

KI-basierte Change Detection in urbanen Räumen Perus

Das rasche Wachstum urbaner Räume in Peru stellt Planungs- und Verwaltungsbehörden vor die Herausforderung, nicht konforme Gebäudeneubauten zeitnah, flächendeckend und zuverlässig zu erkennen. Gleichzeitig fehlen vielerorts aktuelle und konsistente Bestandsdaten, wodurch eine systematische Kontrolle baulicher Entwicklungen nur eingeschränkt möglich ist. Diese Arbeit untersucht die Entwicklung und Evaluation eines reproduzierbaren, halbautomatisierten, KI-basierten Workflows zur Detektion von Gebäudeneubauten in urbanen Gebieten Perus auf Basis bi-temporaler hochauflösender Satellitenbilddaten. Der Fokus liegt auf einer robusten Vorverarbeitung, der Anwendung eines lernbasierten Change-Detection-Modells sowie einer GIS-fähigen Aufbereitung der Ergebnisse für weitere Analysen.

Stand der Forschung

Change Detection beschreibt die Identifikation tatsächlicher Veränderungen zwischen zwei Zeitständen und die Abgrenzung gegenüber Scheinänderungen durch geometrische oder radiometrische Unterschiede (Lu et al., 2004). In der Literatur werden pixelbasierte, objektbasierte und lernbasierte Verfahren unterschieden (You et al., 2020). Pixelbasierte Ansätze reagieren empfindlich auf Lage- und Helligkeitsunterschiede (Lu et al., 2004), während objektbasierte Verfahren robuster sind, jedoch zuverlässige Segmentierungen benötigen (Blaschke, 2010). Lernbasierte Methoden werten beide Zeitpunkte gemeinsam aus, nutzen Kontextinformationen und erfordern korrespondierende Bildpaare sowie qualitativ hochwertige Trainingsdaten (Jiang et al., 2022). In urbanen Szenen stellen insbesondere Schatten und starke Helligkeitsunterschiede zentrale Fehlerquellen dar (Dare, 2005).

Problemstellung

In vielen urbanen Räumen Perus fehlen aktuelle und flächendeckende Gebäudebestandsdaten. Neubauten werden häufig nur punktuell und manuell erfasst, was eine systematische Kontrolle erschwert. Dadurch bleiben bauliche Entwicklungen, in planerisch sensiblen oder gefährdeten Zonen oft lange unerkannt. Ein automatisiertes, gebietsweites Monitoring auf Basis aktueller Geodaten ist bislang nicht vorhanden.

Modellarchitektur: Siamese U-Net

Der Workflow basiert auf einem Siamese U-Net wie in Abbildung 1 dargestellt, das bi-temporale Bildpaare der Zeitpunkte T0 und T1 getrennt, jedoch mit identischen Encoder-Strukturen verarbeitet. Durch die Verwendung geteilter Gewichte werden beide Epochen vergleichbar analysiert, wodurch radiometrische und sensorbedingte Unterschiede reduziert werden. Die extrahierten Merkmalsrepräsentationen werden auf mehreren Skalen zusammengeführt, indem die Merkmale von T0, T1 sowie deren absolute Differenz fusioniert werden. Der anschließende Decoder projiziert diese Informationen mittels Skip-Connections zurück in die ursprüngliche Bildauflösung und erzeugt eine pixelweise Change-Wahrscheinlichkeitskarte.

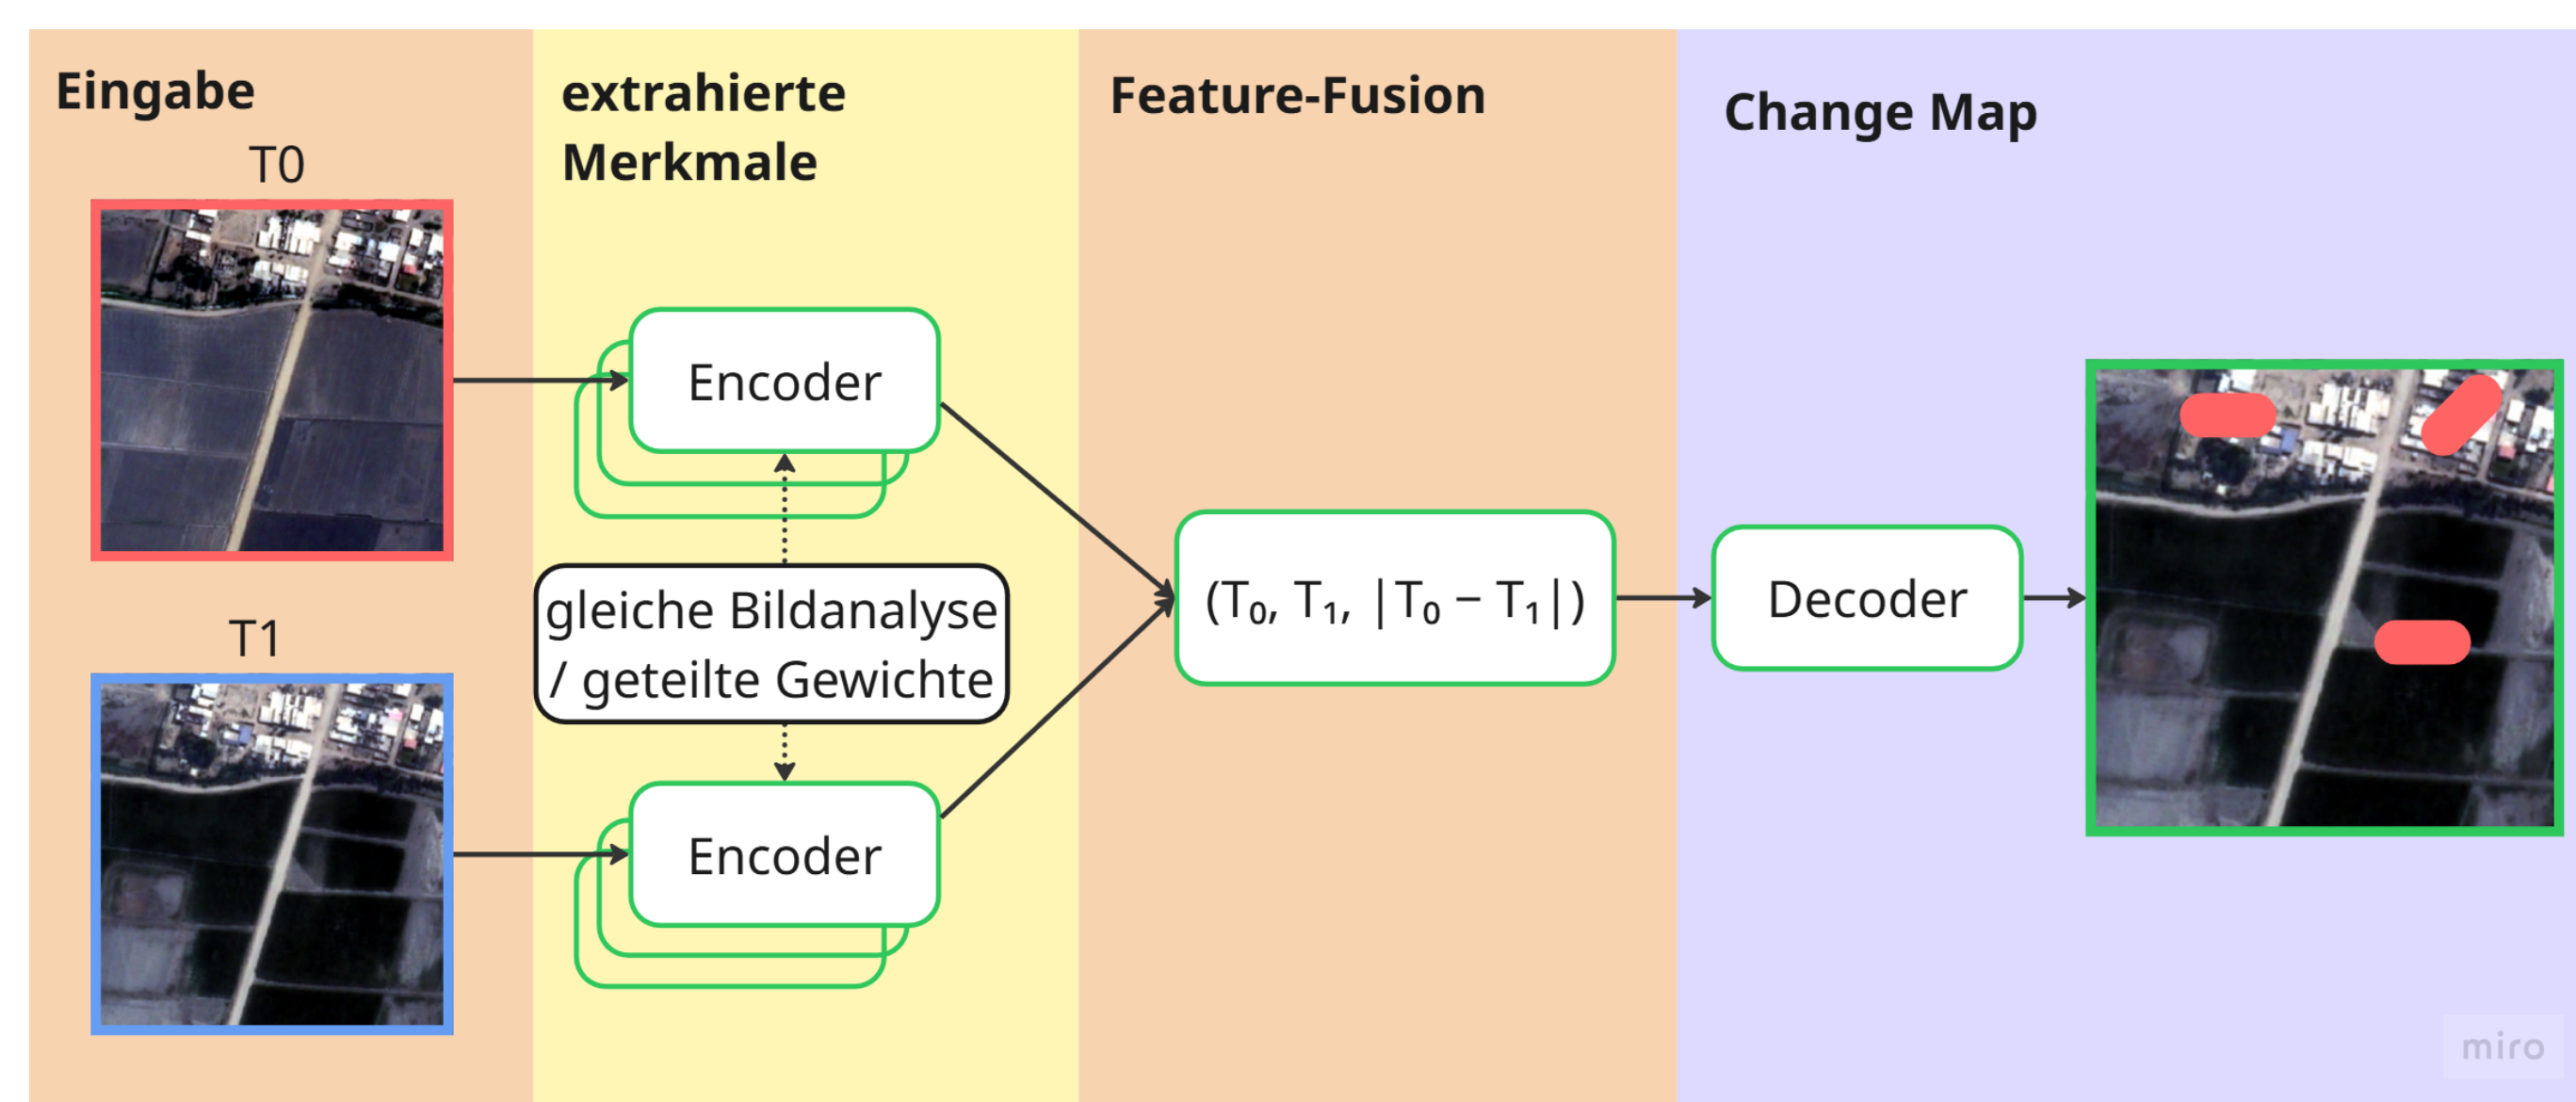


Abb. 2: Schematische Darstellung des Siamese U-Net. (Quelle: Eigene Darstellung)

Methodik & Workflow

Zur Schliessung der identifizierten Forschungslücke wurde ein modularer, reproduzierbarer Workflow zur KI-basierten Change Detection entwickelt, der folgende Hauptschritte umfasst:

Datengrundlage

Bi-temporale, hochauflösende Satellitenbildpaare (T0/T1) des staatlichen Programms PeruSAT-1 (GSD ≈ 0.7 m, RGB + NIR).

1. Vorverarbeitung

- Pixelgenaue geometrische Coregistrierung
- Radiometrische Harmonisierung (perzentilbasierte Normalisierung)
- AOI-Selektion auf Basis planerisch relevanter Zonen

2. Training & Domänenanpassung

- Grundtraining auf öffentlichen Referenzdatensätzen (S2Looking)
- Fine-Tuning mit einem eigens erstellten, peruanischen Trainingsdatensatz

3. KI-basierte Change Detection

Anwendung eines Siamese-U-Net-Modells zur pixelbasierten Detektion baulicher Veränderungen zwischen T0 und T1.

4. Nachbearbeitung & GIS-Integration

Objektbasierte Filterung zur Reduktion falsch positiver Detektionen sowie vektorbasierte, GIS-fähige Ergebnisaufbereitung.

Ergebnisse

Die Resultate zeigen, dass eine zuverlässige Detektion von Gebäudeneubauten unter realen Datenbedingungen nur durch eine konsequente Vorverarbeitung und domänenspezifische Modellanpassung erreicht werden kann.

Quantitativ: Deutliche Verbesserung von F1-Score gegenüber einfachen Differenzmethoden, wie in Tabelle 1 dargestellt.

| Modell | TP | FP | FN | F1 |
|---------------|-----|-----|-----|-------|
| Grundtraining | 6 | 80 | 237 | 0.037 |
| Fine-Tuning 1 | 152 | 221 | 118 | 0.473 |
| Fine-Tuning 2 | 251 | 28 | 14 | 0.923 |

Tab. 1: Veränderung der Modellleistung durch schrittweises Fine-Tuning.

Qualitativ: Klare Lokalisierung relevanter Neubauten, wie in Abbildung 2 zu sehen.



Abb. 2: Detektierte Neubauten im Endergebnis, dargestellt als Vektordaten. (Quelle: Eigene Darstellung)

Nachbearbeitung: Reduktion von Fehlalarmen, wie in Tabelle 2 zu sehen, bei Erhalt relevanter Änderungen. Grenzen des Ansatzes zeigen sich bei sehr kleinen Bauwerken sowie bei grossflächigen, homogenen Dachstrukturen.

| | | | | |
|-------------|-----|----|----|------|
| Endergebnis | 246 | 18 | 14 | 0.94 |
|-------------|-----|----|----|------|

Tab. 2: Modellleistung (TP, FP, FN, F1) nach objektbasierter Nachbearbeitung.

Ausblick

Der entwickelte Workflow stellt eine belastbare Grundlage für die KI-basierte Change Detection dar, erfordert jedoch für eine breitere Anwendung weitere Anpassungen. Eine Übertragbarkeit auf andere Regionen ist insbesondere durch eine gezielte Anpassung der Trainingsdaten an lokale Bauformen und Bildcharakteristika möglich. Grössere und vielfältigere Trainingsdatensätze aus unterschiedlichen Gebieten könnten die Robustheit des Modells weiter erhöhen. Zudem bietet eine schrittweise Erhöhung des Automatisierungsgrads wie etwa bei der Datenauswahl oder Nachbearbeitung, Potenzial zur weiteren Reduktion manueller Arbeitsschritte.