

KI zur Erfassung von Strassenschäden aus Mobile Mapping Bilddaten

Bachelor – Thesis 12 / 2024

Ausgangslage

- Auf Autobahnen und Regionalstrassen werden Fahrzeuge eingesetzt, die mit Sensoren und Kameras ausgestattet sind (Abb. 1);
- Auf kommunalen Strassen erfolgt die Schadenserkenkung durch Fachleute entweder vor Ort oder durch Bildanalyse;
- Notwendigkeit der Automatisierung des Erkennungsprozesses auf kommunalen Strassen mit Hilfe von Fahrzeugen mit Kameras (Abb. 2).

Abb. 1: S.T.I.E.R Fahrzeug von Firma Lehmann & Partner (Lehmann & Partner 2021).



Abb. 2: Ein Fahrzeug der Firma Infra3D zur Erfassung von Strassenbildern. (Infra3D 2022)

Lehmann & Partner (2021): Mobile Erfassung über Messsysteme. In: Lehmann & Partner aus Erfurt 2021. <https://www.lehmann-partner.de/messsysteme-mobile-erfassung/>, 11.4.2024.
Infra3D (2022): Il cantone del Grigione aggiorna i dati delle immagini Infra3D dell'intera rete stradale cantonale. 2022. <https://www.infra3d.ch/it/infra3d-fhnw/>


11. Juni 2024

Autor: Alex Burà

© IGEO FHNW

Ziel

Das Forschungsprojekt KIVIS untersucht das Potenzial einer KI-basierten automatisierten Bildanalyse zur Bestimmung des Strassenzustands sowie zur Erkennung von Strassenschäden auf kommunalen Strassen.




11. Juni 2024

Autor: Alex Burà

© IGEO FHNW

Methodik



11. Juni 2024

Autor: Alex Burà

© IGEO FHNW

Resultate

Jedes Modell wurde getestet.

Für jedes Modell wurde Folgendes berechnet:

Konfusionsmatrizen:

- 2x2 ohne Berücksichtigung der Klassen
- 5x5 mit Unterteilung nach Klasse

Beurteilungsmetriken:

- Precision
- Recall
- F1-Score
- Accuracy
- Klassengenauigkeit

Konfusionsmatrix ohne Berücksichtigung der Klassen		
Model Prediction	Ground Truth	
	Schaden	Nicht Schaden
Schaden	603	83
Nicht Schaden	275	

Precision	0.88	Accuracy	0.63
Recall	0.69	F1-Score	0.77

Abb. 3: Konfusionsmatrix des besten Modells und berechnete Metriken.

Diskussion

- Es wurden drei Modelle ausgewählt: Das Erste wurde mit allen Bildern trainiert (CN_), das Zweite nur mit Bildern aus Norwegen (N_) und das Dritte nur mit Bildern aus der Tschechischen Republik (C_).
- Das Modell, das nur mit tschechischen Bildern (C_) trainiert wurde, erzielt deutlich schlechtere Ergebnisse.
- Wang et al. (2018) erzielten einen F1-Score von 0,579. Die ersten beiden Modelle in der nebenstehenden Tabelle erzielen leicht bessere Resultate.

Modell	Precision	Recall	Accuracy	F1-Score
CN_0000_01_50E	0.75	0.49	0.54	0.59
N_00001_10E_8	0.83	0.46	0.59	0.59
C_50E_5	0.29	0.30	0.21	0.29

Tab. 1: Für die drei besten Modelle (je nach pro Kategorie) berechnete Metriken

Wang, Yankai J., Ding, Ming, Kan, Shichao, Zhang, Shilong und Lu, Chanyue (2018): Deep Proposal and Detection Networks for Road Damage Detection and Classification. <https://arxiv.org/abs/1811.05946>

11. Juni 2024

Autor: Alex Burà

© IGEO FHNW

Test an Schweizer Bildern

Die drei Modelle wurden dann an Schweizer Bildern getestet, die von der Firma Infra3D bereitgestellt wurden. Zwei Modelle (CN_000001_50E und N_00001_10E_8) können Schäden auf Schweizer Bildern zuverlässig erkennen. Es gibt jedoch Fälle, in denen das Modell Fehler macht (siehe nächste Folie), deshalb ist ein weiteres Nachtraining erforderlich.

Abb. 5 und 6: Beispiele für korrekte Erkennungen auf Bildern aus der Gemeinde Lenggries (AG), (Infra3D)



11. Juni 2024

Autor: Alex Burà

© IGEO FHNW

Ausgangslage

- Auf Autobahnen und Regionalstrassen werden Fahrzeuge eingesetzt, die mit Sensoren und Kameras ausgestattet sind (Abb. 1);
- Auf kommunalen Strassen erfolgt die Schadenserkennung durch Fachleute entweder vor Ort oder durch Bildanalyse;
- Notwendigkeit der Automatisierung des Erkennungsprozesses auf kommunalen Strassen mit Hilfe von Fahrzeugen mit Kameras (Abb. 2).

Abb. 1: S.T.I.E.R Fahrzeug von Firma Lehmann & Partner (Lehmann & Partner 2021).




Abb. 2: Ein Fahrzeug der Firma iNovitas zur Erfassung von Strassenbildern. (iNovitas 2022)

Lehmann & Partner (2021): *Mobile Erfassung über Messsysteme*. In: Lehmann & Partner aus Erfurt. 2021. [<https://www.lehmann-partner.de/messsysteme-mobile-erfassung/>; 11.4.2024];


iNovitas (2022): Il cantone dei Grigioni aggiorna i dati delle immagini Infra3D dell'intera rete stradale cantonale. 2022. [<https://www.inovitas.ch/it/ditta/newsfeed-it/news>].

Ziel

Das Forschungsprojekt KIVIS untersucht das Potenzial einer KI-basierten automatisierten Bildanalyse zur Bestimmung des Strassenzustands sowie zur Erkennung von Strassenschäden auf kommunalen Strassen.



Methodik



Methodik

1. Der Datensatz muss:

- im Internet verfügbar sein;
- mit der Schweizer Norm kompatibel sein;
- Bilder enthalten, die denen aus der Schweiz ähneln.

2. Klassen wurden anhand des Datensatzes und der Schweizer Norm ausgewählt:

- D00 – Längsriss;
- D10 – Querriss;
- D20 – Netzriss;
- D40 – Schlagloch.

3. Die Daten wurden wie folgt vorbereitet:

- Die Verteilung zwischen den Klassen war nicht optimal;
- Einige Bilder wurden gespiegelt, um die Anzahl der Netzrisse und Schlaglöcher zu erhöhen;
- Die Bilder, die nur Längsrisse enthalten, wurden gelöscht;
- Alle Bilder wurden so geschnitten, dass ein Quadrat entstand.

Methodik

4. Training:

- Optimizer: Adam;
- Loss Function: Cross-entropy;
- Epochen, Batch-Size, Learning Rate so einstellen, dass Overfitting und Spitzen vermieden werden;
- Mehrere Versuche durchführen;
- Train und Validation Loss beurteilen.

5. Inference:

- Bilder zeigen, die das Modell noch nie gesehen hat;
- Das Modell gibt Bounding Boxes, Name der Klasse und «Score» zurück;
- Vergleich zwischen Output des Modells und «Ground Truth»;
- Man kontrolliert, wie gut das Modell auf neuen Bildern funktioniert.

Resultate

Jedes Modell wurde getestet.

Für jedes Modell wurde Folgendes berechnet:
Konfusionsmatrizen:

- 2x2 ohne Berücksichtigung der Klassen
- 5x5 mit Unterteilung nach Klasse

Beurteilungsmetriken:

- Precision
- Recall
- F1-Score
- Accuracy
- Klassengenauigkeit

Konfusionsmatrix ohne Berücksichtigung der Klassen			
		Ground Truth	
		Schaden	Nicht Schaden
Model Prediction	Schaden	603	83
	Nicht Schaden	276	

Precision	0.88	Accuracy	0.63
Recall	0.69	F1-Score	0.77

Abb. 3: Konfusionsmatrix des besten Modells und berechnete Metriken.

Resultate

Die Klassenunterteilung wurde berücksichtigt.

Precision ist immer besser als Recall, was bedeutet, dass das Modell, wenn es etwas erkennt, oft richtig liegt.

Betrachtet man die Klassengenauigkeit, so stellt man fest, dass die ersten beiden Klassen gut sind, während die D20 und D40 schlechter sind.

		Konfusionsmatrix mit Klassen (IoU>0.1)				
		Ground Truth				
		D00	D10	D20	D40	Not
Model Prediction	D00	415	24	21	7	61
	D10	10	101	5	0	0
	D20	6	0	21	2	0
	D40	0	0	0	17	1
	Not	129	43	34	44	-

Legende: D00 – Längsriss; D10 – Querriss; D20 – Netzriss; D40 – Schlagloch

Average Precision D00	0.79	Recall D00	0.74
Average Precision D10	0.87	Recall D10	0.60
Average Precision D20	0.72	Recall D20	0.26
Average Precision D40	0.94	Recall D40	0.24
mean AP (mAP)	0.83	Mean Recall	0.46
F1-Score	0.59	Accuracy	0.59
Klassengenauigkeit D00	0.76		
Klassengenauigkeit D10	0.74		
Klassengenauigkeit D20	0.49		
Klassengenauigkeit D40	0.59		

Abb. 4: Konfusionsmatrix des besten Modells und berechnete Metriken.

Diskussion

- Es wurden drei Modelle ausgewählt: Das Erste wurde mit allen Bildern trainiert (CN_), das Zweite nur mit Bildern aus Norwegen (N_) und das Dritte nur mit Bildern aus der Tschechischen Republik (C_).
- Das Modell, das nur mit tschechischen Bildern (C_) trainiert wurde, erzielt deutlich schlechtere Ergebnisse.
- Wang et al. (2018) erzielten einen F1-Score von 0,579. Die ersten beiden Modelle in der nebenstehenden Tabelle erzielen leicht bessere Resultate.

Modell	Precision	Recall	Accuracy	F1-Score
CN_000001_50E	0.75	0.49	0.54	0.59
N_00001_10E_8	0.83	0.46	0.59	0.59
C_50E_5	0.29	0.30	0.21	0.29

Tab. 1: Für die drei besten Modelle (eines pro Kategorie) berechnete Metriken.

Wang, Yanbo J.; Ding, Ming; Kan, Shichao; Zhang, Shifeng und Lu, Chenyue (2018): Deep Proposal and Detection Networks for Road Damage Detection and Classification. [<https://sci-hub.se/10.1109/bigdata.2018.8622599>].



Test an Schweizer Bildern

Die drei Modelle wurden dann an Schweizer Bildern getestet, die von der Firma Infra3D bereitgestellt wurden. Zwei Modelle (CN_000001_50E und N_00001_10E_8) können Schäden auf Schweizer Bildern zuverlässig erkennen. Es gibt jedoch Fälle, in denen das Modell Fehler macht (siehe nächste Folie), deshalb ist ein weiteres Nachtraining erforderlich.

Abb. 5 und 6: Beispiele für korrekte Erkennungen auf Bildern aus der Gemeinde Lenzburg (AG). (Infra3D)



Test an Schweizer Bildern



Legende: D00 – Längsriss; D10 – Querriss; D20 – Netzriss; D40 – Schlagloch




Abb. 7, 8, 9 und 10: Beispiele für einige fehlerhafte Erkennungen auf Bildern aus der Gemeinde Lenzburg (AG). (Infra3D)

Fazit und Ausblick

- Anwendung auf Infra3D-Daten vielversprechend;
- Die meisten Schäden werden erkannt, es gibt jedoch einige Fehldetektionen;

Nächste Schritte:

- Nachtraining unter Verwendung von Infra3D-Daten durchführen;
- Eventuell Schachtdeckel in eine eigene Klasse einordnen, damit das Modell versteht, dass es sich nicht um Schlaglöcher handelt;
- Das Ziel ist dann, Masken und nicht mehr Bounding Boxes zu detektieren (semantic segmentation).