Fachhochschule Nordwestschweiz
Hochschule für Architektur, Bau und Geomatik

Solarpotential auf den Philippinen

Analyse des Solarpotentials durch pixelbasierte und Deep-Learning-gestützte Dachflächensegmentierung

Ausgangslage in den Philippinen

Problemstellung

2,5 Millionen Haushalte ohne Zugang zu Elektrizität

Lösungsansatz der lokalen Behörde

Installation von Solaranlagen auf geeigneten Dächern

Aufbau lokaler Solarstrom-Netze mit Solaranlagen auf geeigneten Dachflächen

- Dachmaterial
- Dachstruktur
- Dachgrösse

Quelle: Google Maps (2025): https://www.google.com/maps [Stand: März 2025].

Quelle: Google Street View (2021): https://www.google.com/maps [Stand: Juni 2025].

Pixelbasierte Dachdetektion

Grundlagendaten

Farbraum: RGB+NIR-Satellitenbilder

Bodenauflösungen : 15 cm, 30 cm und 45 cm

Arbeitsschritte

Extraktion der Pixelwerte

Definition der Klassenwertebereiche

Klassifizierung der Dachflächen

- Entfernen des Hintergrunds
- Detektion der Dachflächen
- Bereinigung der detektierten Flächen

Vektorisierung der Dachflächen

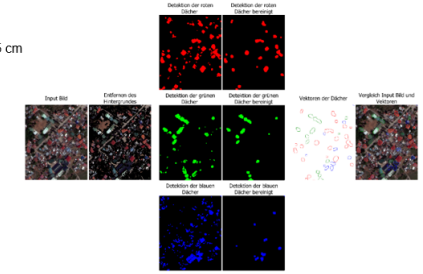

Grundwissen über die U-Net-Architektur

U-Net-Architekturelemente

Eingabebild

Encoder / Decoder

Max-pool 2×2 / up-conv 2×2

Verbindungspfade

Ausgabebild

Modellbewertung

Gesamtgenauigkeit, Präzision, Recall, F1-Score, Objektdetektion

U-Net-Eigenschaften

Entwickelt im Jahr 2015

Entwickelt für biomedizinische Bildsegmentierung

Detailgetreue Segmentierung

Flexible Anpassung

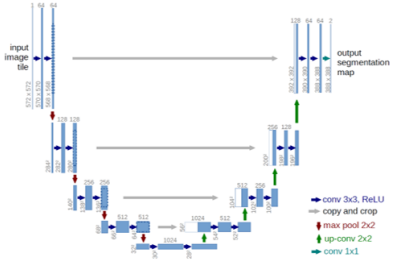

Aufbau der U-Net-Architektur bestehend aus dem Encoder, Decoder und Verbindungen (Ronneberger, O., Fischer, P., & Brox, T. (2015). *U-Net: Convolutional Networks for Biomedical Image Segmentation*)

Dachdetektion mittels U-Net-Architektur

Grundlagendaten / Einstellungen

- Input-Kacheln: 576×576×3
- Farbraum: RGB und RB+NIR
- Bodenauflösung: 15 cm, 30 cm und 45 cm
- Encoder/Decoder: Resnet34 und Mobilenet_v2

Kachel; RGB, GSD 15 cm

Label; schwarz/weiss; GSD 15 cm

Arbeitsschritte

Klassendefinition

- Klare Dachstruktur
- Dachgrösse
- Dachmaterial

Labeln der Daten

- Roboflow mithilfe von SAM

Modelltraining

Anwendung auf den gesamten Datensatz

Anwendung auf Testgebiete

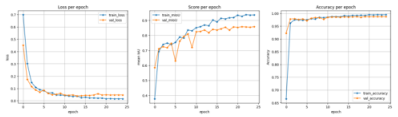

Resultate der Dachsegmentierung

Vergleich mit den Groundtruth Daten

- Deep Learning im RGB-Farbraum erfüllt die Genauigkeitsansprüche von 80%
- Deep Learning im RBNIR-Farbraum hat zu geringe Präzision und Objektdetektion
- Pixelbasierter Ansatz erfüllt die Anforderungen nicht

Farbraum	Encoder / Methode	GSD [cm]	Overall Accuracy [%]	Precision [%]	Recall [%]	F1-score [%]	Objektdetektion [%]
RGB	resnet34	15	99.1	89.0	89.9	89.5	88.8
RGB	resnet34	30	99.1	87.9	90.3	89.1	90.9
RGB	resnet34	45	99.0	87.4	90.3	88.8	90.5
RGB	mobilenet	15	99.0	88.6	88.8	88.7	87.1
RGB	mobilenet	30	99.0	88.6	87.9	88.3	84.1
RGB	mobilenet	45	98.9	88.1	86.7	87.4	81.7
RBNIR	resnet34	15	96.9	59.4	83.2	69.3	76.9
RBNIR	resnet34	30	97.6	65.5	90.7	76.1	89.0
RBNIR	resnet34	45	97.6	65.5	90.7	76.1	64.6
RBNIR	mobilenet	15	97.4	64.8	83.5	72.9	75.0
RBNIR	mobilenet	30	98.2	77.3	80.1	78.7	68.9
RBNIR	mobilenet	45	97.8	71.8	79.9	75.6	67.7
RGBNIR	Pixelbasiert	15	96.4	57.6	59.4	58.5	50.1
RGBNIR	Pixelbasiert	30	96.7	61.4	56.4	58.8	46.1
RGBNIR	Pixelbasiert	45	95.8	50.2	61.9	55.4	57.0

Verteilung der Pixel

- Ungefähr 27-mal so viel Hintergrund wie Vordergrundpixel
- Gesamtgenauigkeit nicht aussagekräftig

	Pred BG	Pred FG
Actual BG	82504370	676029
Actual FG	612284	3072933

Diskussion der Dachsegmentierung

Pixelbasierter Ansatz

- Viele Dächer werden nicht erkannt (verschiedene Rottöne und braune Dächer)
- Unpräzisere Segmentierung

Deep Learning Ansatz auf den RB+NIR-Daten

- Gute Dachdetektion
- Fehlklassifikationen von Vegetation und Strassenflächen
- Teilweise systematische Fehler

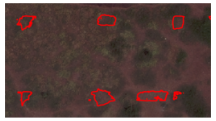

Deep Learning Ansatz auf den RGB-Daten

Erreicht alle geforderten Ziele mit einer sauberen Segmentierung der Dachflächen

Ausgangslage in den Philippinen

<u>Problemstellung</u>

2,5 Millionen Haushalte ohne Zugang zu Elektrizität

<u>Lösungsansatz der lokalen Behörde</u>

Installation von Solaranlagen auf geeigneten Dächern

Aufbau lokaler Solarstrom-Netze mit Solaranlagen auf geeigneten Dachflächen

- Dachmaterial
- Dachstruktur
- Dachgrösse

Quelle: Google Maps (2025): https://www.google.com/maps [Stand: März 2025].

Quelle: Google Street View (2021): https://www.google.com/maps [Stand: Juni 2025].

Einleitung Bachelorarbeit «Solarpotential in den Philippinen»

<u>Zielsetzungen der Arbeit</u>

Segmentierung von geeigneten Dachflächen

- Objektdetektionsgenauigkeit > 80%
- Segmentierungsgenauigkeit > 80%

<u>Untersuchung von Methoden/Grundlagedaten</u>

Detektionsmethode

- Pixelbasierte
- Deep Learning

Grundlagedaten

- Farbräume: RGB+NIR, RGB, RB+NIR
- Auflösungen: 15 cm, 30 cm und 45 cm

Zu detektierende Gebäude

Nicht zu detektierende Gebäude

Quelle: Maxar (6. April 2023) [Stand: April 2025].

Pixelbasierte Dachdetektion

<u>Grundlagendaten</u>

Farbraum: RGB+NIR-Satellitenbilder

Bodenauflösungen : 15 cm, 30 cm und 45 cm

<u>Arbeitsschritte</u>

Extraktion der Pixelwerte

Definition der Klassenwertebereiche

Klassifizierung der Dachflächen

- Entfernen des Hintergrunds
- Detektion der Dachflächen
- Bereinigung der detektierten Flächen

Vektorisierung der Dachflächen

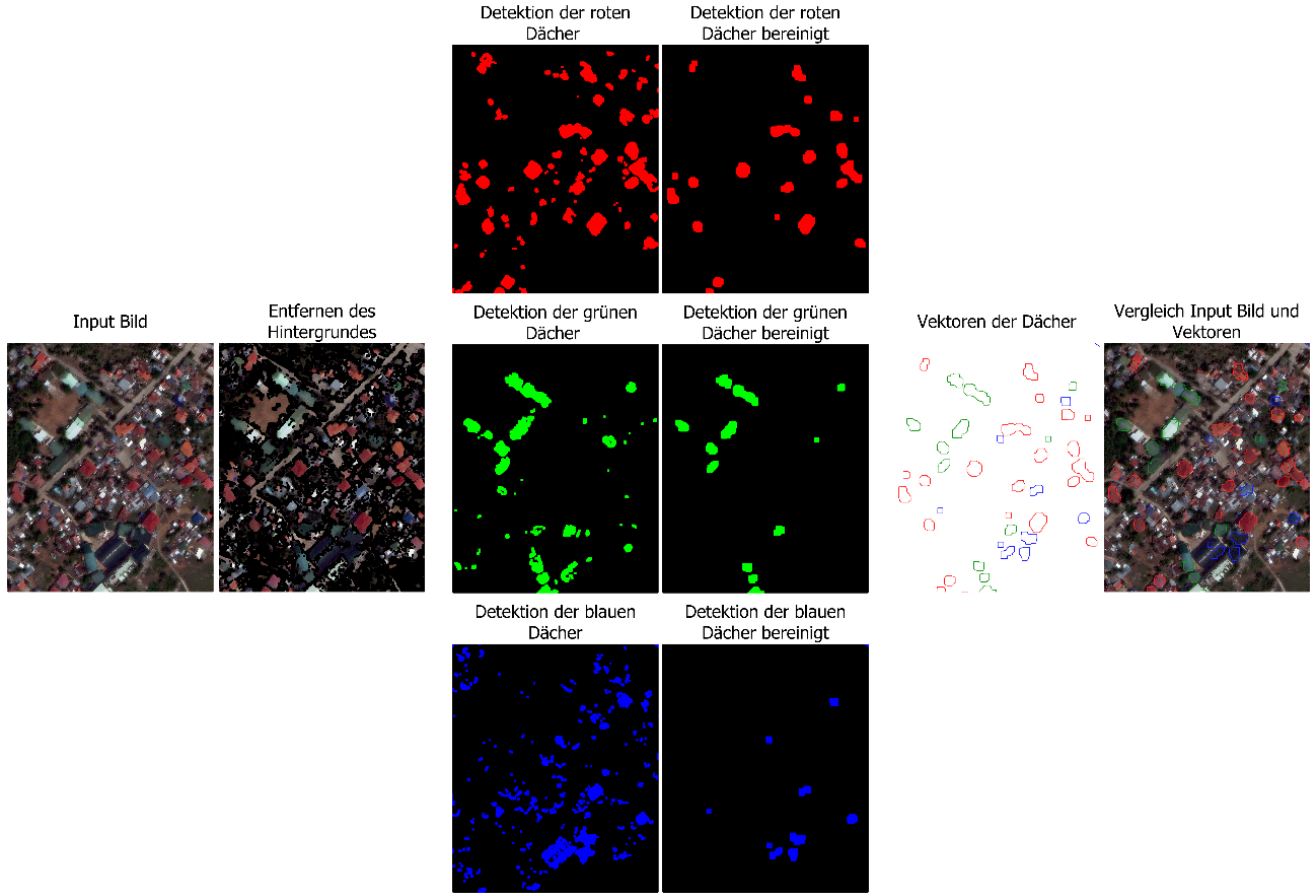

Autor: Janis Kramer, Examinator:in Dr. Prof. Denis Jordan und Natalie Lack, Experte: Thomas Gross, Betreuer: Théo Reibel
© IGEO FHNW

Pixelbasierte Dachdetektion auf der Insel Olango (PHL)

<u>Visueller Vergleich</u>

- Ähnliche Segmentierung bei unterschiedlicher Auflösung
- Keine Dachdetektion von bräunlichen Dachflächen
- Schlechte Detektion von gewissen roten Dachflächen
- Wenig Detektionen von Nicht-Dachflächen

Modelparameter: Bildauflösung 15 cm | Farbraum RGB+NIR | Methode pixelbasiert

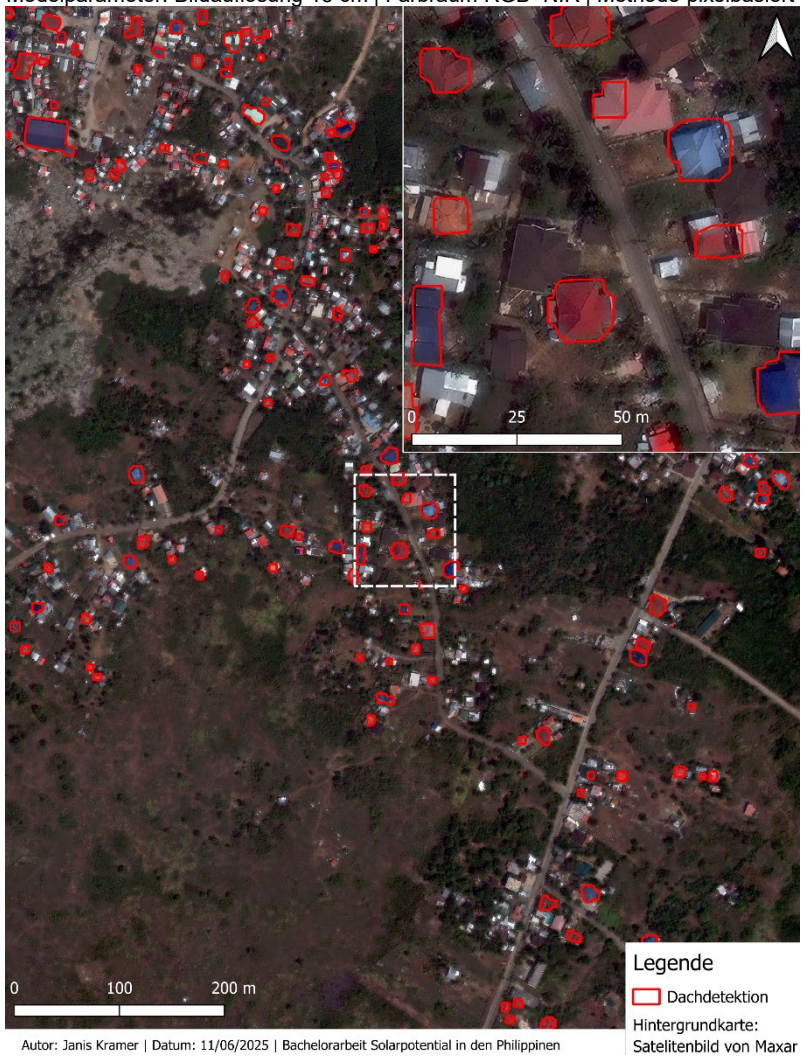

Modelparameter: Bildauflösung 45 cm | Farbraum RGB+NIR | Methode pixelbasiert

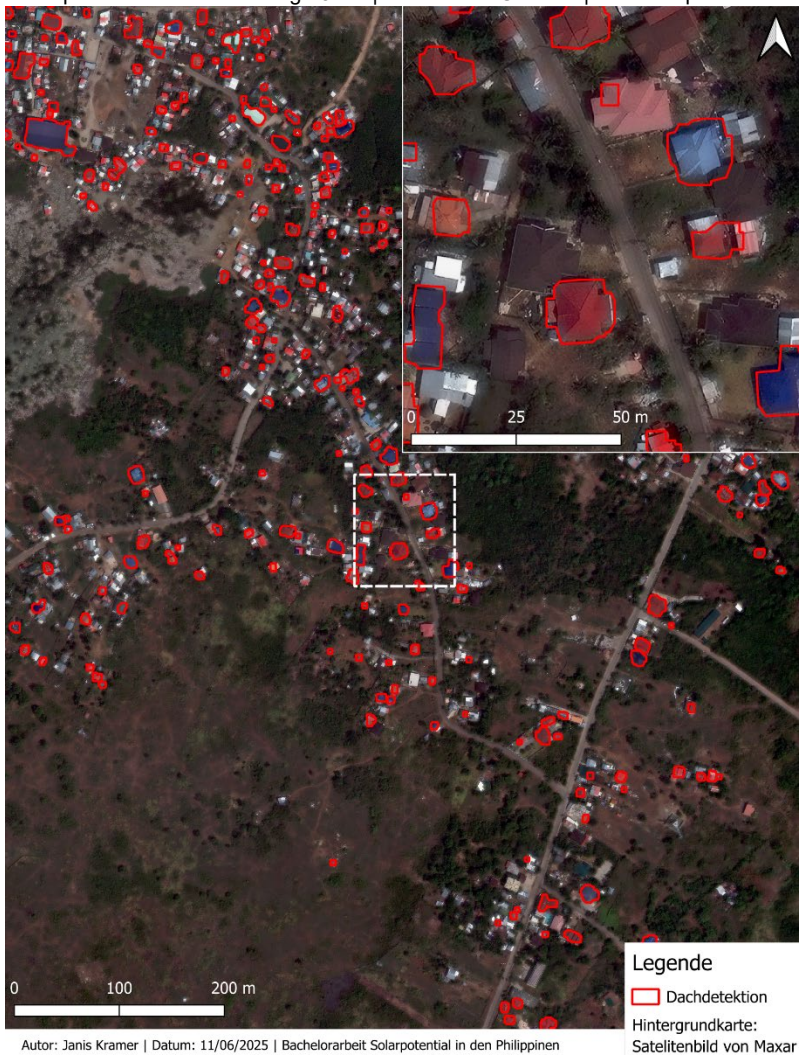

Grundwissen über die U-Net-Architektur

<u>U-Net-Architekturelemente</u>

Eingabebild

Encoder / Decoder

Max-pool 2×2 / up-conv 2×2

Verbindungspfade

Ausgabebild

<u>Modellbewertung</u>

★★☆

Gesamtgenauigkeit, Präzision, Recall, F1-Score, Objektdetektion

<u>U-Net-Eigenschaften</u>

Entwickelt im Jahr 2015

Entwickelt für biomedizinische Bildsegmentierung

Detailgetreue Segmentierung

Flexible Anpassung

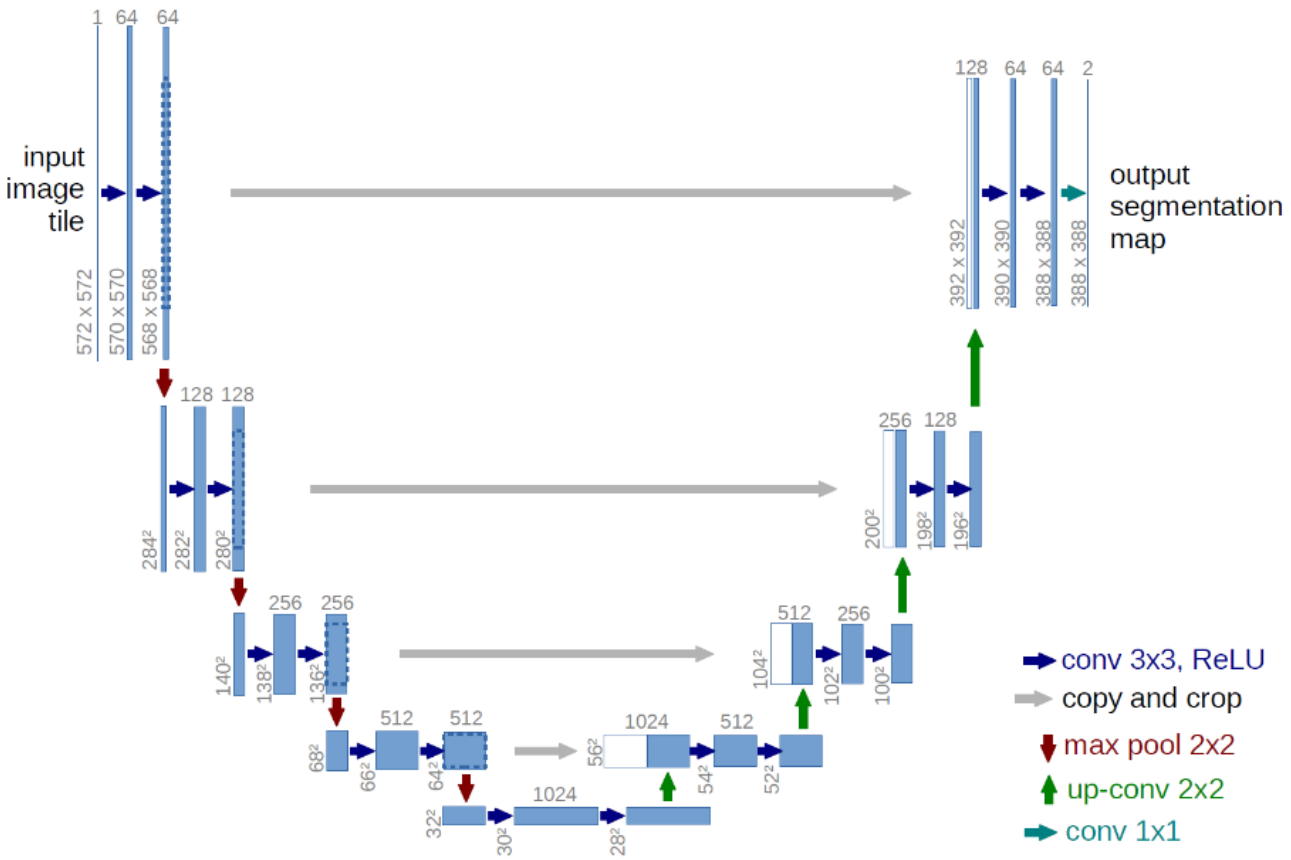

Aufbau der U-Net-Architektur bestehend aus dem Encoder, Decoder und Verbindungen (Ronneberger, O., Fischer, P., & Brox, T. (2015). *U-Net: Convolutional Networks for Biomedical Image Segmentation*)

Dachdetektion mittels U-Net-Architektur

Kachel; RGB, GSD 15 cm

Label; schwarz/weiss; GSD 15 cm

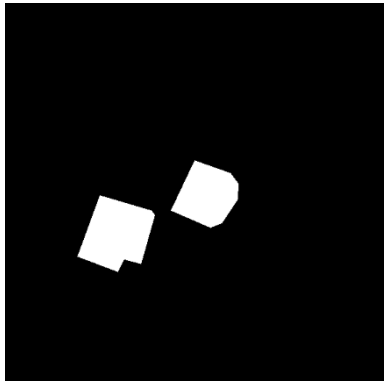

Grundlagendaten / Einstellungen

- Input-Kacheln: 576×576×3
- Farbraum: RGB und RB+NIR
- Bodenauflösung: 15 cm, 30 cm und 45 cm
- Encoder/Decoder: Resnet34 und Mobilenet_v2

Arbeitsschritte

Klassendefinition

- Klare Dachstruktur
- Dachgrösse
- Dachmaterial

Labeln der Daten

- Roboflow mithilfe von SAM

Modelltraining

Anwendung auf den gesamten Datensatz

Anwendung auf Testgebiete

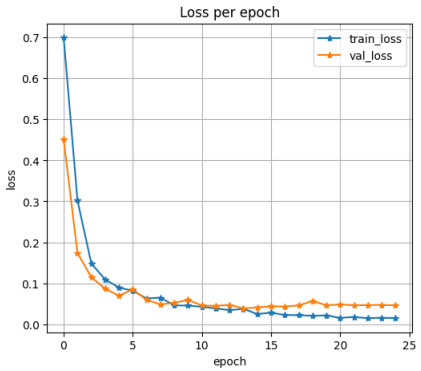

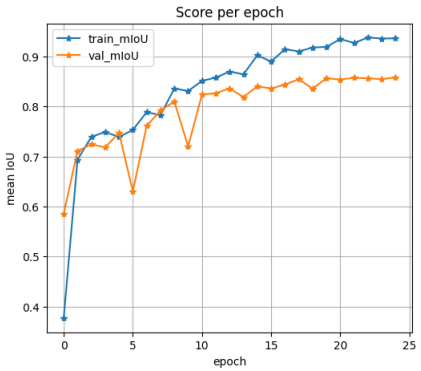

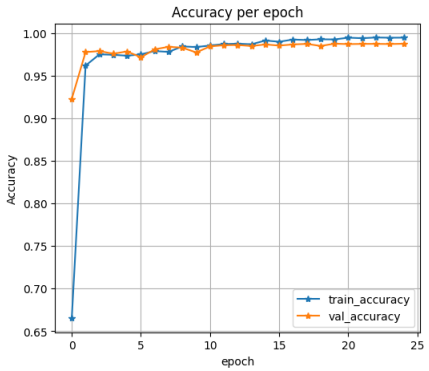

Autor: Janis Kramer, Examinator:in Dr. Prof. Denis Jordan und Natalie Lack, Experte: Thomas Gross, Betreuer: Théo Reibel
© IGEO FHNW

Deep Learning Dachsegmentierung auf der Insel Olango (PHL)

<u>Dachdetektion in RGB</u>

- Ähnliche Segmentierung bei verschiedenen Auflösungen und Encodern
- Visuell gute Segmentierung der Dachflächen
- Einige Falschdetektionen von Wasserflächen

<u>Dachdetektion in RB+NIR</u>

- Ähnliche Segmentierung der Dachflächen
- Mehr Falschdetektionen von Strassen und Vegetation
- Einige Falschdetektionen von Wasserflächen

Modelparameter: Bildauflösung 15 cm | Farbraum RGB | Encoder resnet34

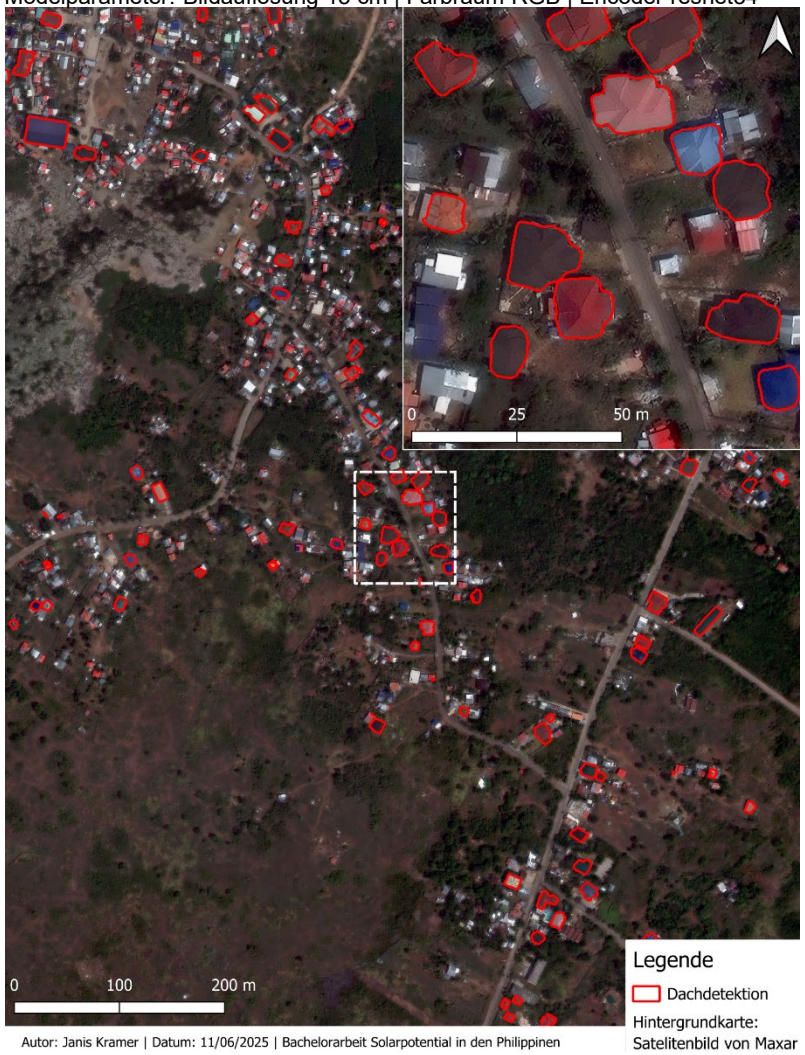

Modelparameter: Bildauflösung 15 cm | Farbraum RB+NIR | Encoder resnet34

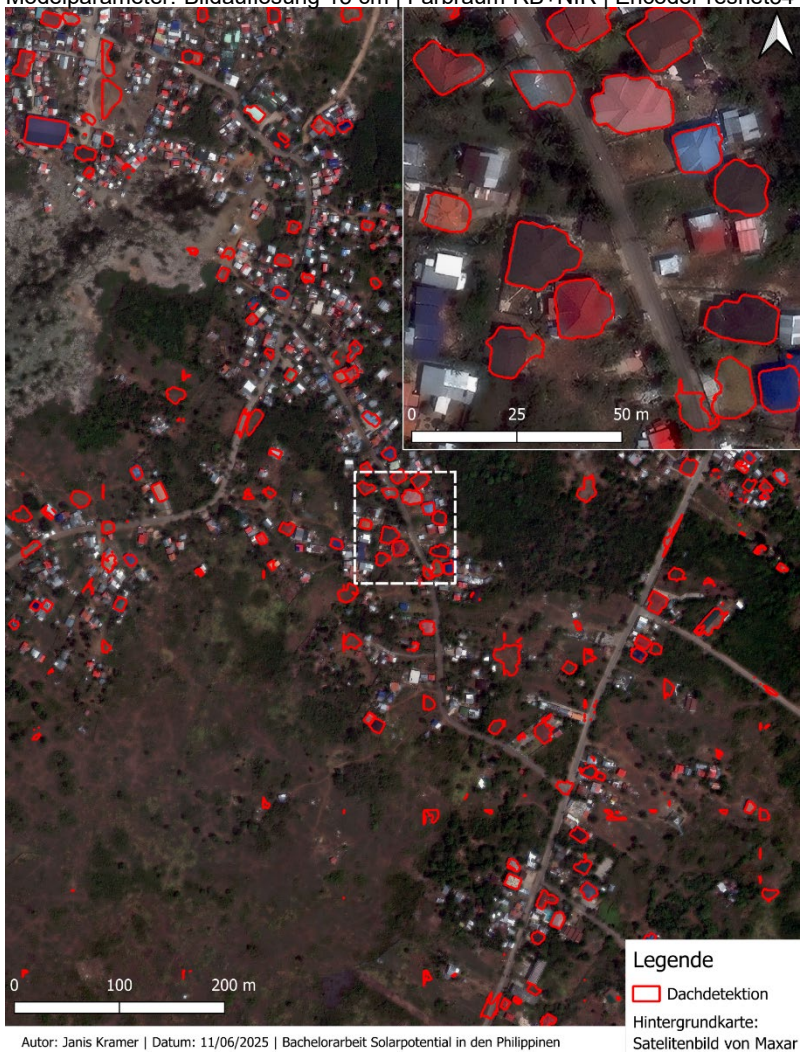

© IGEO FHNW

Dachsegmentierung in unterschiedlichen Regionen

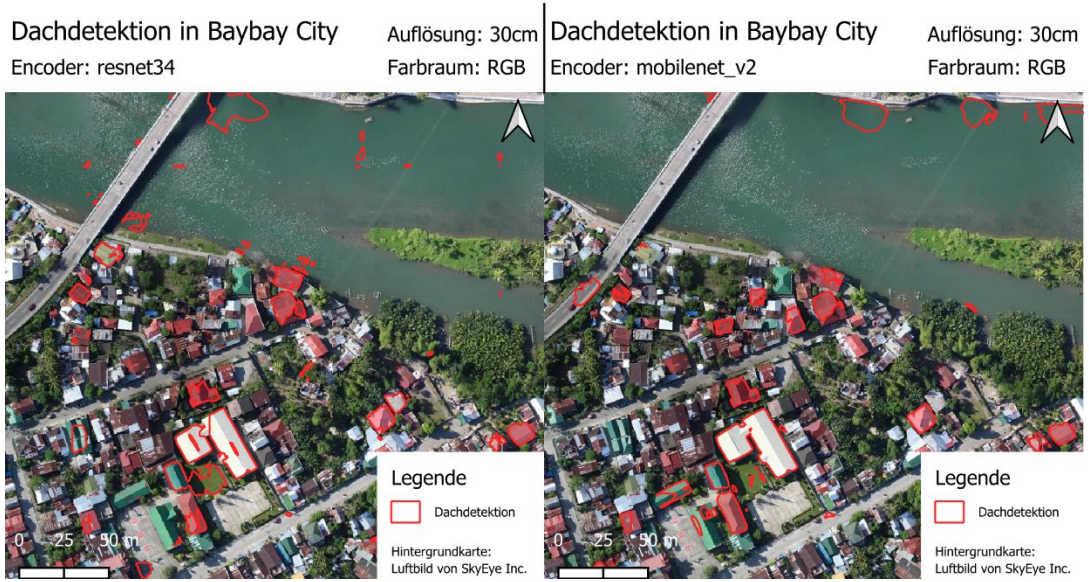

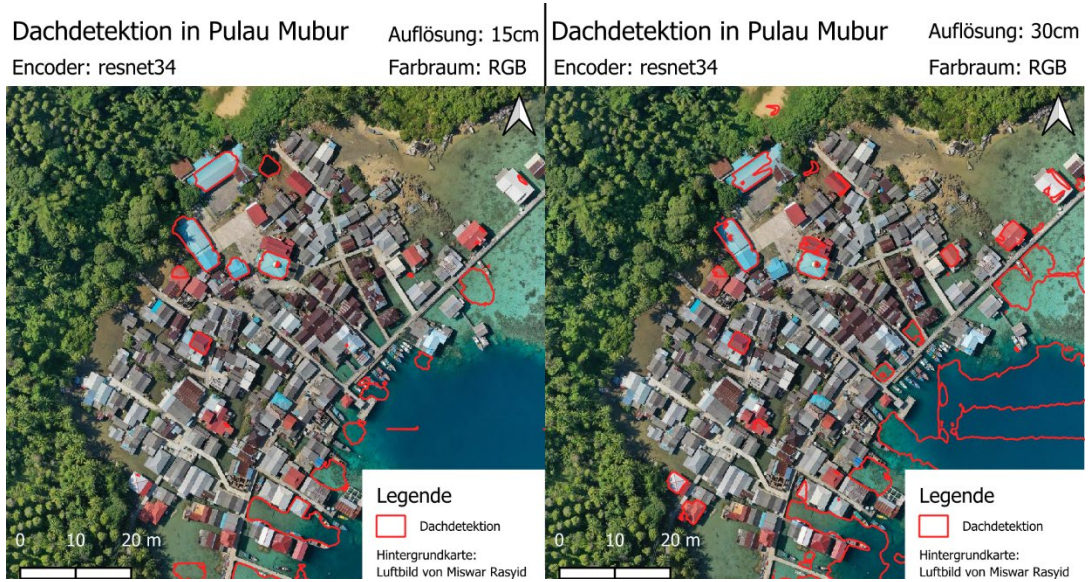

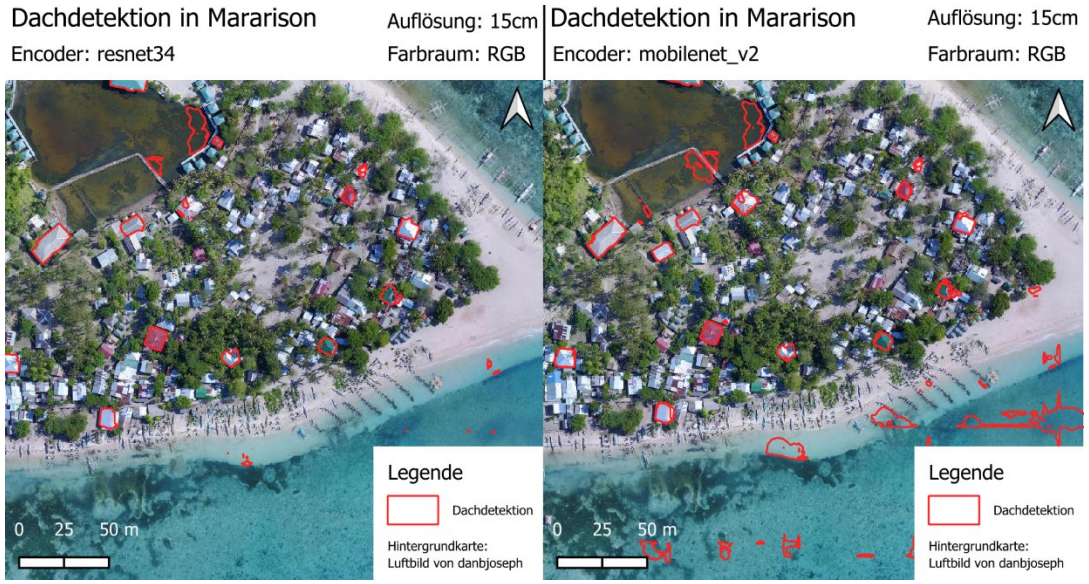

<u>Deep-Learning-Ansatz auf Open-Source-Drohnendaten</u>

Fehlklassifikationen von Wasserflächen

Gute Segmentierung von gewissen Dachflächen

Resnet34 und Mobilenet_v2 erzielen ähnliche Ergebnisse

Kleiner GSD liefern visuell bessere Ergebnisse wie grössere GSD

Resultate der Dachsegmentierung

<u>Vergleich mit den Groundtruth Daten</u>

- Deep Learning im RGB-Farbraum erfüllt die Genauigkeitsansprüche von 80%
- Deep Learning im RBNIR-Farbraum hat zu geringe Präzision und Objektdetektion
- Pixelbasierter Ansatz erfüllt die Anforderungen nicht

Farbraum	Encoder / Methode	GSD [cm]	Overall Accuracy [%]	Precision [%]	Recall [%]	F1-score [%]	Objektdetektion [%]
RGB	resnet34	15	99.1	89.0	89.9	89.5	88.8
RGB	resnet34	30	99.1	87.9	90.3	89.1	90.9
RGB	resnet34	45	99.0	87.4	90.3	88.8	90.5
RGB	mobilenet	15	99.0	88.6	88.8	88.7	87.1
RGB	mobilenet	30	99.0	88.8	87.9	88.3	84.1
RGB	mobilenet	45	98.9	88.1	86.7	87.4	81.7
RBNIR	resnet34	15	96.9	59.4	83.2	69.3	76.9
RBNIR	resnet34	30	97.6	65.5	90.7	76.1	89.0
RBNIR	resnet34	45	97.6	65.5	90.7	76.1	64.6
RBNIR	mobilenet	15	97.4	64.8	83.3	72.9	75.0
RBNIR	mobilenet	30	98.2	77.3	80.1	78.7	68.9
RBNIR	mobilenet	45	97.8	71.8	79.9	75.6	67.7
RGBNIR	Pixelbasiert	15	96.4	57.6	59.4	58.5	50.1
RGBNIR	Pixelbasiert	30	96.7	61.4	56.4	58.8	46.1
RGBNIR	Pixelbasiert	45	95.8	50.2	61.9	55.4	57.0

<u>Verteilung der Pixel</u>

- Ungefähr 27-mal so viel Hintergrund wie Vordergrundpixel
- Gesamtgenauigkeit nicht aussagekräftig

	Pred BG	Pred FG
Actual BG	82504370	676029
Actual FG	612284	3072933

Diskussion der Dachsegmentierung

Pixelbasierter Ansatz

- Viele Dächer werden nicht erkannt (verschiedene Rottöne und braune Dächer)
- Unpräzisere Segmentierung

Deep Learning Ansatz auf den RB+NIR-Daten

- Gute Dachdetektion
- Fehlklassifikationen von Vegetation und Strassenflächen
- Teilweise systematische Fehler

Deep Learning Ansatz auf den RGB-Daten

Erreicht alle geforderten Ziele mit einer sauberen Segmentierung der Dachflächen

© IGEO FHNW

Ausblick und weiter Anwendungen

Bachelorarbeit «Solarpotenzial auf den Philippinen» zeigt den Proof of Concept für die Dachsegmentierung mit einer U-Net-Architektur

<u>Umsetzung für die Lokale Anwendung</u>

Anwendung der aktuellen Modelle auf grössere Testgebiete

Training eines allgemeingültigen Modells

- Definition der Datengrundlagen
- Erweiterung der Trainingsdatengrundlagen

Quelle: Google Maps (2025): https://www.google.com/maps [Stand: März 2025].

Quelle: Google Maps (2025): https://www.google.com/maps [Stand: März 2025].