

# Ko-Registrierung von Sentinel-1 und Sentinel-2 Zeitreihen für die Detektion von Trinkwasserleckagen: ein Methodenvergleich

LINA E. BUDDE<sup>1</sup>, DOROTA IWASZCZUK<sup>1</sup>, LAYTH SAHIB<sup>2</sup> & JÜRGEN BORN<sup>2</sup>

*Zusammenfassung: Leckagen in Fernwasserleitungen in ländlichen Gebieten verursachen große Verluste an Trinkwasser. Ein kontinuierliches Monitoring und damit frühzeitige Erkennung solcher Leckagen ist ohne den Einsatz von Fernerkundung sehr zeit- und kostenintensiv. Durch die gemeinsame Auswertung von Zeitreihen aus den optischen Sentinel-2 Daten als auch SAR Daten von Sentinel-1 können solche Leckagen lokalisiert werden. Eine wichtige Voraussetzung dafür ist genaue Ko-Registrierung der Daten. Daher wurden bestehende Verfahren qualitativ ausgewertet. Sowohl mit der Google Earth Engine als auch mit dem GeFolki Tool kann eine subpixel genaue Ko-Registrierung durchgeführt werden. Dabei zeichnet sich das GeFolki Tool im Vergleich zur Google Earth Engine durch seine Transparenz aus.*

## 1 Einleitung

Der Bedarf an Wasser insbesondere in der Industrie steigt bei gleichzeitig hohen Wasserverlusten beispielsweise durch Verschmutzung (SCHUSTER 2022). Durch den fortschreitenden Klimawandel sind zudem bereits auch in Deutschland Regionen von Dürre bedroht und verringern dadurch zusätzlich die Trinkwasservorkommen (BOEING et al. 2022; KÄSTNER 2023). Umso wichtiger ist es daher, Wasser zu sparen. Während Wasserrohrbrüche in städtischen Gebieten schnell durch überflutete Straßen auffallen, entstehen bei Leckagen in ländlichen Gebieten unbemerkt große Trinkwasserverluste (LAH et al. 2018). Insbesondere bodengestützte Messmethoden wie beispielsweise Druckmessungen bedeuten einen hohen finanziellen Aufwand, ohne, dass dabei zuverlässig kleinere Lecks erkannt und vor allem lokalisiert werden können (LAH et al. 2018). Die Fernerkundung kann jedoch zur Erkennung und Lokalisierung wesentlich beitragen. Während luftgestützte Ansätze durch ihre hohe Auflösung einen Vorteil bieten (KRAPEZ et al. 2022), ermöglichen die frei verfügbaren Sentinel-1 und Sentinel-2 Daten ein kontinuierliches, kostengünstiges und flächendeckendes Monitoring der Wasserleitungen. Im Rahmen eines Projektes der LOEWE Förderlinie 3 wurde daher in Zusammenarbeit mit dem Unternehmen Spatial Business Integration GmbH ein System zur Lokalisierung solcher Leckagen entwickelt. Ein zentraler Bestandteil bildet dafür die Auswertung von Zeitreihen. Diese setzt eine hohe Positionsgenauigkeit der Satellitendaten voraus. Um diese zu erreichen werden die Daten zueinander ko-registriert. Bekannte Verfahren für die Ko-Registrierung beruhen auf Intensitäten oder identischen Punkten (TONDEWAD & DALE 2020). Die Anzahl dauerhafter markanter Punkte in ländlichen Gebieten, die bei den Leckagen im Fokus

---

<sup>1</sup> Technische Universität Darmstadt, Fachbereich Bau- und Umweltingenieurwissenschaften, Fachgebiet Fernerkundung und Bildanalyse, Franziska-Braun-Str. 7, D-64287 Darmstadt, E-Mail: [lina.budde, dorota.iwaszczuk]@tu-darmstadt.de

<sup>2</sup> Spatial Business Integration GmbH, Marienburgstr. 27, D-64297 Darmstadt, E-Mail: [l.y.sahib, juergen.born]@spatial-business-integration.com

stehen, ist jedoch gering. Intensitätsbasierte Ansätze hingegen hängen stark von der jeweiligen Beleuchtung ab. Da somit jedes Verfahren Nachteile besitzt, ist es wichtig Qualitätsangaben zu haben. Bestehende Tools für die Ko-Registrierung liefern allerdings keine einheitlichen Ausgaben und nur begrenzt qualitative Informationen. Insbesondere bei fehlenden Referenzinformationen wie Festpunkten, stellt die qualitative und vergleichbare Auswertung eine Herausforderung dar (USS et al. 2016). Daher wird untersucht, inwieweit bekannte Tools für die Ko-Registrierung im ländlichen Raum im Subpixelbereich geeignet sind und qualitativ ausgewertet werden können.

## 2 Methodik

Für Zeitreihenauswertungen werden zwei verschiedene Ko-Registrierungstools erprobt: die Google Earth Engine (GEE)<sup>3</sup> und GeFolki<sup>4</sup>. Darüber hinaus wird ein Deep Learning Ansatz hinsichtlich seiner Anwendbarkeit geprüft. Ein wichtiger Bestandteil der Untersuchungen ist die Gewinnung von Qualitätsinformation aus den verwendeten Verfahren.

### 2.1 Toolboxen

Die GEE basiert auf der Korrelation der einzelnen gewählten Bildpaare. Dadurch wird eine große Ähnlichkeit der Bilder vorausgesetzt (GOOGLE EARTH ENGINE 2021). Zudem wird in der Beschreibung der GEE angegeben, dass nur ein kleiner Bildversatz bestimmt werden kann. Zusätzlich wird ein Rubber-Sheet Verfahren eingesetzt, welches lokale Bildverzerrungen korrigiert. Im Gegensatz dazu basiert GeFolki auf der Bestimmung eines optischen Flusses (BRIGOT et al. 2016). Die Grundannahme liegt in diesem Fall bei der Invarianz der Pixelintensitäten zwischen zwei Aufnahmen. Aus einer Veränderung der Pixelintensität ergibt sich die gesuchte geometrische Verschiebung. Um diese Verschiebungen auch bei heterogenen Fernerkundungsdaten einsetzen zu können, werden zusätzliche Prozessierungsschritte wie eine Textur- und Kontrastanpassung vorgenommen (BRIGOT et al. 2016). Darüber hinaus wird ein fensterbasierter und somit lokaler Ansatz gewählt. Verwendet werden jeweils die Standardeinstellungen.

### 2.2 Deep Learning

Für die Ko-Registrierung von optischen und SAR Daten mittels Deep Learning stehen verschiedene Ansätze zur Verfügung. Im Gegensatz zu den intensitätsbasierten Verfahren von GEE und GeFolki, beruhen vielversprechende Ansätze im Bereich Deep Learning auf der Suche nach identischen Punkten in SAR-optischen Bildpaaren. Zu dieser Gruppe gehört auch das in diesem Projekt getestete Verfahren SOMatch<sup>5</sup> von HUGHES et al. (2020), bei dem mittels Deep Learning nach korrespondierenden Punkten gesucht wird. Zwei vom Aufbau identische Netze extrahieren jeweils getrennt voneinander in einem optischen beziehungsweise SAR Bild Regionen, die für die Punktzuordnung geeignet sind. Ein drittes Netz dient der genauen

---

<sup>3</sup> <https://earthengine.google.com/>

<sup>4</sup> <https://github.com/aplyer/gefolki>

<sup>5</sup> <https://github.com/system123/SOMatch>

Korrespondenzsuche basierend auf den zuvor gewählten Regionen. Dabei werden jeweils kleinere optische Bildausschnitte mit größeren SAR Ausschnitten korreliert. Im Anschluss erfolgt mit einem vierten Netz eine Ausreißersuche. Da keine trainierten Modelle für die verwendeten Netzwerke vorliegen, müssen diese mit bereits registrierten SAR-optischen Bildpaaren trainiert werden. Nach dem Training können entsprechend der Abbildung 1 korrespondierende Punkte bestimmt werden.

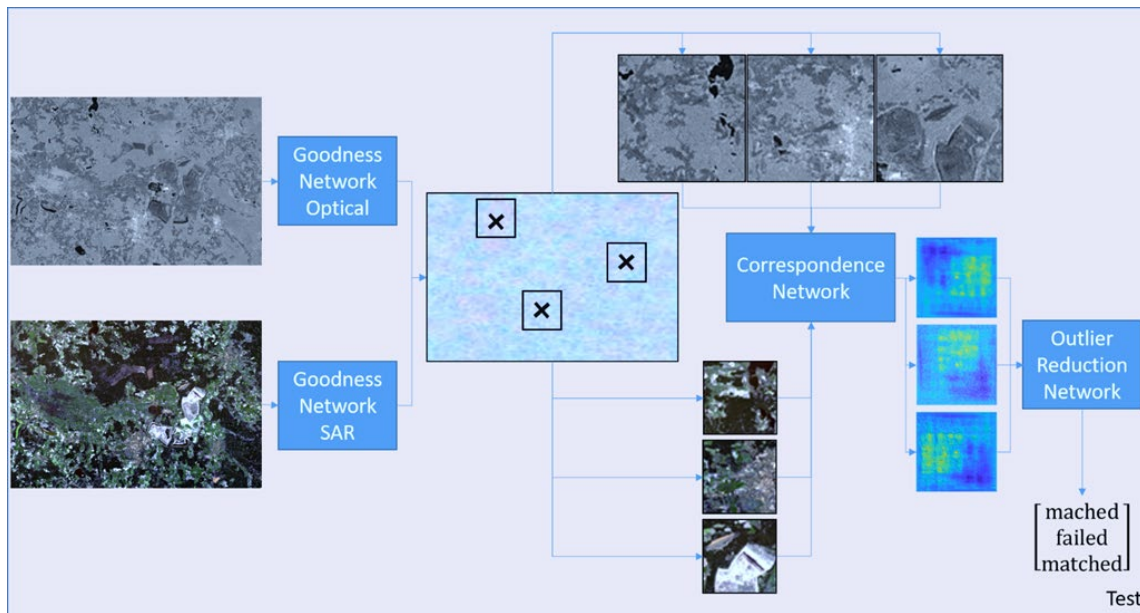


Abb. 1: Schematischer Ablauf der Testphase, bei der ausgehend von einer größeren Bildszene geeignete Bildausschnitte für die Korrespondenzsuche gefunden werden (Goodness Network). Im Anschluss wird die Korrelation zwischen den SAR und optischen Bildausschnitten bestimmt (Correspondence Network) und auf Ausreißer geprüft (Outlier Reduction Network). Adaptiert von HUGHES et al. (2020).

Da sich dieser Deep Learning Prozess auf die Suche nach Korrespondenzen beschränkt, ist die eigentliche Ko-Registrierung nicht enthalten. Infolgedessen erfolgt auf Basis der gefundenen Punktkoordinaten beispielsweise mittels Affintransformation und Ausgleichsrechnung die Bestimmung der Bildtransformationen.

### 2.3 Qualitätsbestimmung

Für eine absolute Genauigkeitsbestimmung der Georeferenzierung fehlen in der Regel gut signalisierte Festpunkte. Daher werden Qualitätsinformation über die Ko-Registrierung intrinsisch aus den Verfahren selbst gewonnen. Somit werden die Abweichungen innerhalb des Ko-Registrierungsvorgangs analysiert. In diesem Fall wird die Annahme verwendet, dass nach einer erfolgreichen Ko-Registrierung keine weitere Transformation notwendig ist. Sowohl bei GEE als auch bei GeFolki wird die Transformation in Form einer pixelweisen Translation  $x, y$  ausgegeben. Diese Translationsvektoren geben die Verschiebung für die Ko-Registrierung an. Treten jedoch Translationen zwischen Referenzbild und bereits ko-registriertem Bild auf, kann aus diesen

verbliebenen Abweichungen  $dx$ ,  $dy$  eine Fehlerabschätzung durchgeführt werden. Die RMSE Werte in x-Richtung werden wie folgt aus den pixelweisen Translationen  $dx_i$  bestimmt:

$$RMSE_{dx} = \sqrt{\sum_i (dx_i)^2} ;$$

die Berechnung in y-Richtung erfolgt äquivalent. Darüber hinaus kann zusätzlich die bei der GEE mitgelieferte Korrelationskonfidenz zur Bewertung herangezogen werden. Für den Vergleich der Verfahren fließen in die Bewertung zusätzlich die Geschwindigkeit, Nutzerfreundlichkeit und Transparenz der Tools ein.

### 3 Versuchsaufbau

#### 3.1 Datensätze

Für den Vergleich der Ko-Registrierungstools wird ein eigener Datensatz bestehend aus einer Sentinel-1 und Sentinel-2 Zeitreihe zwischen Juli und Anfang September 2020 im Gebiet nordwestlich von Darmstadt mit einer Bildausschnittgröße von  $1274 \times 588$  Pixel verwendet. Eine Übersicht über die verschiedenen Zeitreihen ist der Tabelle 1 zu entnehmen. Durch Wolkenbedeckung stehen insgesamt fünf geeignete Aufnahmezeitpunkte bei den optischen Daten zur Verfügung. Für den gleichen Zeitraum wurden insgesamt elf SAR Aufnahmen mit der relativen Orbitnummer 66 eingesetzt. Für die Ko-Registrierung werden für Sentinel-2 nur die RGB Bänder verwendet. Die Sentinel-1 Daten werden entsprechend zum SEN12 Benchmark Datensatz (SCHMITT et al. 2018) vorverarbeitet. Sowohl bei Sentinel-1 als auch bei Sentinel-2 wird eine Bodenauflösung von 10 m verwendet. Zusätzlich wird der SEN12 Benchmark Datensatz (SCHMITT et al. 2018) für das Training des Deep Learning Verfahrens eingesetzt.

Tab. 1: Sentinel-2 (S2) und Sentinel-1 (S1) Zeitreihen für das Untersuchungsgebiet Darmstadt Nordwest. Angegeben sind jeweils Tag und Monat der Aufnahme. Alle Aufnahmen im Untersuchungsgebiet stammen aus dem Jahr 2020.

Bild Nr.	1	2	3	4	5	6	7	8	9	10	11
S2	03.07.	13.07.	23.07.	07.08.	12.08.						
S1	04.07.	10.07.	16.07.	22.07.	28.07.	03.08.	09.08.	15.08.	21.08.	27.08.	02.09.

#### 3.2 Ko-Registrierungsstrategien

Für die Untersuchungen werden verschiedene Ko-Registrierungsstrategien angewendet. Für die Ko-Registrierung von Zeitreihen wird in der ersten Variante „Pfad A“ für jeden Zeitpunkt  $t_i$  das bereits ko-registrierte Bild vom Zeitpunkt  $t_{i-1}$  als Referenzbild verwendet. In der zweiten Variante „Pfad B“ werden alle Zeitpunkte auf dieselbe Referenz  $t_0$  transformiert. Bei der multi-modalen Ko-Registrierung werden SAR-optische Bildpaare ohne zeitliche Komponente ko-registriert.

## 4 Ergebnisse

Nachfolgend sind die Ergebnisse der Versuchsreihen aufgeführt. Bei den Zeitreihenuntersuchungen werden die in 3.2 beschriebenen Strategien jeweils mit GeFolki und GEE ausgeführt und diese qualitativ nach 2.3 ausgewertet.

### 4.1 Vergleich der Ko-Registrierungstools

Zusätzlich zu qualitativen Auswertung werden die eingesetzten Tools hinsichtlich ihrer Bedienbarkeit und ihre Eignung für den praktischen Einsatz im Zusammenhang der Leckage Detektion bewertet. Dafür werden folgende Kriterien berücksichtigt: Geschwindigkeit, Nutzerfreundlichkeit und Transparenz. Tabelle 2 zeigt eine Übersicht über die Kriterien und die verwendeten Tools. Im Gegensatz zu GeFolki und SOMatch ist bei GEE weder die genaue Vorgehensweise beschrieben noch die Implementierung einsehbar. GeFolki weist durch eine Integration sowohl in Python als auch Matlab eine hohe Flexibilität auf. Zudem besitzt GeFolki eine hohe Prozessierungsgeschwindigkeit, welche insbesondere bei großen Datenmengen vorteilhaft ist. Werden die Ko-Registrierungsergebnisse direkt in der GEE weiterverwendet, wird ebenfalls nur eine kurze Verarbeitungszeit benötigt. Jedoch wird ein Wechsel zu einem anderen Verarbeitungstool gewünscht, verlangsamt ein dafür erforderlicher Export der Ko-Registrierung den Verarbeitungsprozess. Bei SOMatch liegt nur eine datensatzspezifische Implementierung vor, die entsprechend für die eigenen Eingabedaten angepasst werden muss. Dadurch werden Programmierkenntnisse in Python und Erfahrung mit Deep Learning Verfahren vorausgesetzt. Zudem ist keine Ende-zu-Ende Implementierung für den Gesamtprozess vorhanden.

Tab. 2: Übersicht über die verwendeten Ko-Registrierungstools und deren Bewertung.

	GEE	GeFolki	SOMatch
Geschwindigkeit	Es werden keine eigenen Rechenkapazitäten benötigt, Export in Google Drive eher langsam	Schnell, abhängig von verwendetem System	Hoher zeitlicher Aufwand für das Training
Nutzerfreundlichkeit	Benötigt Google Account, mit wenigen Befehlen umsetzbar	Matlab auch mit wenig Programmierkenntnis verwendbar, Python Implementierung benötigt mehr Kenntnisse	Viel Programmieraufwand, nur Korrespondenzsuche implementiert
Transparenz	Black Box	Open Source Code, Paper	Open Source Code, Paper

### 4.2 Sentinel-2 Zeitreihe

Bei der Auswertung der Ko-Registrierung der Sentinel-2 Zeitreihe wird durchschnittlich ein Versatz von circa 6 m bei GeFolki und 7 m bei GEE zwischen Referenz und unregistriertem Bild ermittelt. Abbildung 2 zeigt die Fehlerabschätzung nach der wiederholten Ko-Registrierung. Dabei weist die GEE eine systematische Verschlechterung der Genauigkeit bei Variante „Pfad B“ auf, insbesondere in der y-Komponente. Diese Verschlechterung über die Zeitschritte geht bereits aus der Korrelationskonfidenz hervor (Tabelle 3), wobei 0 für eine niedrige und 1 für eine hohe Kon-

fidenz steht (GOOGLE EARTH ENGINE 2021). GeFolki liefert eine gleichbleibende Qualität. Insgesamt schneidet die „Pfad A“ Variante besser ab als die Ko-Registrierung bei gleichbleibender Referenz. Die Verschlechterungen bei „Pfad B“ sind auf die unterschiedliche Wolkenbedeckung zurückzuführen. Zudem entstehen durch die größeren Zeitabstände größere Veränderungen hinsichtlich Beleuchtung und spektralen Eigenschaften. Diese Unterschiede können in Variante „Pfad A“ besser berücksichtigt werden. Mit beiden Tools kann eine Subpixelgenauigkeit bei der Ko-Registrierung erreicht werden, wobei die verbleibenden Abweichungen kleiner als die ursprünglichen Differenzen in der Georeferenzierung sind.




Abb. 2: Verbleibender Fehler nach zweimaliger Anwendung der Ko-Registrierung auf Sentinel-2 Zeitreihe bei „Pfad A“ (links) und „Pfad B“ (rechts).

Tab. 3: Durchschnittliche Korrelationskonfidenzen bei Verwendung der GEE für die Sentinel-2 Zeitreihe. Die Werte beziehen sich auf die Konfidenzen zwischen der Referenz und dem angegebenen Bild.

Bild	2	3	4	5
Pfad A	0,42	0,56	0,63	0,61
Pfad B	0,42	0,37	0,28	0,25

### 4.3 Sentinel-1 Zeitreihe

Im Gegensatz zu der Sentinel-2 Zeitreihe ist die bestimmte durchschnittlich notwendige Translation mit circa 5 m bei der GEE kleiner als bei GeFolki mit 7 m. Bezogen auf die Fehlerabschätzung schneidet GEE bei den Sentinel-1 Daten qualitativ besser als GeFolki ab (Abbildung 3). Beim Vergleich der Ko-Registrierungsstrategien kann keine eindeutige Präferenz festgestellt werden. Anhand der Korrelationskonfidenzen in Tabelle 4 zeigt sich eine etwas bessere Konfidenz für „Pfad A“. Jedoch verbleiben die Konfidenzen auf niedrigem Niveau. Mit Ausnahme des Ausreißers bei Bild 8 zu 1 sind jedoch die RMSE Werte in Abbildung 3 für „Pfad B“ besser als bei „Pfad A“. Im Gegensatz zur GEE und auch zur Sentinel-2 Ko-Registrierung können für GeFolki sowohl bei „Pfad A“ als auch „Pfad B“ systematische Unterschiede zwischen der x- und y-Komponente festgestellt werden, bei denen die y-Komponente schlechter abschneidet. Eine mögliche Ursache dafür kann in einem stärkeren Einfluss der Schrägsichtgeometrie bei den SAR Daten auf das GeFolki Verfahren liegen. Obwohl bei der Sentinel-1 Zeitreihe ebenfalls die Subpixelgenauigkeit erreicht

werden kann, ist festzustellen, dass im Vergleich zu der Sentinel-2 Zeitreihe die Qualität der eingesetzten Tools abnimmt. Zudem erreicht die verbleibende Abweichung in der Fehlerabschätzung in Einzelfällen das gleiche Maß wie die durchschnittlich bestimmte Ko-Registrierung selbst.

Tab. 4: Durchschnittliche Korrelationskonfidenzen bei Verwendung der GEE für Sentien-1 Zeitreihe.

	2	3	4	5	6	7	8	9	10	11
Pfad A	0,32	0,29	0,26	0,35	0,33	0,37	0,22	0,24	0,36	0,27
Pfad B	0,32	0,25	0,29	0,29	0,21	0,25	0,17	0,25	0,19	0,16




Abb. 3: Verbleibender Fehler nach zweimaliger Anwendung der Ko-Registrierung auf Sentinel-1 Zeitreihe bei „Pfad A“ (oben) und „Pfad B“ (unten).

#### 4.4 Multi-modale Ko-Registrierung

Für die multi-modale Ko-Registrierung mit SOMatch wurde bereits im Training des „Correspondence“ Netzwerkes ein durchschnittlicher Abstand zwischen Prädiktion und Referenz von 70 Pixeln erreicht. Dies deutet daraufhin, dass allein auf Basis von den Sentinel-1-2 Bildpaaren keine ausreichend korrelierenden Merkmale extrahiert werden konnten. Der erforderliche Grenzwert für eine erfolgreiche Zuordnung wurde somit nur von einem sehr kleinen Anteil der Trainingsdaten

erfüllt. Das hat zur Folge, dass keine Testdaten auf Basis von SOMatch ko-registriert werden konnten. Ein wesentlicher Faktor spielt dabei die Auslegung der Implementierung auf hochauflösende Satellitendaten oder alternativ die Hinzunahme von zusätzlichen Informationen wie der Landbedeckung. Somit ist trotz seiner Größe und entsprechender Anpassungen auf den SEN12 Datensatz die derzeitige Implementierung von SOMatch nicht für die Ko-Registrierung von Sentinel-1 mit Sentinel-2 Daten geeignet.

## 5 Fazit & Ausblick

Die Auswertung der verschiedenen Toolboxen zeigt, dass die bereits vorliegende Georeferenzierung der Datenprodukte eine Pixelgenauigkeit erreicht. Für die subpixel genaue Auswertung wird jedoch eine Ko-Registrierung benötigt. Insbesondere durch das gute Abschneiden bei der Sentinel-1 Ko-Registrierung wurde die GEE für die Datenvorverarbeitung der nachfolgenden Leckage Detektion eingesetzt. Der Einsatz von Deep Learning für den Ko-Registrierungsprozess benötigt jedoch in Zukunft eine robustere Trainierbarkeit, um effizient eingesetzt werden zu können. Zudem sind die in diesem Bereich eingesetzten punktbasierten Ansätze stark von der Auflösung und anderen datenvorverarbeitenden Schritten wie beispielsweise Speckle Filterung abhängig. Auf der Basis konventioneller Verfahren wie der GEE konnten jedoch vielversprechende Ergebnisse für die Leckage Detektion für Frei- und Landwirtschaftsflächen erzielt werden. Mit Hilfe der optischen Bildinformationen im Infrarotbereich können unter anderem Anomalien der Biomasse erkannt werden. Radardaten reagieren dagegen auf eine veränderte Dielektrizität des Bodens, die wiederum durch die Bodenfeuchte bestimmt wird. Beide Datenquellen zusammen liefern Hinweise auf Leckagen in den Wasserversorgungsleitungen. Diese entwickelte Technologie ermöglicht eine schnelle und genaue Identifikation von Leckagen in Versorgungsleitungen und damit die kostengünstige Überwachung von Netzabschnitte mit vorhandenen Satelliten.

## 6 Danksagung

Wir bedanken uns für die Projektförderung im Rahmen von LOEWE beim Land Hessen und der guten Zusammenarbeit mit der Spatial Business Integration GmbH. Zusätzlich möchten wir Jakob Bahle, Julian Schnell und Sebastian Hunger für ihre Unterstützung danken.

## 7 Literaturverzeichnis

- BOENING, F., RAKOVEC, O., KUMAR, R., SAMANIEGO, L., SCHRÖN, M., HILDEBRANDT, A., REBMANN, C., THOBER, S., MÜLLER, S., ZACHARIAS, S., BOGENA, H., SCHNEIDER, K., KIESE, R., ATTINGER, S. & MARX, A., 2022: High-resolution drought simulations and comparison to soil moisture observations in Germany. *Hydrol. Earth Syst. Sci.*, **26**, 5137-5161, <https://doi.org/10.5194/hess-26-5137-2022>.
- BRIGOT, G., COLIN-KOENIGUER, E., PLYER, A. & JANEZ, F., 2016: Adaption and Evaluation of an Optical Flow Method Applied to Coregistration of Forest Remote Sensing Images. *IEEE J. Sel. Top. Appl. Earth Observations Remote Sensing*, **9**(7), 2923-2939, <https://doi.org/10.1109/JSTARS.2016.2578362>.



- GOOGLE EARTH ENGINE, 2021: Registering Images. <https://developers.google.com/earth-engine/guides/register>, letzter Zugriff am: 16.01.2023.
- HUGHES, L. H., MARCOS, D. LOBRY, S., TUIA, D. & SCHMITT, M., 2020: A deep learning framework for matching of SAR and optical imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, **169**, 166-179, <https://doi.org/10.1016/j.isprsjprs.2020.09.012>.
- KÄSTNER, S., 2023: Trockenheit im tiefen Boden behindert Grundwasserbildung. Deutschlandfunk, <https://www.deutschlandfunk.de/duerre-trotz-regen-warum-trockene-boeden-das-grundwasser-behindern-100.html>, letzter Zugriff am: 23.01.2023.
- KRAPEZ, J.-C., SANCHIS MUÑOZ, J., MAZEL, C., CHATELARD, C., DÉLIOT, P., FRÉDÉRIC, Y.-M., BARRILLOT, P., HÉLIAS, F., BARBA POLO, J., Olichon, V., SERRA, G., BRIGNOLLES, C., CARVALHO, A., CARREIRA, D., OLIVEIRA, A., ALVES, E., FORTUNATO, A.B., AZEVEDO, A., BENETAZZO, P., BERTONI, A. & LE GOFF, I., 2022: Multispectral Optical Remote Sensing for Water-Leak Detection. *Sensors*. **22**(3), 1057, <https://doi.org/10.3390/s22031057>.
- LAH, A. A. A., DZIYAUDDIN, R. A. & MD YUSOFF, N., 2018: Localization Techniques For Water Pipeline Leakages: A Review. 2nd International Conference on Telematics and Future Generation Networks (TAFGEN), Kuching, Malaysia, 49-54, <https://doi.org/10.1109/TAFGEN.2018.8580467>.
- SCHMITT, M., HUGHES, L. H. & ZHU, X. X., 2018: The SEN1-2 Dataset for Deep Learning in SAR-Optical Data Fusion. *ISPRS Ann. Photogramm. Remote Sens. Spatial Inf. Sci.*, **IV-1**, 141–146, <https://doi.org/10.5194/isprs-annals-IV-1-141-2018>.
- SCHUSTER, K., 2022: Klimakrise: Wird in Deutschland das Trinkwasser knapp? <https://www.zdf.de/nachrichten/panorama/klima-wasser-knappheit-deutschland-100.html>, letzter Zugriff am 09.01.2023.
- TONDEWAD, P. S. & DALE, M. P., 2020: Remote Sensing Image Registration Methodology: Review and Discussion. *Procedia Computer Science*, **171**, 2390-2399, <https://doi.org/10.1016/j.procs.2020.04.259>.
- USS, M. L., VOZEL, B., LUKIN, V. V. & CHEHDI, K., 2016: Multimodal Remote Sensing Image Registration with Accuracy Estimation at Local and Global Scales. *IEEE Transactions on Geoscience and Remote Sensing*, **54**(11), 6587-6605, <https://doi.org/10.1109/TGRS.2016.2587321>.