Die permanente dreidimensionale Datenerfassung alpiner Hangrutschungen – multitemporale Datenanalyse in webbasierten Anwendungen¹

The Permanent Three-dimensional Data Acquisition of Alpine Landslides — Multitemporal Data Analysis in Web-based Applications

Daniel Czerwonka-Schröder, Katharina Anders, Lukas Winiwarter

Dieser Beitrag stellt einen webbasierten Monitoringdienst auf Basis eines permanent installierten Long-Range-Laserscanners (PLS) zur Identifizierung von Hangbewegungen vor, der im Zusammenhang mit der Abwehr von Naturgefahren und dem Schutz von Infrastrukturen eingesetzt wird. Grundlage dieser Arbeit ist ein Datensatz aus dem Valsertal in Tirol, wo 2021 ein fest installierter Laserscanner im Bereich eines Felssturzes "online" betrieben wurde. Der Fokus der Forschungsarbeiten liegt auf der Integration eines PLS in ein Risikomanagementsystem aus ingenieurgeodätischer Sicht. Vier wesentliche Prozessierungsschritte sind im Rahmen eines solchen Monitorings mit PLS durchzuführen: (1) Die Datenerfassung einer einzelnen Epoche, (2) die Bereitstellung eines redundanten Datenmanagements sowie einer sicheren Datenkommunikation zu zentralen Servern, (3) die multitemporale Datenanalyse und (4) die Aufbereitung, das Reporting und die Präsentation der Ergebnisse für Stakeholder. Dieser Beitrag fokussiert sich auf die letzteren beiden Aspekte und stellt eine zweistufige Methode vor, mit der automatisiert Informationen aus dem umfangreichen Datensatz abgeleitet werden können. Aus der vollumfänglichen 3D-Zeitserie der Szene werden zunächst relevante Merkmale auf Basis von 2D-Rasterbildern durch Clustering extrahiert. Die so gewonnene Information wird in einem zweiten Schritt genutzt, um die Szene räumlich einzuschränken und in den Interessensbereichen eine raumzeitliche Segmentierung mithilfe von 4D-Änderungsobjekten zu realisieren.

Schlüsselwörter: Permanentes Laserscanning, multitemporale Datenanalyse, geomorphologische Datenanalyse, Clustering, Geomonitoring

This contribution presents a web-based monitoring service on the basis of a permanently installed Long Range Laser Scanner (PLS) to identify slope movements, implemented in the context of natural hazard prevention and infrastructure protection. This work is driven from a dataset collected in the Vals Valley in Tyrol, Austria, where a permanently installed laser scanner was operated "online" in the area of a rockfall in 2021. Focus of the research is the integration of a PLS into a risk management framework from an engineering geodetic point of view. Four fundamental processing steps have to be performed in the context

¹ Überarbeitete und erweiterte Fassung des Beitrags der 22. Internationalen Geodätischen Woche Obergurgl 2023 (Tagungsband "22. Internationale Geodätische Woche Obergurgl 2023", Hrsg.: Th. Weinold, Wichmann Verlag)

of a monitoring with PLS: (1) the data acquisition of a single epoch, (2) the deployment of a redundant data management as well as a secure data communication to central servers, (3) the multitemporal data analysis, and (4) the preparation, reporting and presentation of the results to stakeholders. This article is focused on the last two aspects and presents a two-step methodology to automatically derive information from the extensive dataset. First, relevant features are extracted from the full 3D time series of the scene based on 2D raster images by clustering. The resulting information is used in a second step to spatially limit the scene and to implement spatiotemporal segmentation in the regions of interest using 4D Objects-By-Change (4D-OBC).

Keywords: Permanent laser scanning, multi-temporal data analysis, geomorphological data analysis, clustering, geomonitoring

1 EINLEITUNG UND MOTIVATION

Hangrutschungen, Böschungsabbrüche und Felsstürze treten in weiten Teilen der Welt auf und verursachen Schäden in Milliardenhöhe an Gebäuden, Infrastruktur und der Umwelt /Niemeier & Riedel 2017/. Beispielsweise führen das Tauen des Permafrosts in hochalpinen Gebieten und das Zusammenwirken von Wetterextremen als Folge des Klimawandels zu vermehrten gravitativen Massenbewegungen in alpinen Regionen /Dinkel et al. 2020/. Das Risikomanagement, die Prävention von Naturgefahren und der Schutz der Bevölkerung sind essenziell, um mit diesen Gefahren sicher umgehen zu können, und erfordern qualitativ aufbereitete drei- und vierdimensionale (3D- und 4D-)Datensätze der Erdoberfläche /Bremer et al. 2019/.

In den vergangenen Jahren hat ein Paradigmenwechsel stattgefunden, der durch (1) einen Übergang von punktuellen, epochenweisen Messungen zu flächenhaften, kontinuierlichen Datenaufnahmeverfahren und (2) die Entwicklung komplexer Online-Systeme anstelle von zeitintensiven Offline-Analysen gekennzeichnet ist /Niemeier & Riedel 2017/. Die technischen Fortschritte beim terrestrischen Laserscanning (TLS) tragen zu diesem Trend bei und ermöglichen die Erfassung von räumlich und zeitlich dichten Punktwolken. Gerade permanentes TLS (PLS) erweitert den klassischen Anwendungsbereich von TLS in der Ingenieurgeodäsie /Wujanz 2016/. Ihre kompakte und robuste Bauweise in Verbindung mit offenen Dateiformaten und ihrer Programmierfähigkeit machen PLS-Systeme wirtschaftlich attraktiv und für eine webbasierte Überwachung einsetzbar.

PLS ermöglicht eine hochfrequente Datenerfassung über vergleichsweise lange Zeiträume. Dies birgt auch die Herausforderung, tausende Punktwolken der einzelnen Messepochen analysieren zu müssen. Bitemporale Methoden sind hier nur eingeschränkt anwendbar, da nicht bekannt ist, wann und wo Veränderungen auftreten, welche Art von Veränderungen auftreten, Unterschiede von einer Epoche zur nächsten nicht immer beobachtbar sind und Veränderungen mit räumlicher Überlappung auftreten. Neue Methoden verwenden daher die vollständige Zeitserieninformation der 4D-Datensätze zur Detektion und Extraktion von Oberflächenaktivitäten sowie zur Charakterisierung von Änderungen. Das Potenzial solcher Ansätze wurde durch die raumzeitliche Segmentierung von /Anders et al. 2021/, den Clusteransatz nach Veränderungsmustern mittels k-Means von /Kuschnerus et al. 2021/ oder die 4D-Kalman-

Filterung von /Winiwarter et al. 2023/ gezeigt. Bisher sind diese Algorithmen jedoch nicht für die Anwendung im Rahmen eines echtzeitnahen Assistenzsystems optimiert. Die Berechnungen basieren auf der gesamten Punktwolke und haben eine höhere Latenz zwischen der Datenerfassung und der Bereitstellung von Informationen. Im vorliegenden Beitrag wird daher ein konzeptioneller Workflow vorgeschlagen, der mehrstufig angelegt ist und die genannten Verfahren in einem semiautomatisierten Prozess anwendet. Zunächst wird eine räumliche Segmentierung der Zeitreihen auf der Grundlage von 2D-Rasterdaten mittels unüberwachtem maschinellen Lernen durchgeführt. Analog zu /Kuschnerus et al. 2021/ wird die Szene mit k-Means-Clustering in homogene Segmente unterteilt, die eine räumliche Beschränkung der für die Änderungsanalyse relevanten Bereiche zulassen. Der räumliche Ausschnitt wird dadurch vorausgewählt und kann im zweiten Prozessierungsschritt genutzt werden, um die volle Zeitreihe der 3D-Punktwolken zu analysieren. Hierbei kommt die Methode der raumzeitlichen Segmentierung von 4D-Änderungsobjekten zur Anwendung. Dieser Workflow ermöglicht die Extraktion raumzeitlich detaillierter Informationen innerhalb eines webbasierten Echtzeit-Assistenzsystems.

2 UNTERSUCHUNGSGEBIET UND DATEN

Am 24.12.2017 hat sich im Valsertal/Tirol in Österreich (ca. 30 km südlich von Innsbruck) ein Felssturz ereignet. Nach /Berger et al. 2021/ lösten sich dabei etwa 117000 m³ Gesteinsvolumen mit einer maximalen Anbruchtiefe von 25 m und einer maximalen Anbruchhöhe von 150 m. Auf Basis zweier Laserscans, die 2008 und am 27.12.2017 direkt nach dem Ereignis stattgefunden haben, geben /Anegg & Fritzmann 2019/ die Kubatur der Ablagerung mit 130 000 m³, die Ablagerungsfläche mit 50 000 m², eine Fallhöhe von 380 m und eine maximale Ablagerungshöhe von 9 m an. Durch das Ereignis wurde das Material aufgelockert, was einer Volumenzunahme von ca. 11,5 % entspricht. Obwohl es weder menschliche Opfer noch nennenswerte Schäden an Gebäuden gab, wurde die unmittelbar unterhalb des Felssturzes gelegene Valser Landstraße mit 8 m Schutt und Geröll verschüttet /Hartl 2019/. Die Veränderung des Geländes machte eine Neubeurteilung der Lawinen- und Steinschlaggefahr erforderlich. Resultierend aus dieser Beurteilung wurden

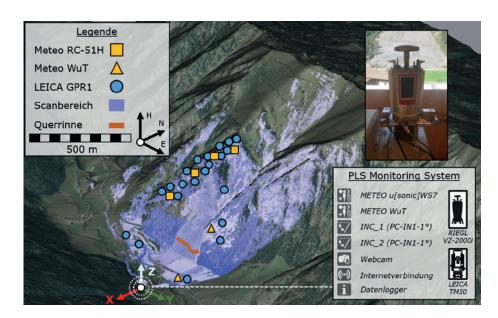


Abb. 1 I Dreidimensionale
Darstellung des Testgebiets am
Felssturz im Valsertal mit integrierter
Sensortechnik, deren räumliche Lage
zueinander sowie Darstellung der
hergestellten Querrinne. DGM und
Orthofotos: Land Tirol –data.tirol.gv.at
/Czerwonka-Schröder 2023/.

mehrere Barrieren und eine Querrinne als Schutz errichtet. Neben umfassenden dreidimensionalen Kartierungen der neuen Situation wurde am 28.01.2018 durch die Tiroler Landesregierung ein geodätisches Monitoring errichtet, bestehend aus einer Totalstation (Modell: Leica TM30) und 21 Prismen (Modell: Leica GPR1). Die Totalstation wurde auf einem Messpfeiler in einer Schutzhütte etwa 800 m südlich am gegenüberliegenden Hang des Felssturzbereichs installiert und die Prismen oberhalb des Felssturzes, in der Talsohle und in anderen Bereichen des Hangs verteilt (*Abb. 1*). Im Juni 2021 wurden die Überwachungssysteme der Landesregierung Tirol abgebaut, da keine potenzielle Gefahr mehr im überwachten Gebiet nachgewiesen werden konnte.

Die Infrastruktur des bestehenden Überwachungssystems wurde 2020 für diese Arbeit zur Verfügung gestellt. Daher konnten in drei Messkampagnen permanente Installationen eines Laserscanners über einen Zeitraum von jeweils mehreren Wochen realisiert werden:

- Messkampagne 1 (M1): 13.08.2020 bis 08.09.2020,
- Messkampagne 2 (M2): 10.05.2021 bis 17.06.2021,
- Messkampagne 3 (M3): 28.07. 2021 bis 17.12.2021.

Während der Kampagnen M1 und M2 standen die Daten der Totalstation ebenfalls zur Verfügung. Im Messzeitraum konnte belegt werden, dass die Prismen keine Bewegung aufweisen. Auf Basis einer stabilen Vergleichsgeometrie in Form der Prismen und der simultanen Vermessung mittels Totalstation ist es möglich, verschiedene ingenieurgeodätische Fragestellungen unter realistischen Umweltbedingungen zu bearbeiten /Czerwonka-Schröder 2023/. Resultierend wird an dieser Stelle ein Open-Air-Labor für die Forschungs- und Weiterentwicklung von PLS vorgestellt.

Die Installationen des Laserscanners (Riegl VZ-2000i) erfolgten auf einem zweiten Messpfeiler direkt neben der Totalstation in der Schutzhütte, sodass zum einen eine ständige Stromversorgung gewährleistet war und zum anderen das Messsystem zusätzlich von Wettereinflüssen geschützt wurde. Die Datenerfassung wurde für die verschiedenen Forschungs- und Entwicklungsaktivitäten im Hinblick auf den Einsatz von PLS mit großen Messreichweiten

innerhalb eines ferngesteuerten, webbasierten Monitoringsystems aus ingenieurgeodätischer Sicht konzipiert. Während der Messkampagnen M2 und M3 wurde – im Gegensatz zur Kampagne M1 – ein anderer Laserscanner eingesetzt, welcher allerdings vom gleichen Hersteller. Typ und Modell war. Auf mögliche Differenzen in den Messdaten, die aus dem Einsatz unterschiedlicher Laserscanner zustande kommen könnten, wird in dieser Arbeit nicht eingegangen. Neben dem Laserscanner und der Totalstation wurden zwei Neigungssensoren am Vermessungspfeiler (PC-IN1-1°), an dem der Laserscanner befestigt war, installiert. Dadurch können Fragestellungen hinsichtlich der Stabilität der Installation an sich beantwortet werden. Zusätzlich wurden sieben meteorologische Sensoren an der Schutzhütte selbst und im Überwachungsgebiet eingerichtet. Aus der Notwendigkeit einer ständigen Stromversorgung wurden die präziseren meteorologischen Sensoren von W&T nur an der Schutzhütte, in der Talsohle und im unteren Bereich des Felssturzgebietes installiert. Die Temperaturlogger von ELITECH, die keine zusätzliche Stromversorgung benötigen, wurden oberhalb des Felssturzareals befestigt. Die ergänzenden Messdaten können dazu verwendet werden, diurnale und saisonale systematische Effekte auf die Messwerte des Laserscanners zu verifizieren /Schröder & Nowacki 2021/. Während in Kampagne M1 zusätzlich externe meteorologische Messwerte von der Zentralanstalt für Meteorologie und Geodynamik ZAMG) genutzt wurden, kam in der Kampagne M2 und M3 eine weitere Wetterstation (LAMBRECHT U[SONIC]WS7) an der Schutzhütte zum Einsatz.

Für die hier vorgestellte Methode wurde ein zeitlicher Ausschnitt vom 2. August bis zum 22. September 2021 aus dem Datensatz ausgewählt. In diesem Zeitraum sind drei Erosionsrinnen als natürliche Prozesse (8. August 2021 aufgrund eines Gewitters) und Baustellenaktivität als anthropogene Ereignisse (20. – 22. September 2021) aufgetreten, die es mittels der vorgestellten Methodik zu detektieren gilt. Während dieses Zeitraums wurde alle drei Stunden ein hochauflösender Scan des Gebiets mit einer Auflösung von 15 mdeg in Azimut und Elevation bei einer Laser-Repetitionsrate von 50 kHz erfasst, was zu einer Zeitserie von 318 Einzelscans

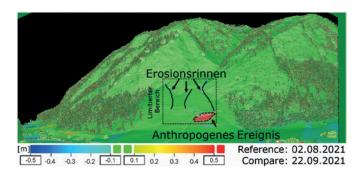


Abb. 2 | Bitemporaler Vergleich der Szene zwischen dem 2. August 2021 und dem 22. September 2021 mit Darstellung von drei Erosionsrinnen und einem anthropogenen Ereignis /Czerwonka-Schröder 2023/

führte. *Abb. 2* zeigt einen bitemporalen Vergleich der gesamten Zeitspanne. In der Abbildung wurden Änderungen von über 10 cm Magnitude hervorgehoben. Eine manuelle Überprüfung der einzelnen Scans ermöglicht die zeitliche Verortung der Vorgänge. Diese Wissensbasis dient als Referenz für die weiteren Untersuchungen hinsichtlich der Informationsextraktion innerhalb des nachfolgend vorgestellten Systems.

3 METHODEN

3.1.1 Zeitreihen-Clustering mittels k-Means-Algorithmen

Clustering ist als häufigste Anwendungsform des unüberwachten (maschinellen) Lernens anzusehen und zeichnet sich dadurch aus, dass es ohne ein Vorwissen von bekannten Ausgabedaten zur Detektion von Mustern in den Eingabedaten genutzt werden kann /Matzka 2021/, mit der u.a. Zeitreihen nach ihrer Ähnlichkeit in den Veränderungsmustern gruppiert werden können. In /Kuschnerus et al. 2021/ wurde ein k-Means-Clustering erfolgreich auf PLS-Daten angewendet. Dieses Vorgehen wird auf den hier vorliegenden Datensatz adaptiert. Die Vorgehensweise ist in *Abb. 3* grafisch dargestellt und lässt sich wie folgt zusammenfassen: (1) Extraktion der

Zeitreihen aus den TLS-Punktwolken, (2) globale Filterung der Zeitreihen, (3) Ableitung von Merkmalen aus den Zeitreihen, (4) Auswahl einer geeigneten Zahl an Clustern, (5) Segmentierung der Zeitreihen und (6) Identifizierung und Zuordnung von Oberflächenprozessen.

3.1.2 Extraktion von Zeitreihen aus den Punktwolken

Die Daten werden vor der Extraktion der Zeitreihen aus den Punktwolken in einem komprimierten, unmittelbar am Laserscanner erzeugten Rasterdatenformat gespeichert /Czerwonka-Schröder & Gaisecker 2022/. Dazu werden jeweils fünf horizontale und vertikale Winkelschritte zu einer Rasterzelle (Pixel) zusammengefasst. Bei einer Auflösung von 0.015° entspricht dies einem Öffnungswinkel von 0.075° . Diese Strategie ermöglicht es, die große Menge an Informationen, die in den 3D-Punktwolken enthalten sind, in einer komprimierten Struktur darzustellen /Vosselman & Maas 2010/. In einem zweiten Schritt werden alle Punkte innerhalb einer Rasterzelle mittels der Methode der kleinsten Quadrate an eine Ebene angepasst, um die Entfernung und Ausrichtung jeder Zelle zu erhalten. Die Entfernung wird am Laserscanner in eine farbige (RGB-)Darstellung umgewandelt und dann als Bild abgespeichert. Unter Verwendung von Gl. (1) kann der Abstandswert $I_{\text{pix}(i,i),t_0}$ in Metern

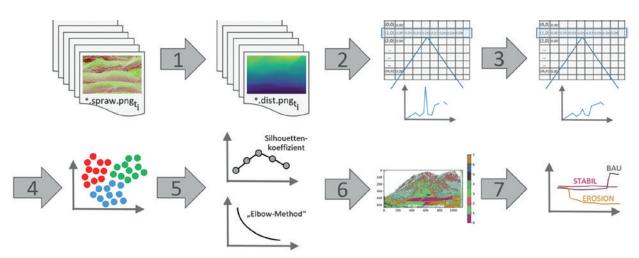


Abb. 3 I Übersicht des Workflows: (1) Streckenberechnung pro Pixel auf Basis der RGB-Werte, (2) Berechnung einer Zeitreihe pro Pixel, (3) globale Filterung von Differenzen größer als 1 m und Interpolation von Datenlücken, (4) Berechnung von verschiedenen Segmentierungen, (5) Modellauswahl, (6) Visualisierung des Clustering und (7) Zuordnung zu relevanten Oberflächenprozessen

vom Ursprung des Scanners für jedes Pixel aus den RGB-Werten rückgerechnet werden:

$$r_{\text{pix}(i,j),t_n} = (Rot + 256 \cdot Gr\ddot{u}n + 256^2 \cdot Blau) \cdot 0,001.$$
 (1)

Wir bezeichnen n als die ausgewählte Epoche. Die Streckenänderung Δr_n über die Zeit wird in Bezug auf die erste Messung bei t_0 wie folgt berechnet und stellt das wesentliche Merkmal für den folgenden Segmentierungsalgorithmus dar:

$$\Delta r_n = \left(r_{\mathsf{pix}(i,j),t_0} - r_{\mathsf{pix}(i,j),t_n}\right) \cdot \frac{1}{2} \left(\frac{s_{\mathsf{pix}(i,j),t_0}}{255} + \frac{s_{\mathsf{pix}(i,j),t_n}}{255}\right); \tag{2}$$

$$\mathsf{mit} \ s = -b \cdot \mathsf{v}.$$

wobei b der Richtungsvektor vom Bezugspunkt der Ebene zum Ursprung des Scanner-Koordinatensystems und ν der für jeden Pixel bestimmte Ebenennormalvektor ist. Die in Gl. (2) ausgedrückte Differenz ist auf einen annähernd mittleren lokalen Normalenvektor zwischen der Referenzepoche und der zu vergleichenden Epoche bezogen. Anschießend werden Streckenänderungen, die größer als 1 m sind, aus den Zeitreihen als Ausreißer entfernt und Datenlücken interpoliert.

3.1.3 Segmentierung der Zeitreihen

Der k-Means-Algorithmus basiert auf der Minimierung der Summe der Distanzen zwischen den Datenpunkten und den jeweiligen Schwerpunkten ("Means"). Als zu minimierende Metrik wird die euklidische Distanz dieser Auswertung zugrunde gelegt. Das bedingt, dass alle Merkmale, die zum Clustering genutzt werden, die gleiche Einheit und Skalierung nutzen müssen. Die Umsetzung der Methode erfolgt in Python mithilfe des Pakets Tslearn /Tavenard et al. 2020, Version 0.5.2/. Eine Voraussetzung für k-Means ist jedoch die Angabe einer Anzahl k an Clustern, die berechnet werden sollen. Die Festlegung ohne Vorwissen über die Änderungseigenschaften ist eine wesentliche Herausforderung in der Anwendung von k-Means. An dieser Stelle werden zwei Verfahren vorgestellt, die sich dazu eignen, als Deskriptoren für die Ermittlung einer bestmöglichen Anzahl der zu nutzenden Segmente eingesetzt zu werden: (1) die Ellenbogen-Methode: Hier wird Clustering für verschiedene Werte von k durchgeführt. Die resultierenden Summen der quadrierten Residuen werden in Abhängigkeit von k in einem X-Y-Plot eingetragen. Visuell wird beurteilt, dass ein optimales k dann erreicht ist, wenn die Kurve abflacht und durch zusätzliche Cluster keine signifikante Verringerung der Residuen-Quadratsumme mehr erreicht wird /Shi & Zeng 2013/. Die alleinige Beurteilung von minimalen Abweichungsquadraten ist aufgrund der Abhängigkeit von k jedoch nicht zielführend und wird durch (2) die Berechnung eines Silhouetten-Koeffizienten unterstützt. Der Koeffizient kombiniert sowohl Kohärenz innerhalb eines Clusters als auch die Trennung von Clustern /Tan et al. 2006/. Die Berechnung und Beurteilung des Koeffizienten ist bei /Kaufmann & Rousseeuw 1990/ ausführlich beschrieben. Nach der Interpretation der Ergebnisse und der Wahl k geeigneter Cluster wird das Clustering durchgeführt. Als Ergebnis wird jede Rasterzelle einem Cluster zugewiesen. Auf Basis dieser Segmentierung werden erstmalig die räumlichen Zusammenhänge interpretiert. Für die Interpretation der mit den Segmenten verknüpften Prozesse wird für alle Zeitreihen eines Clusters der Median

berechnet und dieser den Medianen der anderen Cluster gegenübergestellt. Abschließend können Zeitreihen durch die analysierende Person den zugrunde liegenden Prozessen zugeordnet werden.

3.2 4D-Änderungsobjekte

Die Extraktion von 4D-Änderungsobjekten ist eine Methode der raumzeitlichen Segmentierung in 3D-Zeitserien, um Änderungen verschiedener räumlicher und zeitlicher Eigenschaften vollautomatisch zu analysieren. Dabei werden Änderungen zunächst in der Zeitserie detektiert und dann auf Basis ähnlicher Änderungshistorien räumlich abgegrenzt. Dies ergibt sogenannte 4D-Änderungsobjekte ("4D objects-by-change" /Anders et al. 2021/), die sich zeitlich und räumlich überlagern können, entsprechend verschiedener Oberflächenprozesse in der realen Welt. Gegenüber der gängigen Vorgehensweise, bei der Oberflächenänderungen zwischen Epochenpaaren manuell gewählter Zeitspannen analysiert werden, verbessert die Zeitserien-basierte Methode die Änderungsdetektion in Anwendungsfällen, in denen der Startzeitpunkt der beteiligten Prozesse nicht bekannt ist. Auch die Quantifizierung des Änderungsvolumens wird genauer, wenn die Oberflächenänderungen von unterschiedlicher Dauer sind und dabei mehrere Epochen in der Zeitserie umfassen /Anders et al. 2022/.

3.2.1 Ableitung des Raum-Zeit-Arrays der Oberflächenänderungen

Die raumzeitliche Segmentierung basiert auf der Datenstruktur eines gleichförmig dimensionierten Raum-Zeit-Arrays, was das zu beobachtende Objekt einschließt. Abgeleitet aus der Zeitserie der 3D-Punktwolken, enthält dieser Array die Oberflächenänderungen relativ zu einer globalen Null-Epoche für eine Menge sogenannter "Core Points", die für die beobachtete Szene definiert werden. Somit enthält der Raum-Zeit-Array die Information über Änderungen in der Szene zu jedem Zeitpunkt in der Zeitserie. Gleichzeitig besteht Zugriff auf die 1D-Zeitserie an jedem Punkt in der Szene (also Core Point). Als Punktwolke können die Core Points grundsätzlich irregulär im Raum angeordnet sein. In dieser Studie wird für die Extraktion der 4D-Änderungsobjekte jedoch ein reguläres Gitter an Core Points herangezogen. Die räumliche Auflösung (Gitterweite) der Core Points wird auf 0,5 m festgelegt. Die Änderungswerte pro Punktwolken-Epoche werden relativ zur ersten Epoche (als globale Null-Epoche) als Punktwolkendistanzen bestimmt. Die Distanzberechnung basiert hierbei auf einer Erweiterung des weitverbreiteten M3C2-Algorithmus /Lague et al. 2013/ mit Varianzfortpflanzung (M3C2-EP /Winiwarter et al. 2021/). M3C2 berechnet die Distanz lokaler Oberflächen zweier Punktwolken, indem die 3D-Position der Referenzpunktwolke für einen Core Point aus allen Punkten in einer lokalen Nachbarschaft gemittelt wird. Die Änderung wird dann auf den Normalvektor einer lokal eingepassten Ebene projiziert, wobei die Distanz zur Vergleichspunktwolke durch einen orientierten Zylinder (mit separat definiertem Radius) bestimmt wird, der die zweite Epoche schneidet. Die Normalvektoren für die Distanzberechnung werden anhand der Core Points in einer Nachbarschaft von 5,0 m berechnet und für alle Punktwolkenvergleiche in der Zeitserie verwendet. Für die M3C2-EP-Distanzberechnung an den Core Points werden alle Punkte der Originalpunktwolke berücksichtigt. Bei der M3C2-Nachbarschaftssuche kommt ein Zylinderradius von 0,5 m und eine maximale Zylinderlänge, also maximale Distanz, von 3,0 m zum Einsatz, wodurch durchschnittlich 18 ± 6 Punkte einer Epoche im Zylinder enthalten sind.

Nach der Distanzberechnung für alle Epochen ist für jeden Core Point eine Zeitserie von M3C2-EP-Distanzen vorhanden. Auf diese Zeitserien wenden wir zur Reduktion von Rauschen eine zeitliche Mittelung an. Dem Ansatz von /Kromer et al. 2015/ folgend, wird der Änderungswert jeder Epoche auf den Medianwert eines gleitenden Zeitfensters von 24 h Dauer gesetzt, was für unsere Daten 8 Epochen entspricht. Diese Filterung wird nur in der zeitlichen Domäne angewandt, da eine räumliche Aggregation bereits in der M3C2-Distanzberechnung enthalten ist. Die zeitlich gemittelten Änderungswerte im abgeleiteten Raum-Zeit-Array stellen den Input für die Extraktion von 4D-Änderungsobjekten.

3.2.2 Raumzeitliche Segmentierung von 4D-Änderungsobjekten

Die raumzeitliche Segmentierung, also der Kern der Extraktion von 4D-Änderungsobjekten, wird durch Region Growing ausgehend von Seed Points (kurz: Seeds) durchgeführt. Diese Seeds sind bestimmte Zeitspannen an bestimmten Core Points, in denen relevante Oberflächenaktivität auf Basis der Zeitserie detektiert wurde.

Die Detektion dieser relevanten Oberflächenaktivität erfolgt durch lineare Regression /Anders et al. 2022/. Dabei werden Zeitspannen identifiziert, in denen Akkumulation oder Erosion stattfindet, also eine kontinuierliche Zu- oder Abnahme von Oberflächenmaterial (oder eine Verformung der Oberfläche selbst). Diese Identifizierung erfolgt durch stückweise lineare Regression, indem eine Gerade mittels kleinster Quadrate für Teile von Zeitserienwerten, die ähnliche numerische Gradienten aufweisen, eingepasst wird. Um dann zu bestimmen, ob es sich um eine relevante Änderung handelt, d. h. ob eine Änderungszeitspanne als Seed verwendet werden soll, ist ein Schwellenwert erforderlich, der die minimal detektierbare Änderung repräsentiert. Für die Daten in dieser Studie wird ein fester Wert von 0,05 m verwendet. Ein niedrigerer Wert würde zu einer höheren Anzahl an 4D-Änderungsobjekten führen, die keine relevanten oder realen Oberflächenänderungen repräsentieren, sondern durch Unsicherheiten der Koregistrierung und in geringerem Maße auch der Messunsicherheiten verursacht werden. Tatsächliche Oberflächenänderungen mit Magnituden unter 0,05 m können demnach aber nicht detektiert werden und sind nicht im Analyseergebnis enthalten.

Die Detektion von Oberflächenänderungen wird für alle Core Points durchgeführt. An jedem Core Point können keine, eine, oder mehrere Zeitspannen von Oberflächenaktivitäten als Seed-Kandidaten detektiert werden. Im Anschluss an die Seed-Detektion werden 4D-Änderungsobjekte durch Region Growing räumlich abgegrenzt. Dabei wird die Zeitspanne eines 4D-Änderungsobjekts genau durch den Start- und Endzeitpunkt einer im Seed detektierten Oberflächenaktivität abgegrenzt. Seeds aus der Liste von Seed-

Kandidaten werden für Region Growing verwendet, wenn sie nicht bereits in ein voriges 4D-Änderungsobjekt segmentiert wurden (d. h. es besteht sowohl zeitliche als auch räumliche Überlappung). Als Homogenitätskriterium für das Region Growing wird die Ähnlichkeit der Oberflächenänderungen in der Seed-Zeitspanne, die als Inverse der Dynamic-Time-Warping-(DTW-)Distanz /Berndt & Clifford 1994/ abgeleitet wird, verwendet. Der Schwellenwert für die Segmentierung wird für jedes 4D-Änderungsobjekt automatisch bestimmt, basierend auf dem Ergebnis mehrerer, parallel berechneter Segmentvarianten für verschiedene verwendete Schwellenwerte (in dieser Studie 0,5 bis 0,9). Dies folgt dem Ziel, das Objektausmaß zu maximieren, aber gleichzeitig eine starke Überschätzung der Fläche zu vermeiden. Letzteres passiert, sobald der Schwellenwert für das jeweilige 4D-Änderungsobjekt so niedrig wird, dass eine große Fläche außerhalb des strikteren Objektausmaßes hinzugefügt wird. Details zur Methode der raumzeitlichen Segmentierung sind in /Anders et al. 2021/ präsentiert. Das Ergebnis ergibt eine Sammlung von 4D-Änderungsobjekten, die Oberflächenaktivitäten in der Szene der 3D-Zeitserie beschreiben.

4 RESULTATE

4.1 Zeitreihen-Clustering mittels k-Means-Algorithmen

Es werden 318 Einzelscans aus dem genannten Zeitraum für die Auswertung genutzt. Jedes Rasterbild hat eine Größe von 1129×535 Pixeln und nach der Filterung der Daten verbleiben 406756 Pixel und die gleiche Anzahl an Zeitserien, die geclustert werden. Zunächst werden Modelle für verschiedene Werte für k (2 bis 15, 20, 25, 30, 35, 40, 45 und 50) berechnet. Nach der Begutachtung der jeweiligen Summen der Abweichungsquadrate sowie der Silhouetten-Koeffizienten fällt die Wahl auf ein Modell mit k = 14. Aufgrund der hohen Anzahl der vorliegenden Prozesse und Bereiche (Fels, Wiesen, Felder, Bauarbeiten usw.) in der kompletten Szene fällt auf, dass die berechneten Parameter keine eindeutige Struktur in den Daten erkennen lassen. Das ist nicht als Defizit der Methode zu verstehen, vielmehr reicht das Merkmal einer Streckenveränderung alleine nicht aus, die Vielzahl an Oberflächenprozessen in der Szene durch das Modell darzustellen. Im Sinne einer semiautomatischen Echtzeitassistenz der hier vorliegenden Methodik ist im nächsten Schritt eine manuelle Analyse der Daten notwendig. Abb. 4 zeigt auf der linken Seite das Ergebnis des Clustering in 14 Klassen. Die Erosionsrinnen und die darunter liegende Baustellenaktivität sind visuell zu erkennen, aber die Zeitreihen selbst zeigen diese Prozesse nicht eindeutig und während der vorgegebenen Zeiträume werden die Prozesse nicht exklusiv extrahiert. Die Segmente werden durch eine Vielzahl an Subprozessen, die überwiegend aus den Bereichen mit den Bäumen stammen, mehrdeutig interpretierbar.

Mit den bisher semiautomatisch generierten Informationen wird ein Bereich von 200×180 Pixeln ausgewählt, der die drei Erosionsrinnen als auch die Baustellenaktivität beinhaltet. Der Bereich wird dadurch auf 36 000 Zeitreihen reduziert und hat jetzt eine Größe von etwas weniger als 10 % des ursprünglichen Datensatzes.

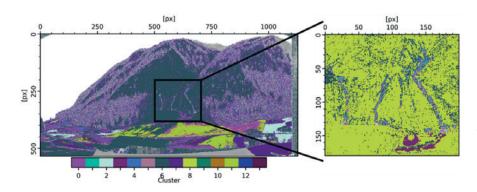


Abb. 4 I Räumliche Darstellung der Rasterzellen, eingefärbt nach ihrem Clusterergebnis. Links: Clustering der kompletten Szene; rechts: Clustering im limitierten Bereich.

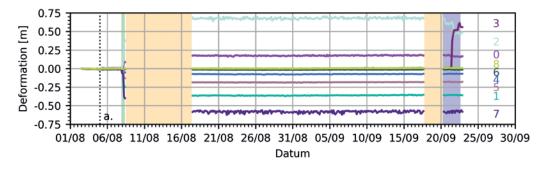


Abb. 5 I Median aller Zeitreihen, die einem bestimmten Cluster zugeordnet sind. Türkis: Zeitraum des Gewitters mit Erosion, Blau: Zeit der Baustellenaktivität, Beige: Datenlücken /Czerwonka-Schröder 2023/.

Der ausgewählte Bereich wird nun verwendet, um die zuvor beschriebene Methode in einer weiteren Iteration erneut durchzuführen. Die Summe der Abweichungsquadrate als auch der Silhouetten-Koeffizient deuten auf ein Modell mit k=9. Das visuelle Ergebnis ist in $Abb.\ 4$ auf der rechten Seite zu sehen. Die Zuordnung zu den Segmenten ist bei jeder Berechnung stochastisch, sodass die Farbgebung der beiden Grafiken nicht identisch ist.

Für die jeweiligen Segmente lässt sich der Median der Zeitreihen berechnen, der robust gegenüber Fehlzuordnungen innerhalb eines Segments ist. In *Abb. 5* sind Zeitreihen als Repräsentation eines Segments zu sehen, die sich durch visuelle Interpretation einem Oberflächenprozess zuordnen lassen. Die Cluster 1, 4, 5 und 7 sind den Erosionen in unterschiedlicher Magnitude zuzuordnen. Cluster

0 und 2 entsprechen der Akkumulation in der Querrinne aufgrund der Erosion. Erosion und Akkumulation sind zeitlich im Bereich des Gewitters (türkis markierter Zeitraum) zu verorten. Cluster 3 stellt die Baustellenaktivität dar, die in Verbindung mit Cluster 2 als eine Entnahme von Material aus der Querrinne verstanden werden kann und deutlich im blau markierten Bereich der Zeitreihe darstellbar ist. Cluster 6 und 8 können als stabil klassifiziert werden. In den beige markierten Bereichen kam es zu Datenausfällen, die den Algorithmus nicht beeinflussen, weil sie ignoriert werden. Die Stärke der Methode ist in Abb. 5 (Zeitpunkt a.) zu sehen. Bei genauer Betrachtung der Scandaten ist zu diesem Zeitpunkt zunächst keine Deformation aufgefallen. Es kann ein weiterer Versatz erkannt werden, der bei erneuter Betrachtung der Daten als Erosion und

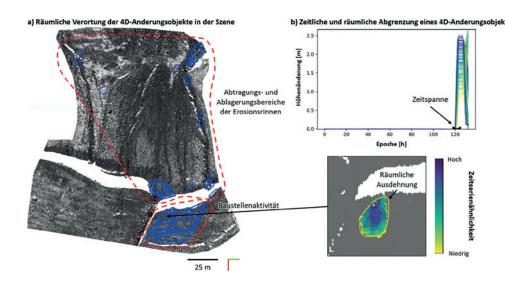


Abb. 6 1 a) Räumliche Vorkommnisse von 4D-Änderungsobjekten in der 3D-Zeitserie (blaue Polygone zeigen die räumliche Ausdehnung), b) Zeitspanne und räumliche Ausdehnung eines Beispielobjekts von Oberflächenänderungen durch Baustellenaktivität. Die Höhenänderungen in der Szene sind in Abb. 7a dargestellt /Czerwonka-Schröder 2023/.

Akkumulation infolge eines Gewitters am Abend des 4. August 2021 eingeordnet werden kann. Die Bereiche wurden schon bei diesem Gewitter erodiert und waren anschließend wieder stabil.

4.2 4D-Änderungsobjekte

Die besondere Stärke dieser raumzeitlichen Segmentierung ist, dass Oberflächenaktivitäten in der Szene individuell identifiziert und raumzeitlich abgegrenzt werden. So kann es — wie bei Oberflächenprozessen in der realen Welt — vorkommen, dass sich 4D-Änderungsobjekte räumlich und/oder zeitlich überlappen. Die höhere Berechnungskomplexität der Methode wiederum kann durch Eingrenzung der räumlichen (und ggf. auch zeitlichen) Abdeckung der PLS-Daten reduziert werden. Aus diesem Grund wird der limitierte Bereich als Ergebnis des k-means-Clusterings (*Abb. 4*) für die Extraktion von 4D-Änderungsobjekten verwendet.

Es werden für 73 433 Core-Points Zeitreihen bereitgestellt. An 13687 Orten werden in Summe 61 023 Änderungen detektiert, aus denen im weiteren Verlauf 67 Änderungsobjekte extrahiert werden. Eine visuelle Inspektion der räumlichen Anordnung zeigt (blaue Objekte in *Abb. 6a*), dass sich die 4D-Änderungsobjekte vor allem auf den Bereich der Baustellenaktivität (rote Markierung in *Abb. 6a*) konzentrieren. Einige Objekte wurden im Bereich der Erosionsrinnen als Abtragungs- und Ablagerungsbereiche identifiziert.

Besonders interessant für die Prozessanalyse ist die Eigenschaft der 4D-Änderungsobjekte, dass räumlich überlappende Oberflächenaktivitäten individuell als zeitlich aufgetrennte Objekte identifiziert werden. Zahlreiche 4D-Änderungsobjekte, die Baustellenaktivitäten repräsentieren, können demnach aus unterschiedlichen Phasen der Materialablagerung und -abtragung stammen. Ein Beispiel dafür ist in *Abb. 6* visualisiert. Es ist demnach möglich, die Dynamik bestimmter Bereiche als einzelne Aktivitäten in ihren zeitlichen und räumlichen Eigenschaften nachzuvollziehen.

Die Erosionsrinnen im Hangbereich werden von den 4D-Änderungsobjekten nicht vollständig abgedeckt. Bei der vorgestellten Fallstudie liegt das daran, dass die Materialabtragung auch innerhalb der Rinne recht homogen durch verschiedene Magnituden von Abtragung und Anlagerung in den Zeitserien manifestiert ist (*Abb. 7*). Daher wird eine Vielzahl kleinerer Objekte extrahiert (teilweise sichtbar in *Abb. 6*). Ein Großteil der Segmente im Bereich der Rinne wird aber aufgrund eines Minimumgrößenkriteriums nicht als

4D-Änderungsobjekt identifiziert. Eine sensiblere Parametrisierung der Analyse ist dazu möglich. Ausschlaggebend ist hierbei die Anforderung der Stakeholder und inwieweit die gesuchten Prozesse vor der Analyse beschrieben werden können.

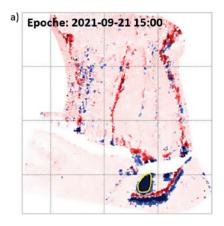
ZUSAMMENFASSUNG UND AUSBLICK

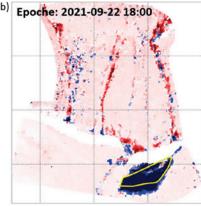
In Zukunft wird die kontinuierliche Überwachung von topographischen Oberflächenveränderungen mittels PLS zunehmen und eine große Menge an Daten erzeugen. Die erwarteten Anwendungen gehen über die Überwachung von Erdrutschen hinaus und umfassen die Untersuchung atmosphärischer Effekte, aber auch die Analyse von Vegetationsveränderungen. Die riesigen Datenmengen müssen verarbeitet, analysiert und gespeichert werden, eine Aufgabe, die mit vorhandenen Ansätzen noch nicht vollumfänglich zu bewältigen ist.

In diesem Beitrag wurde eine zweistufige Vorgehensweise zur Bearbeitung der PLS-Punktwolken vorgestellt. Auf der Grundlage der komprimierten Datenformate wurde mithilfe von unüberwachtem maschinellem Lernen automatisch Informationen extrahiert. Auf diese Weise können Nutzer dabei unterstützt werden, sich auf die relevanten Details zu konzentrieren. Dieser Ansatz ist einfach und hat ein hohes Potenzial für die halbautomatische Analyse, um auf effiziente Weise erste interpretierbare Ergebnisse zu erreichen.

In einem zweiten Schritt wurde eine detailliertere Extraktion von individuellen Oberflächenaktivitäten angewendet. Die Analyse dieser 4D-Änderungsobjekte ermöglicht es, Änderungsprozesse räumlich und zeitlich aufzutrennen, sodass verschiedene Prozesse und auch einzelne Phasen (z. B. von Baustellenaktivität) vollautomatisch raumzeitlich abgegrenzt werden. Die zugrunde liegende raumzeitliche Segmentierung erfordert eine höhere Prozessierungszeit, kann aber durch den ersten Schritt des Zeitserien-Clusterings mit einer räumlichen Eingrenzung der relevanten Bereiche effizient durchgeführt werden.

Eine Kombination von Methoden für das vorgestellte kontinuierliche 3D-Monitoringsystem kann demnach in Zukunft eine zeitnahe Informationsbereitstellung ermöglichen, die je nach Anwendungsfall durch weitere vollautomatische Analysen der Szenendynamik ergänzt wird.





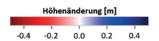


Abb. 7 I Höhenänderungen in der Szene zu den jeweiligen Endzeitpunkten zweier 4D-Änderungsobjekte. Die Ausdehnung der räumlich überlappenden Objekte ist in den gelben Polygonen in a) und b) dargestellt. Angrenzende Bereiche mit ähnlichen Höhenänderungen in b) haben sich in einer anderen Zeitspanne gebildet und werden darum nicht in das Objekt segmentiert /Czerwonka-Schröder 2023/.

LITERATUR

Anders, K.; Winiwarter, L.; Mara, H.; Lindenbergh, R.; Vos, S. E.; Höfle, B. (2021): Fully automatic spatiotemporal segmentation of 3D LiDAR time series for the extraction of natural surface changes. In: ISPRS Journal of Photogrammetry and Remote Sensing 173(2021), 297–308.

Anders, K.; Winiwarter, L.; Höfle, B. (2022): Improving change analysis from near-continuous 3D time series by considering full temporal information. In: IEEE Geoscience and Remote Sensing Letters 19(2022), 1–5.

Anegg, J.; Fritzmann, P. (2019): Geomonitoring am Felssturz im Valsertal. https://www.tirol.gv.at/fileadmin/themen/sicherheit/geoinformation/Monitoring/Vals_2019_Anegg_Fritzmann_Online.pdf (28.01.2023).

Berger, S.; Hofmann, R.; Wimmer, L. (2021): Einwirkungen auf starre Barrieren durch fließähnliche gravitative Massenbewegungen. In: geotechnik 44(2021)2. 77–91.

Berndt, D. J.; Clifford, J. (1994): Using Dynamic Time Warping to Find Patterns in Time Series. In: Proc. of the 3rd international conference on knowledge discovery and data mining, 359–370.

Bremer, M.; Zieher, T.; Pfeier, J.; Petrini-Monteferri, F.; Wichmann, V. (2019): Monitoring der Großhangbewegung Reissenschuh (Schmirntal, Tirol) mit TLS und UAV-basiertem Laserscanning. In: Hanke, K.; Weinold, T. (Hrsg.): 20. Internationale Geodätische Woche Obergurgl 2019. Wichmann, Berlin/Offenbach, 321–330.

Czerwonka-Schröder, D.; Gaisecker, T. (2022): Die permanente dreidimensionale Datenerfassung geotechnischer Strukturen mittels webbasierter Anwendung terrestrischer LiDAR-Sensorik. In: Geomechanik und Tunnelbau 15(2022)5, 596–604.

Czerwonka-Schröder, D. (2023): Konzeption einer qualitätsgesicherten Implementierung eines Echtzeitassistenzsystems basierend auf einem terrestrischen Long Range Laserscanner. Dissertation, Fakultät für Geowissenschaften, Geotechnik und Bergbau, Technische Universität Bergakademie Freiberg. https://nbn-resolving.org/urn:nbn:de:bsz:105-qucosa2-857419 (01.09.2023).

Dinkel, A.; Hoegner, L.; Emmert, A.; Ra, L.; Wunderlich, T.; Stilla, U. (2021): Gemeinsame Auswertung von geodätischen und photogrammetrischen Punktwolken zum Monitoring hochalpiner, gravitativer Massenbewegungen. In: Weinold, T. (Hrsg.): 21. Internationale Geodätische Woche Obergurgl 2021. Wichmann, Berlin/Offenbach, 13–21.

Hartl, S. (2019): Analyse der Felslawinen Frank Slide und Vals mit Hilfe des Computercodes r.avaflow. Diplomarbeit, Institut für Geotechnik, Technische Universität Wien

Kaufman, L.; Rousseeuw, P. (1990): Finding Groups in Data: An Introduction To Cluster Analysis. John Wiley.

Kromer, R.; Abellán, A.; Hutchinson, D.; Lato, M.; Edwards, T.; Jaboyedoff, M. (2015): A 4D Filtering and Calibration Technique for Small-Scale Point Cloud Change Detection with a Terrestrial Laser Scanner. In: Remote Sensing 7(2015)10, 13029–13052.

Kuschnerus, M.; Lindenbergh, R.; Vos, S. (2021): Coastal change patterns from time series clustering of permanent laser scan data. In: Earth Surface Dynamics 9(2021)1, 89-103.

Lague, D.; Brodu, N.; Leroux, J. (2013): Accurate 3D comparison of complex topography with terrestrial laser scanner: Application to the Rangitikei canyon (N-Z). In: ISPRS Journal of Photogrammetry and Remote Sensing 82(2013), 10–26.

Matzka, S. (2021): Unüberwachtes Lernen. In: Künstliche Intelligenz in den Ingenieurwissenschaften. Springer Vieweg, Wiesbaden, 171–197.

Niemeier, W.; Riedel, B. (2017): Monitoring von Hangrutschungen. In: Freeden, W.; Rummel, R.; Schwarz, W. (Hrsg.): Ingenieurgeodäsie. Springer, Berlin/Heidelberg, 539-564.

Shi, W.; Zeng, W. (2013): Genetic k-Means Clustering Approach for Mapping Human Vulnerability to Chemical Hazards in the Industrialized City: A Case Study of Shanghai, China. In: International journal of environmental research and public health 10(2013), 2578–2595.

Tan, P. N.; Steinbach, M.; Kumar, V. (2006): Data mining introduction. People's Posts and Telecommunications Publishing House, Beijing.

Tavenard, R.; Faouzi, J.; Vandewiele, G.; Divo, F.; Androz, G.; Holtz, C.; Payne, M.; Yurchak, R.; Rußwurm, M.; Kolar, K.; Woods, E. (2020): Tslearn, A Machine Learning Toolkit for Time Series Data. In: Journal of Machine Learning Research 21(2020)118, 1–6.

Vosselman, G.; Maas, H.-G. (2010): Airborne and terrestrial laser scanning. CRC Press.

Winiwarter, L.; Anders, K.; Höfle, B. (2021): M3C2-EP: Pushing the limits of 3D topographic point cloud change detection by error propagation. In: ISPRS Journal of Photogrammetry and Remote Sensing 178(2021), 240–258.

Winiwarter, L.; Anders, K.; Schröder, D.; Höfle, B. (2023): Full 4D change analysis of topographic point cloud time series using kalman filtering. In: Earth Surface Dynamics 11(2023), 593–613.

Wujanz, D. (2016): Terrestrial Laser Scanning for Geodetic Deformation Monitoring. Dissertation. Deutsche Geodätische Kommission bei der Bayerischen Akademie der Wissenschaften, C 775. München.

AUTOREN



Dr.-Ing. Daniel Czerwonka-Schröder

DMT GMBH & CO. KG GEO FIELD SERVICES & DATA MANAGEMENT

Am TÜV 1 | 45307 Essen | Deutschland daniel.schroeder@dmt-group.com | ORCID: 0009-0008-0314-5674



Prof. Dr. Katharina Anders

TECHNISCHE UNIVERSITÄT MÜNCHEN-DEPARTMENT OF AEROSPACE AND GEODESY

Lise Meitner Str. 9 | 85521 Ottobrunn | Deutschland k.anders@tum.de | ORCID: 0000-0001-5698-7041



Dr. rer. nat. Lukas Winiwarter

TECHNISCHE UNIVERSITÄT WIEN – RESEARCH UNIT PHOTOGRAMMETRY, DEPARTMENT OF GEODESY AND GEOINFORMATION

Wiedner Hauptstraße 8-10/E120-07 | 1040 Wien | Österreich lukas.winiwarter@tuwien.ac.at | ORCID: 0000-0001-8229-1160

