Fläche in Kacheln zerlegt, kann es vorkommen, dass auch die Bildränder der einzelnen Kacheln als Objektbestandteile segmentiert werden, was zu den beobachteten Artefakten führt.

## B0 & KI\_3



Abbildung 17 Beispielausschnitt der Anomalien: B0 - Anomalien aus Differenzenkarte, KI\_3 - Anomalien aus Inferenz von YOLO-Modell (S111)

Um die Ergebnisse sinnvoll bewerten zu können wurden als nächstes mithilfe der im Projekt zuvor erstellten Differenzenkarte sowie den Rutschungsanfälligen Schichten, gefiltert. Weiterhin wurden die Polygone, die sich mit den im Training verwendeten Daten (also bereits bekannten Rutschungen) überschneiden, auch aus den Ergebnissen entfernt. Die Ergebnisse dieser Verschneidung ist in Tabelle 2 zusammengefasst. Nach Abschluss des Filterns wurden 198 Polygone als „unklassifiziert & interessant“ markiert. Diese wurden innerhalb des AP25-1 manuell überprüft und klassifiziert. Das Ergebnis wurde als GeoPackage (GPKG) bereitgestellt.

	▪ Polygonanzahl gesamt	▪ Klassifiziert	▪ Unklassifiziert	▪ Polygone in R0	▪ Unklassifiziert in R0
▪ B0	▪ 5728	▪ 407	▪ 5321	▪ 2915	▪ 274
▪ KI_2 (S19)	▪ 11406			▪ 5454	
▪ KI_3 (S111)	▪ 5646			▪ 3060	

▪ $\cap$	▪ B0	▪ B0 Klassifiziert	▪ B0 Unklassifiziert	▪ B0 in R0	▪ B0 Unklassifiziert in R0
▪ KI_2* (S19)	▪ 988	▪ 117	▪ 828	▪ 460	▪ 425
▪ KI_3* (S111)	▪ 497	▪ 79	▪ 418	▪ 227	▪ 198

Tabelle 2 **B0**: Differenzmodell; **R0**: Rutschungsanfällige Schichten; **TRAIN**: Rutschungen Trainingsdaten; **KI**: Mit Yolov11 generierte Daten (trainiert mit 2-facher bzw. 3-facher Datenmenge  
\*für alle Berechnungen wurde KI  $\cap$  TRAIN bereits eliminiert

### 4.1.3 AP 25-3 Erstellung von Trainingsdatensätzen

Zum Trainieren der in Arbeitspaket 2 verwendeten Modelle wurden drei entsprechende Trainingsdatensätze erstellt. Die dafür nötigen Verarbeitungsschritte werden in diesem Abschnitt erläutert.

#### Random Forest

Die Trainingsdaten des Random Forest Modells wurden aus den maschinenlesbaren Attributen der Differenzkarte erstellt. Alle Attribute die einheitliche Werte enthielten und keine manuellen Kommentare wurden mithilfe eines Python-Skripts in Feature-Vektoren konvertiert und normalisiert. Tabelle 3 zeigt eine Übersicht der verfügbaren maschinenlesbaren Attribute. Als Trainingslabels der zu klassifizierenden Klassen wurden die Einträge aus *Manual\_Class\_1* verwendet. Insgesamt gab es 563 Polygone die bereits eine manuelle Klassifizierung in 19 Klassen enthielten und 5165 ungelabelte Daten (siehe Abbildung 18).

Allgemeine Attribute	Attribute jeweils aus DGM 2014, 2019, 2021
area	aspect_hull_mean
buildings_area	aspect_hull_median
geology_area	aspect_hull_std
geology_percent	aspect_polygons_mean
hydro_area	aspect_polygons_median
hydro_percent	aspect_polygons_std
landslide_area	slope_hull_mean
landslide_percent	slope_hull_median
landuse_area	slope_hull_std
landuse_major	slope_polygons_mean
landuse_names + landuse_percent	slope_polygons_median
roads_main_area	slope_polygons_std
roads_minor_area	
shape_roundness	
subsidence_area	
subsidence_percent	
volumes_added	
volumes_moved	
volumes_removed	
volumes_total	
water area	

Tabelle 3 Maschinenlesbare Attribute der Differenzkarte

```
unlabeled: 5165
Baustelle: 171
Landwirtschaft: 136
Deponie: 56
Artefakt: 44
Rutschung: 34
Gewasser: 28
Freizeitanlage: 17
Erdfall: 16
Erosion: 15
Aufschüttung: 12
Steinbruch: 11
Industrie: 7
Hebung: 5
Verkehr: 5
Subsidenz: 2
Steinschlag: 2
Senkungsmulde: 1
Alllast: 1
```

Abbildung 18 Klassenverteilung der manuell klassifizierten Attribute in der Differenzkarte

### U-Net

Um den Trainingsdatensatz für das U-Net zu erstellen wurde das Raster der Differenzkarte mit den entsprechenden manuell klassifizierten Polygonen in Kacheln (1080x1080px) zugeschnitten und normalisiert. Die einzelnen Bilder wurden in Trainings, Validierung und Testdatensätze aufgeteilt (im Verhältnis 80/10/10). Im zweiten Schritt wurden die maschinenlesbaren Attribute (die bereits für Random Forest extrahiert worden waren) zu den Polygonen hinzugefügt.

### YOLO

Für die YOLO-Segmentierung wurden das jüngste DGM von Hessen (bis 2021) sowie eine Datenbank mit Rutschungen vom HLNUG verwendet. Diese enthält bereits bekannte Rutschungen, wovon 1468 als im DGM sichtbar gelabelt waren. Basierend auf der durchschnittlichen Größe der vorhandenen Rutschungen wurde eine Kachelgröße von 512x512 Pixel festgelegt. Aus dem DGM wurden entsprechende Kacheln, die eine Rutschung beinhalten, ausgeschnitten und normalisiert. Zusätzlich wurden zu jeder Kachel eine Bounding Box und eine Segmentierung von der Ground-Truth Rutschung gespeichert. Um negative Trainingsbeispiele zu erzeugen wurden Kacheln zufällig in Hessen ausgeschnitten.

Im weiteren Verlauf der Arbeit wurden die Daten künstlich erweitert, dabei kamen zufällige Spiegelung, Rotation und Zoom zum Einsatz. Außerdem wurde die Schummerung angepasst. Es wurde eine erhebliche qualitative und quantitative Verbesserung festgestellt als Schummerungsbasierte DGMs verwendet wurden, im Vergleich zu ohne (vgl. Abbildung 19). Zwischen verschiedenen Winkeln in der Schummerung konnte jedoch kein Unterschied festgestellt werden, weder visuell, noch im Modell-Ergebnis. Da das Attribut „Sichtbarkeit“ in der verwendeten Rutschungsdatenbank auf der Einstellung *Azimut: 315, Höhe: 45, Z-Faktor: 1* basiert, wurde diese letztendlich verwendet. Die Trainingsdaten sind beispielhaft in Abbildung 20 dargestellt.

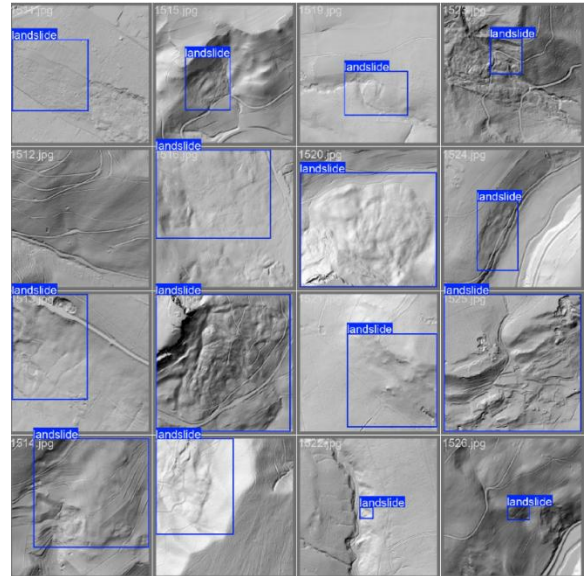



Abbildung 19 Vergleich der Trainingsdaten. Links: DGM Ohne Schummerung, Rechts: DGM mit Schummerung

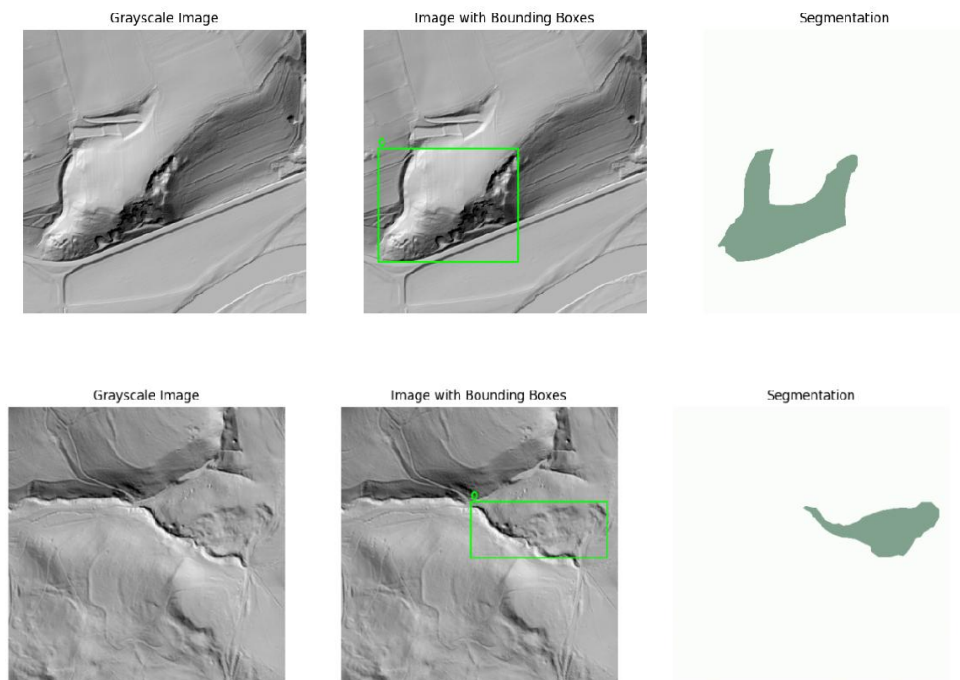


Abbildung 20 Beispiel Trainingsdaten aus dem DGM. Die Segmentierung entspricht der „Ground-Truth Rutschung“ aus der Rutschungsdatenbank

---

#### 4.1.4 AP 25-4 Anwendung SBAS-Verfahren zur Erweiterung des Bodenbewegungsdienstes

Das klassische SBAS-Verfahren (Small Baseline Subset) ist eine Methode, die in der Radarinterferometrie verwendet wird, um Bodenveränderungen mit hoher Präzision zu erfassen. Der Hauptvorteil des SBAS-Verfahrens liegt in der Nutzung von sogenannten „kleinen Baselines“. Das bedeutet, dass für die Analyse nur solche Bildpaare ausgewählt werden, die zeitlich und räumlich nahe beieinander liegen. Je größer die zeitlichen Abstände zwischen zwei Aufnahmen sind, je ungenauer und unzuverlässiger sind die Ergebnisse. Dadurch werden Fehler minimiert, die durch atmosphärische Störungen oder Veränderungen an der Erdoberfläche zwischen den Aufnahmen verursacht werden könnten. Dies führt zu genauen und zuverlässigen Ergebnissen (Li, 2022)

Zur Anwendung des SBAS-Verfahrens standen zum Zeitpunkt des Projektes zwei mögliche Softwares zur Verfügung: ENVI SARscape<sup>3</sup> und ASF Vertex<sup>4</sup> in Kombination mit MintPy<sup>5</sup>. Beide Ansätze bieten spezifische Vorteile und erlauben die detaillierte Analyse von Bodenbewegungen, wobei sie sich in ihrer Bedienung und Flexibilität unterscheiden. ENVI SARscape stellt umfassende Werkzeuge für die Verarbeitung und Analyse von SAR-Daten bereit. Die Integration von SBAS in SARscape ermöglicht eine weitgehend automatisierte Prozessierung, die besonders für Anwender mit begrenzter Erfahrung in der Radarinterferometrie geeignet ist. Der zweite Ansatz kombinierte ASF Vertex, eine cloudbasierte Plattform des Alaska Satellite Facility (ASF), mit MintPy (Miami INsar Time-series software in PYthon). ASF Vertex erlaubt die einfache Auswahl und automatische Verarbeitung von Sentinel-1-Daten zu Interferogrammen, die dann für die SBAS-Analyse verwendet werden können. Diese Plattform eignet sich besonders, da die Interferogrammerstellung On-Demand erfolgt und keine leistungsstarke lokale Recheninfrastruktur benötigt wird. Die generierten Interferogramme werden über eine Schnittstelle in das Open Science Lab von ASF übertragen, wo sie mit MintPy weiterverarbeitet werden können. MintPy ist eine spezialisierte Open-Source Software für die SBAS-Analyse.

In den vorausgegangenen Projektjahren wurden beide verfügbaren Software ausführlich ausprobiert (vergl. Endbericht 2024 Kap 3.2.4) und dabei festgestellt: „Die Berechnung von ca. 30 Sentinel-1-Bildern konnte bis zu eine Woche in Anspruch nehmen. Dies begrenzte die Analyse auf relativ kurze Zeitreihen und erschwerte die Untersuchung von Langzeittrends.“ Hingegen „... mit ASF Vertex und MintPy Zeitserien über mehrere Jahre innerhalb eines Tages berechnet werden“. Da eine hohe zeitliche Auflösung essenziell für das SBAS-Verfahren ist und es nicht möglich ist z.B. stichprobenhaft Aufnahmen auszuwählen und zu verarbeiten, beschränkt sich die sinnvolle Auswahl der Tools für dieses Arbeitspaket auf ASF Vertex in Kombination mit MintPy. Jedoch hat zum Zeitpunkt des Projektes die Software das Problem aus politischen Gründen nicht mehr öffentlich zugänglich zu sein (Abbildung 21) und das Arbeitspaket konnte in dem geplanten Umfang nicht bearbeitet werden.

---

<sup>3</sup> <https://www.nv5geospatialsoftware.com/Solutions/SAR-Solutions>

<sup>4</sup> <https://search.asf.alaska.edu/#/>

<sup>5</sup> <https://github.com/insarlab/MintPy>



NASA JupyterHub operated by the Alaska Satellite Facility

Users not affiliated with NASA should apply for access here: [OpenSARLab Access Application](#)

User storage is permanently deleted after 30 days of inactivity. Users can request a temporary extension by contacting the OSL Admins.

---

By accessing and using this information system, you acknowledge and consent to the following:

You are accessing a U.S. Government information system, which includes: (1) this computer; (2) this computer network; (3) all computers connected to this network including end user systems; (4) all devices and storage media attached to this network or to any computer on this network; and (5) cloud and remote information services.

**This information system is provided for U.S. Government-authorized use only.** You have no reasonable expectation of privacy regarding any communication transmitted through or data stored on this information system. At any time, and for any lawful purpose, the U.S. Government may monitor, intercept, search, and seize any communication or data transiting, stored on, or traveling to or from this information system. You are NOT authorized to process classified information on this information system. Unauthorized or improper use of this system may result in suspension or loss of access privileges, disciplinary action, and civil and/or criminal penalties.

Abbildung 19 Zugriffsproblematik der im Arbeitspaket 25-4 vorgesehenen Software

#### 4.1.5 AP 25-5 Anwendungsausweitung und Visualisierung

In Arbeitspaket 5 sollte evaluiert werden, ob die Datensätze für andere Anwendungen verwendet werden können bzw. ob weitere Daten in das Projekt integriert werden können, so z.B. die Erhebung von in-situ Messdaten zu Bodenbewegungen/ Erschütterungen. Als potentielle erweiterte Anwendungen sind Bereiche, die durch menschliche Aktivitäten geprägt sind (Steinbrüche, Halden und Deponien), denkbar. Bisher wurden diese Gebiete nicht vorrangig bearbeitet, da die menschliche Aktivität mögliche natürliche Prozesse überlagert. Zusätzlich sollen, neben der Darstellung in Viewern, weitere Formen der Visualisierung der Datensätze geprüft werden (3D-Ansichten, GST-Viewer, Augmented Reality, etc.). Diese Arbeiten werden durch das HLNUG durchgeführt.

Zur Einrichtung einer in-situ Messstation wurden entsprechende Messgeräte (Messensor und Datenlogger) angeschafft. Aufgrund der späten Mittelverfügbarkeit und entsprechender Lieferzeiten, konnten die Messgeräte gekauft, jedoch noch nicht im Gelände installiert werden. Dies wird für 2026 angepeilt.

Als potentielle weitere Anwendungen wurde die Bestimmung von Abbau- und Einlagerungsmengen von Steinbrüchen, Halden und Deponien, sowie Daten zur Überwachung von Setzungen von Deponien identifiziert, die mit der Differenzkarte des DGM darstell- und berechenbar sind (Abbildung 2122). Hiermit können Abbau- und Einlagerungsmengen zwischen den verschiedenen Befliegungszeiträumen (in der Regel alle 6 Jahre) berechnet werden anhand der Auswertung der DGM-Differenzen. Zur Überwachung von Setzungen oder Hebungen im Bereich von Altdeponien können auch die InSAR-Bodenbewegungsdaten herangezogen werden, vor allem in den Fällen, in denen sich eine spätere Bebauung (z.B. Solarparks) im Bereich der Altdeponiefläche befindet.

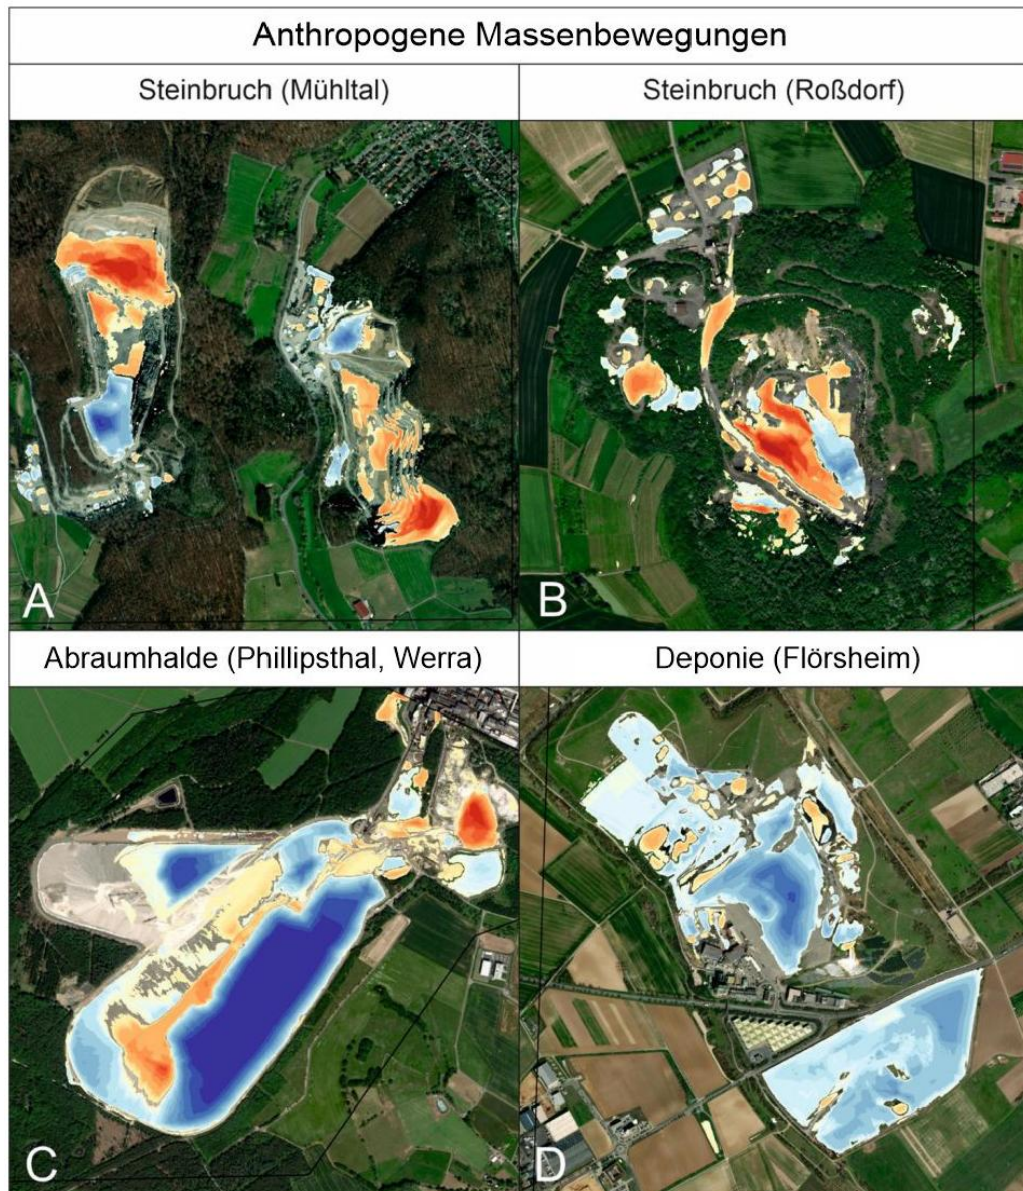


Abbildung 20 Anthropogene Massenbewegungen, die auf den Differenzplänen im Bereich von z. B. (A) und (B) Steinbrüchen (Mühlital und Roßdorf) (C) Halden (Phillipsthal) und (D) Deponien (Flörsheim) sichtbar werden. Blau ist Auffüllung, Rot ist Absenkung.

Weitere Formen der Visualisierung der Datensätze sind möglich und sollen in 2026 weiterverfolgt werden (3D-Ansichten, GST-Viewer). Die Einbindung neu klassifizierter Rutschungen in die Datenbankstruktur des HLNUG zu Geogefahren ist geplant.

Bei der Fortschreitung der öffentlichen Bereitstellung der bisherigen Projektergebnisse sind leider technische Probleme mit einigen der neuartigen Datensätzen aufgetreten, die eine intensive Nachforschung in der zentralen Viewer-Technologie des HLNUG erforderlich macht. Des Weiteren sind die restlichen Datensätze aufgrund von technischen Umstellungen auf eine neue Viewer-Version ebenfalls noch nicht veröffentlicht. Die Veröffentlichung soll im Laufe des Jahres 2026 erfolgen, eine Anbindung an den GST-3D-Viewer des HLNUG wird angestrebt.

---

#### 4.1.6 AP 25-6 Berichterstellung, Datenabgabe und Datenintegration zur Veröffentlichung

Der vorliegende Bericht wurde in Abstimmung mit allen Beteiligten erstellt. Die abgegebenen Daten umfassen die Trainingsdaten sowie die manuell- und KI-klassifizierte Polygone. Der Code sowie das final trainierte KI-Modell wird über GIT zur Verfügung gestellt ([https://git-ce.rwth-aachen.de/fg-fub/u4py\\_machine\\_learning](https://git-ce.rwth-aachen.de/fg-fub/u4py_machine_learning)).

Die finalen Polygone aus der KI als GPKG in zwei Dateien vor:

- K13\_intersect\_BO.gpkg (5000 Polygone) beinhaltet alle von der KI identifizierten Polygone in Hessen (ungefiltert).
- K13\_intersect\_BO\_unclassified.gpkg (200 Polygone) ist einfach eine Submenge davon und beinhaltet nur die Polygone die für eine manuelle Klassifikation am interessantesten wären.

---

## 5 Ausblick

Im Anschluss an das Projekt ist eine Veröffentlichung der Methodik zusammen mit den Ergebnissen als Konferenzpaper geplant. Weiterhin wird Saghir et al. bei der DGPF Jahrestagung 2026 ein Poster präsentieren, welches die Aufbereitung der Trainingsdaten (AP 25-3) für das Machine Learning eingehend erklärt. Auch in Zukunft wird an der TU Darmstadt am Fachgebiet für Fernerkundung und Bildanalyse das Thema Bodenbewegung relevant bleiben. Im Anschluss an das Projekt wird eine Masterarbeit zum Thema *Erdfall-detektion in Hessen mit Machine Learning* ausgeschrieben. Dafür dient die im Rahmen dieses Projekts erarbeitete Methodik als Grundlage und soll speziell für die Erdfalldetektion in Karstgefährdeten Gebieten erweitert werden.

---

## 6 Literaturverzeichnis

---

Breiman, L. (2001). Random Forests. *Machine Learning* 45, 5-32.

doi:<https://doi.org/10.1023/A:1010933404324>

Joseph Redmon, S. D. (2016). You Only Look Once: Unified, Real-Time Object Detection. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, S. 779-788.

Kaiming He, X. Z. (2016). Deep Residual Learning for Image Recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, S. 770-778.

Li, S. W. (2022). Review of the SBAS InSAR Time-series algorithms. *Geodesy and Geodynamics*, S. 114–126.

Ronneberger, O. F. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*. doi:[https://doi.org/10.1007/978-3-319-24574-4\\_28](https://doi.org/10.1007/978-3-319-24574-4_28)

---

---