Universität Bamberg

Promotionsvorhaben:

Aufbereitung, Analyse und Evaluierung von Mobile Laserscanning Daten mit Methoden der digitalen Geländemodellanalyse und tiefen neuronalen Faltungsnetzen im Kontext des kommunalen Straßeninfrastrukturmanagements

Dipl.-Geogr. Maximilian Sesselmann

Agenda

Agenda

1 Vorstellung des Projektes

2 Forschungsfragen

3 Ergebnisse

4 Aktueller Stand und nächste Schritte

5 Wissenschaftliche Aktivitäten

Vorstellung des Projektes

Über mich und mein Thema …

- Studium Dipl. Geographie Uni Bamberg
- Seit 2013: Mitarbeiter des R&D-Teams bei Lehmann+Partner GmbH
- nebenberufliches PhD-Projekt betreut von M. Möller, G. Schellmann, R. Bill
- Schlagworte: Straßenzustand, Mobiles Laserscanning, Deep Learning, GIS

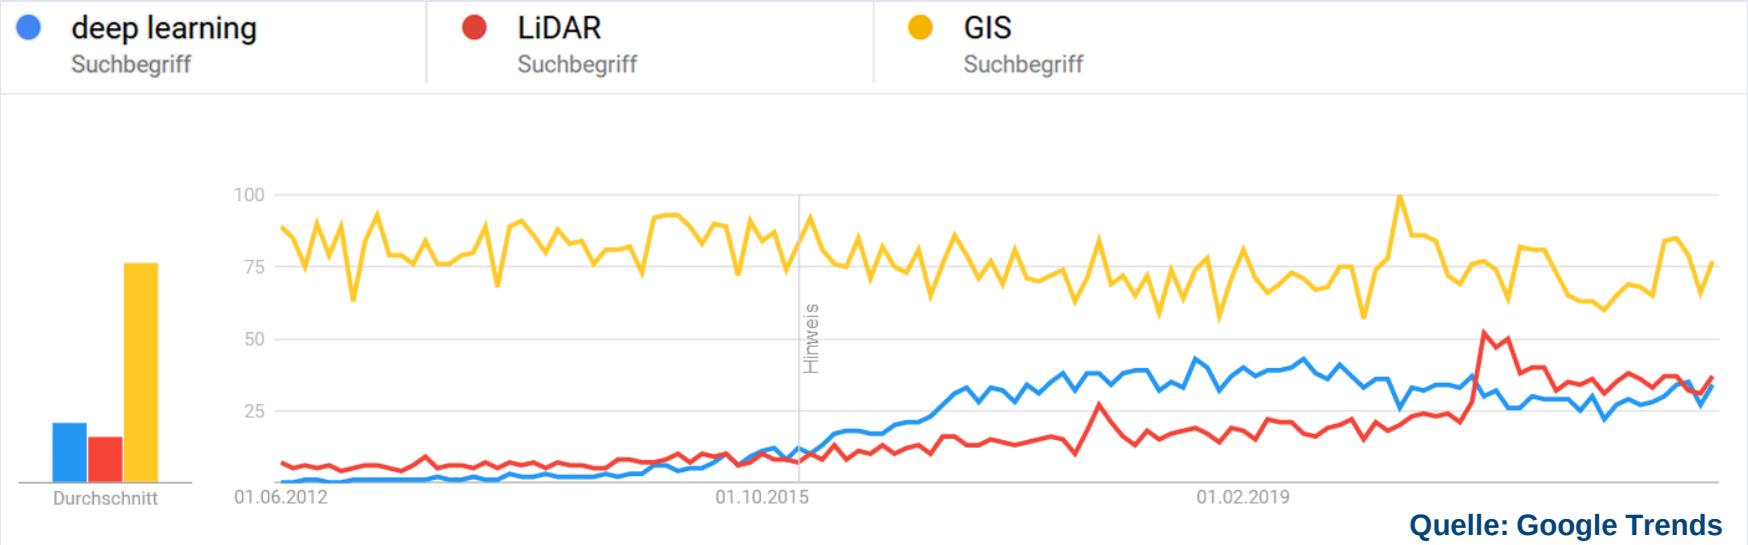

Kommunales Straßeninfrastrukturmanagement: Motivation (1/2)

- Mobilität von Personen und Gütern erfordert eine **effizient Verkehrsinfrastruktur**
- **Erhaltung der Verkehrsinfrastruktur** ist eine zentrale Aufgabe kommunaler Baulastträger
- Möglichst **detaillierte Straßenzustandsdaten** sind die Basis für **operative und strategische Entscheidungsprozesse** (optimaler Maßnahmenzeitpunkt, optimaler Mitteleinsatz, …)
- für den kommunalen Bereich existieren **Richtlinien (E EMI, FGSV AP9K)**, die sich an den für die Bundesautobahnen verbindlichen Regelwerke zur Zustandserfassung und -bewertung orientieren (ZTV ZEB Stb)

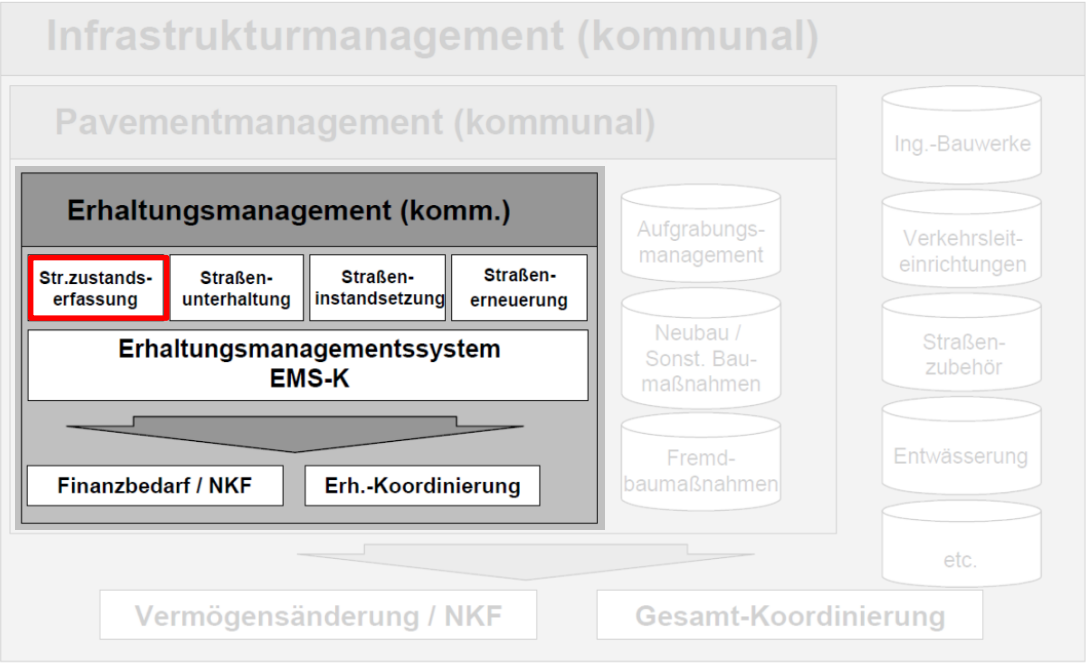

Kommunales Straßeninfrastrukturmanagement: Motivation (2/2)

- Unterscheidung: visuelle und **messtechnische Zustandserfassung und -bewertung**
- Einsatz von Mobile Mapping Systemen:
  - i. d. R. Laser-basierte Messung von Ebenheitsindikatoren (z. B. Spurrinnen)
  - i. d. R. Kamerabild-basierte Inspektion von Oberflächenschäden (z. B. Risse)
  - Keine Berücksichtigung der Oberflächenmorphologie bei der Aufnahme von Oberflächenschäden (nur Reflektanz-/Grauwertunterschiede als Schadensindikator)
  - passive Sensorik unterliegt Defiziten bei Schatten/Dunkelheit/Gegenlicht

- moderne **Mobile Laserscanning Systeme** ermöglichen es, digitale Topographien von Fahrbahnoberflächen schnell, flächendeckend und präzise zu erfassen → das Potential dieser Daten wird aber derzeit nicht ausgeschöpft
- Erhebliche Datenmengen und immenser Zeitbedarf für manuelle Inspektion + wiederkehrend-monotone Tätigkeiten → hohes Automatisierungspotential

Mobile Laserscanning System I.R.I.S

- Kinematisches Multisensorsystem zur bildhaften und dreidimensionalen Erfassung des Straßenraumes
- Relevante Komponenten:
  - Inertiales Positionierungssystem Applanix POS LV 420
  - Fraunhofer IPM Pavement Profile Scanner

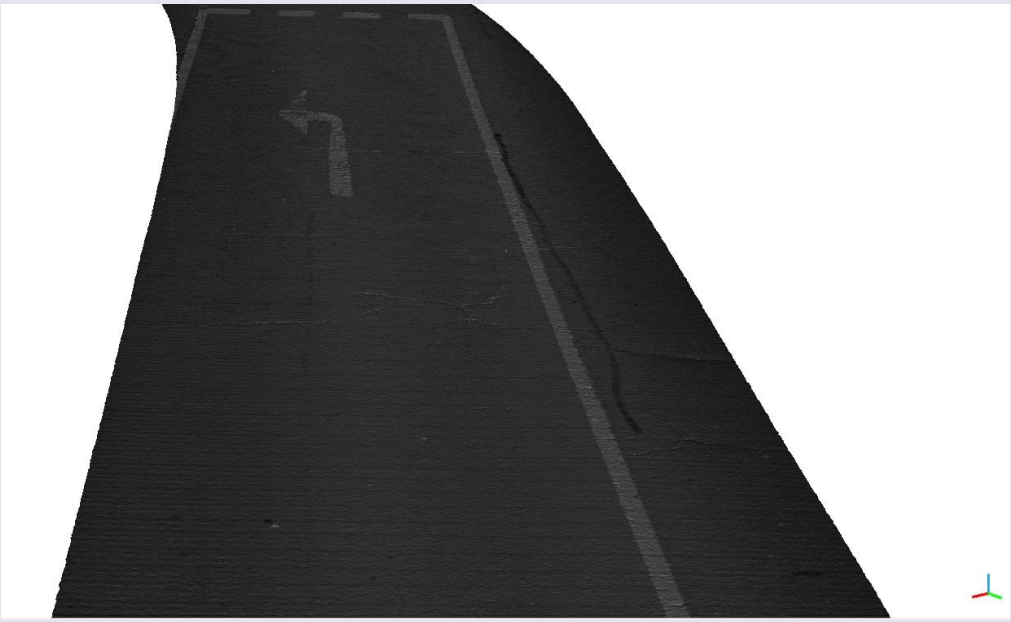

Mobile Laserscanning System I.R.I.S : Pavement Profile Scanner

- Wellenlänge: 1550 nm
- Auflösung der Entfernungsmess.: < 1mm
- Öffnungswinkel: 70°
- Scanbreite: ≈ 4.2 m
- 1 Mio. Punkte / Sekunde
  mit ≈ 920 Punkten / Profil
- Punktabstand auf Profil: ≈ 4.5 mm
- Profilabstand bei 20 – 50 km/h: 8 – 18 mm

→ sehr genaue Oberflächenerfassung und hohe Datendichte

→ **radiometrische und geometrische** Information für die Schadenserkennung

→ Keine negativen Einflüsse durch vorherrschende Lichtverhältnisse

→ **direkt georeferenzierte Ergebnisse**: Straßenschäden als einzelne Geoobjekte

Vision und These

- **These:** es bestehen Analogien zwischen Formelementen des Georeliefs und Oberflächenmerkmalen einer Fahrbahnoberfläche

  → Ein kombinierter Ansatz aus **digitaler Geländemodellanalyse** und **Deep Learning** ermöglicht eine **automatische, differenzierte und georeferenzierende Zustandsbewertung von Oberflächenschäden** auf Basis von Mobile LiDAR Daten

- **Vision:** Erfassung von **Ebenheit <u>und</u> Oberflächenschäden** mit **<u>einem</u> LiDAR Sensor**

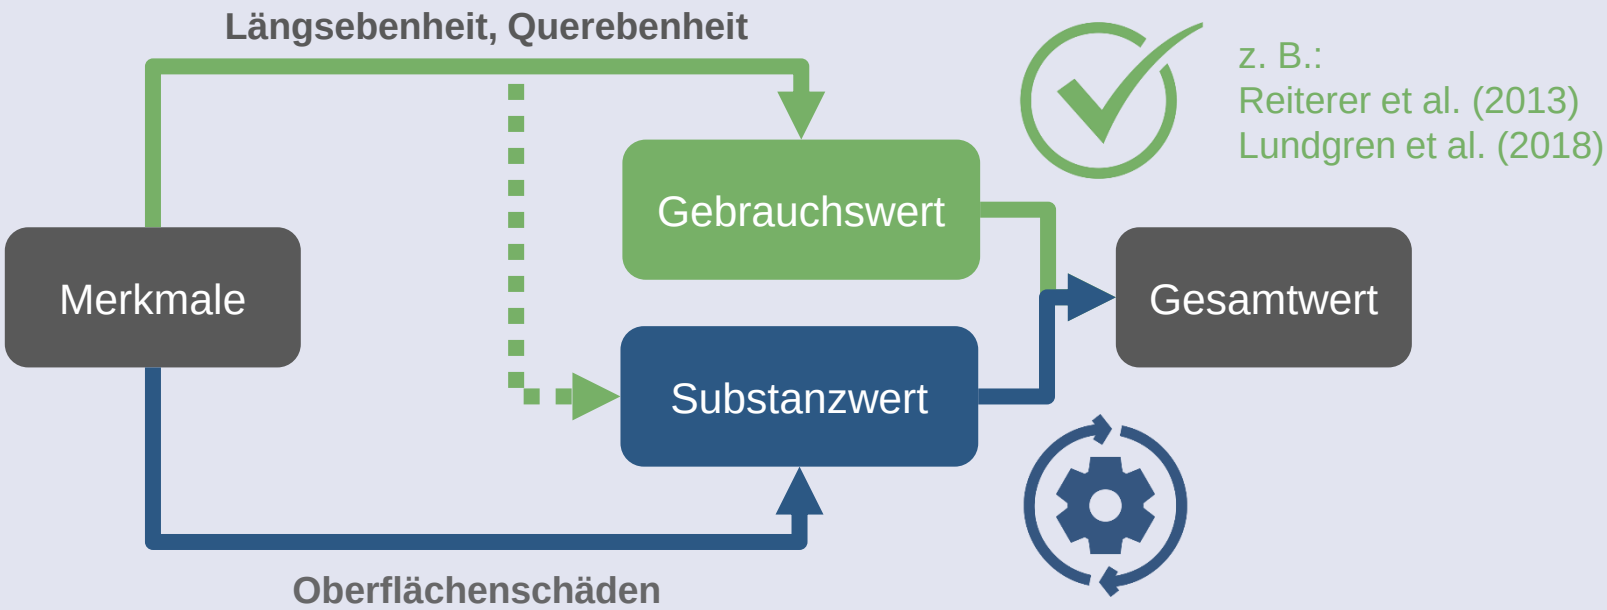

Forschungsfragen

Forschungsfragen

- Können alle relevanten Schadenstypen aus den LiDAR Daten detektiert werden?
- Wie genau lassen sich die Laserscans und daraus abgeleitete Schäden verorten?
- Wie genau kann ein Objekt im Laserscan abgebildet werden?
- Welche räumliche Interpolationsmethode ist für die gegebene Problemstellung und das Datenmaterial am besten geeignet?
- Bis zu welcher Breite lassen sich Schadstellenstrukturen im Laserscan erkennen?
- Welches sind geeignete Hyperparameter für den Trainingsprozess (DeepLabv3+)?
- Wie stark streut der Trainingsprozess zur Erzeugung eines Deep Learning Modells?
- Welche geomorphometrische Vorverarbeitung von Oberflächenmodellen ist zur Erkennung von Straßenschäden geeignet?
- Wie leistungsfähig sind die trainierten Modelle?
- Wie leistungsfähig ist ein Deep Learning basierter, automatischer Inspektionsprozess im Vergleich zu einer konventionell-visuellen Inspektion im kommunalen Straßennetz?

Ergebnisse

Untersuchung: Eignung des Datenmaterials zur Schadenanalyse

- **Frage:** Können alle relevanten Schadenstypen aus den LiDAR Daten detektiert werden?
- Ablauf:
  - Anforderungsanalyse: Richtlinien Zustandserfassung (E EMI, AP 9 K, ZTV ZEB Stb)
  - visuell-manueller Abgleich von Mess- und Zustandsdaten
  - Erstellung eines Objektkatalogs für das spätere Labelling von Trainingsdaten
- **Ergebnis:** Alle bewertungsrelevanten Schadensarten für Asphalt-Bauweisen können aus den verfügbaren Datenkanälen zuverlässig detektiert werden

Tabelle 4: Zustandsindikatoren und Zustandsgrößen der Zustandsmerkmale Substanz (Oberfläche) von Fahrbahnen in Asphaltbauweise

Zustandsmerkmal	Zustandsindikator	Zustands-größe
Risse	prozentualer Anteil der von Rissen betroffenen Fläche [%]	RISS
offene Nähte und Fugen	Gesamtlänge der offenen Nähte/Fugen [m]	ONF
aufgelegte Flickstellen	prozentualer Flächenanteil der aufgelegten Flickstellen [%]	AFLI
eingelegte Flickstellen	prozentualer Flächenanteil der eingelegten Flickstellen [%]	EFLI
sonstige Oberflächen-schäden:	prozentualer Anteil der Schadensflächen ohne Risse und Flickstellen [%]	OFS
– Ausbrüche	prozentualer Anteil der von Ausbrüchen betroffenen Fläche [%]	AUS
– Ausmagerung	prozentualer Anteil der von Ausmagerung betroffenen Fläche [%]	AMA
– Bindemittelanreicherungen	prozentualer Flächenanteil mit Bindemittelanreiche-rungen [%]	BIN

Quelle:
Arbeitspapier AP 9
Management der Straßenerhaltung
Reihe K: Kommunale Straßen
Abschnitt K 2 Zustandserfassung
Unterabschnitt K 2.1

Untersuchung: absolute Genauigkeit der MLS-Daten

- **Frage:** wie genau lassen sich die Laserscans und daraus abgeleitete Objekte bzw. Schäden verorten?
- Ablauf:
  - Terrestrische Passpunktaufnahme (RTK und Tachymeter) für zwei Testfelder (Szenario „Außerorts“ und Szenario „Innerorts“)
  - Post-Processing der Realtime-Trajektorie unter Zuhilfenahme eines virtuellen Referenzstationsnetzes
  - Abgleich der Passpunktkoordinaten

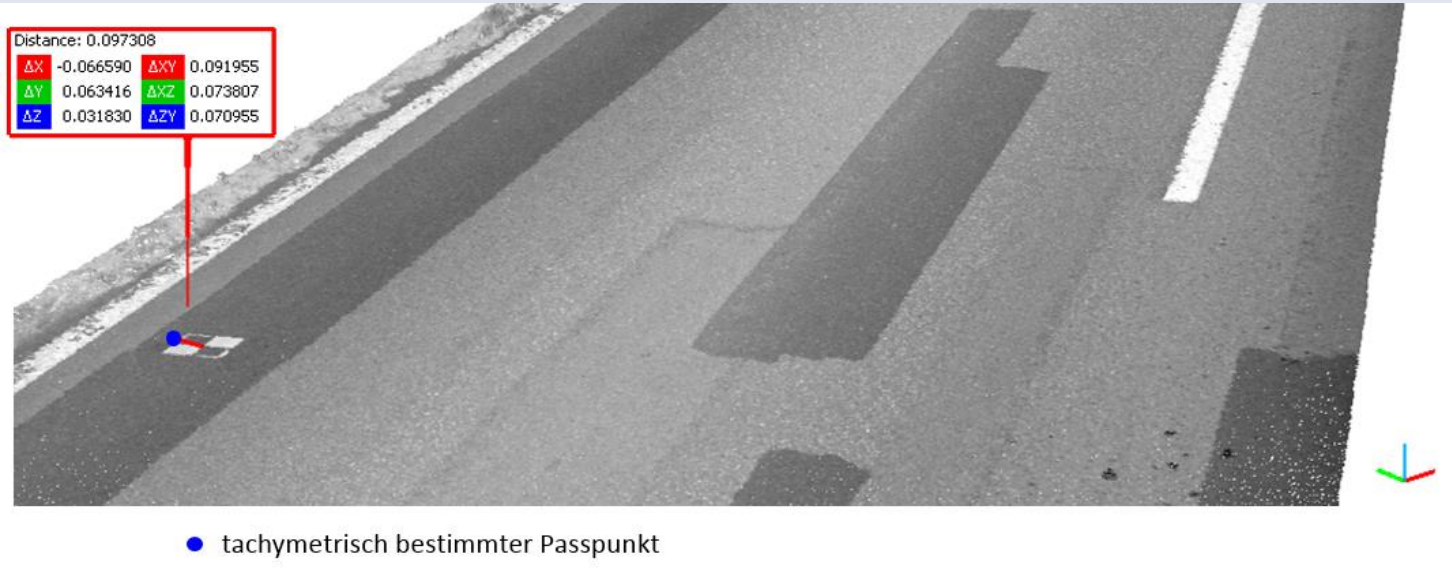

Untersuchung: absolute Genauigkeit der MLS-Daten

- **Ergebnis:** Mittlere 3D-Abweichung von Passpunktmarkierungen im Laserscan zur terrestrisch bestimmten Referenz: 0.08 m (std-dev: 0.02 m | max: 0.12 m)

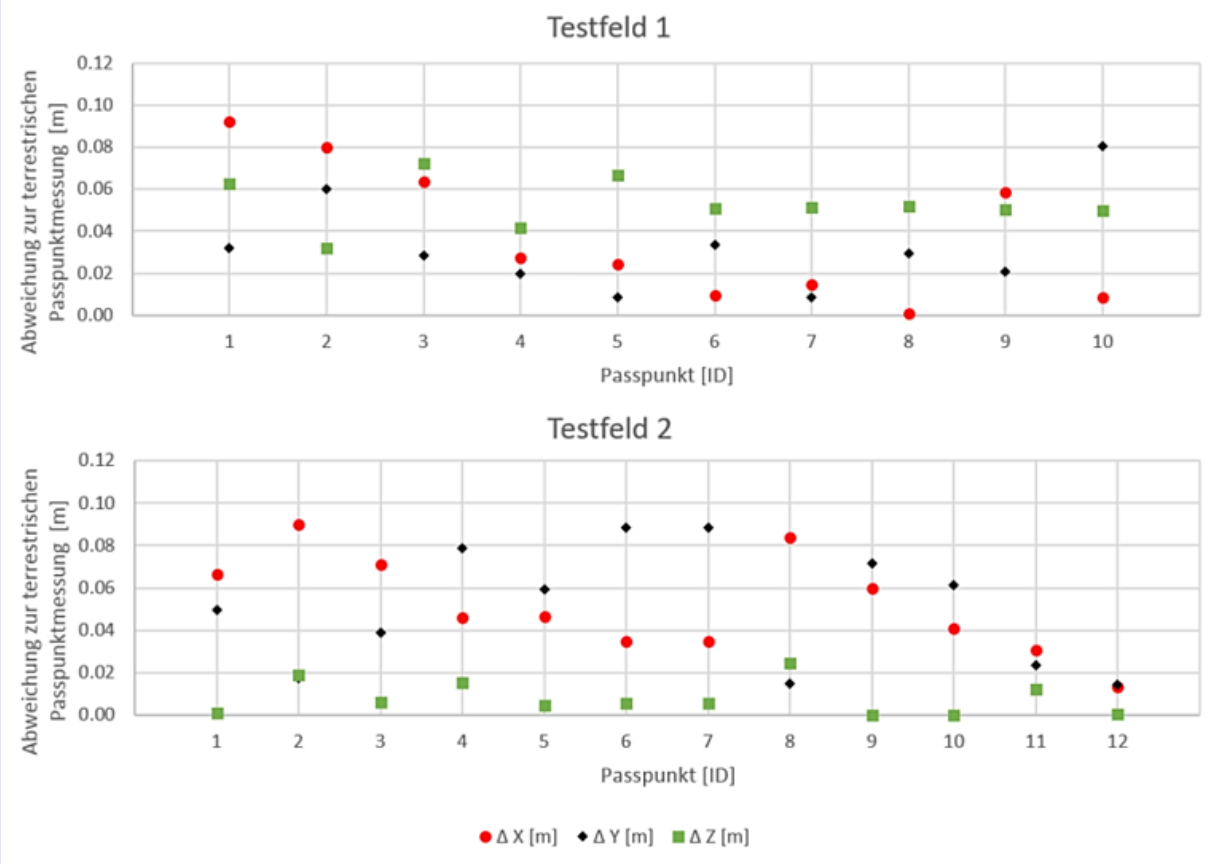

Szenario „Außerorts“

Lagegen. (Mittelw.):	35 mm
Lagegen. (Standardabw.):	28 mm
Höhengen. (Mittelw.):	52 mm
Höhengen. (Standardabw.):	12 mm

Szenario „Innerorts“

Lagegen. (Mittelw.):	51 mm
Lagegen. (Standardabw.):	26 mm
Höhengen. (Mittelw.):	8 mm
Höhengen. (Standardabw.):	9 mm

Untersuchung: relative Genauigkeit der MLS-Daten

- **Frage:** Wie genau kann ein Objekt im Laserscan abgebildet werden?
- Ablauf:
  - 3D-Modellierung des Prüfkörpers als Referenz (zertifizierte LCMS2 Kalibrier-Platte)
  - 8-fach Messung eines Prüfkörpers
  - TIN-Vermaschung mittels Delauney-Triangulation
  - ICP-Matching auf Referenzmodell
  - Differenzbildung: gematchter Scan zu Referenzmodell
- **Ergebnis (1/2):** die durch das Messsystem verursachte Streuung (RMSE) liegt im Bereich <=1.31 mm für die gesamte Prüfkörperoberfläche

Untersuchung: relative Genauigkeit der MLS-Daten

- Ausrundungs- bzw. Glättungseffekt an Kanten durch Mischphasen
- **Ergebnis (2/2):** die durch das Messsystem verursachte Streuung (RMSE) liegt im Bereich <=0.84 mm (nur horizontale und geneigte Oberflächen des Prüfkörpers)

Messung [Nr.]	RMSE [mm] ICP Registrierung *	RMSE [mm] Alle Oberflächen	RMSE [mm] horizontale Oberflächen	RMSE [mm] geneigte Oberflächen
1	1.91	1.28	0.71	0.80
2	2.15	1.30	0.69	0.83
3	1.92	1.28	0.67	0.80
4	1.89	1.31	0.69	0.81
5	1.73	1.21	0.67	0.77
6	1.76	1.19	0.67	0.84
7	1.86	1.23	0.70	0.84
8	1.90	1.22	0.68	0.75

* Tool-intern nur auf einen Teil der registrierten Daten berechnet

Ergebnisse

Untersuchung: Vergleich von räumlichen Interpolationsmethoden zur Oberflächenmodellierung

- Deep Learning Ansätze sind effektiv auf Matrix-Daten (Oberflächeninterpolation)
- **Frage:** welche räumliche Interpolationsmethode ist für die gegebene Problemstellung und das Datenmaterial am besten geeignet?
- Ablauf:
  - Vergleich deterministischer Verfahren anhand von zwei repräsentativen Testarealen
  - relevante Kriterien: Erhaltung der Oberflächeneigenschaften, geringe Parametersensitivität, Rechenkomplexität, visuelles Erscheinungsbild
  - Identifikation der optimalen Methode in Anlehnung an Nutzwertanalyse

Merkmal	Testareal 1	Testareal 2
Mittlere Punktdichte (r = 0.03m)	79	52
Übersichtsbild (Schrägansicht TIN)	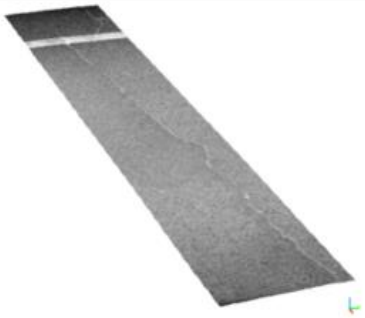	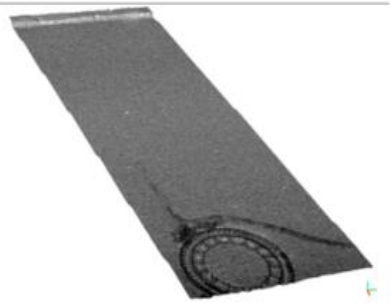

Untersuchung: Vergleich von räumlichen Interpolationsmethoden zur Oberflächenmodellierung

- **Ergebnis:**
  - höchster Score für die lineare Natural Neighbors Methode (wenn auch nicht beste vertikale Genauigkeit im Versuch)
  - Unterschied zum RMSE des akkuratesten Verfahrens beträgt < 0.12 mm
  - Vorteile: Schnelligkeit und geringer Aufwand für Parametrierung

Methode (Parameter)	RMSE Testfeld 1 [mm]	RMSE Testfeld 2 [mm]	Parameter [Anzahl]	Rechenzeit [s]	Score [0 bis 100]
NN-Linear	1.01	1.46	0	5	100
NN-Sibson	0.98	1.42	0	10	97
NN-NonSibson	0.96	1.39	0	12	96
IDW ($\beta = 2$)	0.95	1.44	3	7	87
IDW ($\beta = 4$)	1.03	1.49	3	7	87
IDW ($\beta = 6$)	1.09	1.54	3	7	87
IDW-VR ($\beta = 2$)	1.00	1.58	4	7	83
IDW-VR ($\beta = 4$)	1.07	1.51	4	7	83
IDW-VR ($\beta = 6$)	1.13	1.54	4	7	83
MQS ($n_q = 5, n_w = 7$)	26.11	40.83	2	7	30
MQS ($n_q = 9, n_w = 13$)	2.88	13.96	2	10	77
MQS ($n_q = 13, n_w = 19$)	1.38	7.69	2	13	83
MQS ($n_q = 16, n_w = 23$)	1.17	6.94	2	15	82
MQS ($n_q = 23, n_w = 33$)	1.09	2.83	2	21	83
TPS ($\lambda = 0.0$)	1.07	1.79	3	48	65
TPS ($\lambda = 0.0001$)	1.07	1.74	3	49	65
TPS ($\lambda = 0.001$)	1.06	1.61	3	48	66
TPS ($\lambda = 0.01$)	1.02	1.48	3	48	66
TPS ($\lambda = 0.1$)	0.95	1.37	3	47	66
TPS ($\lambda = 0.5$)	0.92	1.35	3	47	66
TPS-VR ($\lambda = 0.0$)	1.19	1.81	4	20	76
TPS-VR ($\lambda = 0.0001$)	1.19	1.77	4	19	77
TPS-VR ($\lambda = 0.001$)	1.18	1.64	4	19	77
TPS-VR ($\lambda = 0.01$)	1.14	1.54	4	19	77
TPS-VR ($\lambda = 0.1$)	1.04	1.43	4	20	77
TPS-VR ($\lambda = 0.5$)	0.98	1.39	4	19	77

Untersuchung: Erkennbarkeit von Oberflächendiskontinuitäten

- **Frage:** bis zu welchem Ausmaß können Oberflächendiskontinuitäten im Oberflächenmodell identifiziert werden?
- Ablauf:
  - Prüfkörper mit definierten Spaltbreiten (1 mm bis 30 mm)
  - 3D Scan bei verschiedenen Geschwindigkeiten (30 und 50 km/h)
  - 3D Scan verschiedener Ausrichtungen des Prüfkörpers
  - Interpolation der 3D Punktwolken zu 2.5D Oberflächenmodellen (Raster)
  - Visuelle Inspektion der Oberflächenmodelle
  - Ermittlung des Anteils erkennbarer Spalten (verschiedene Szenarien)

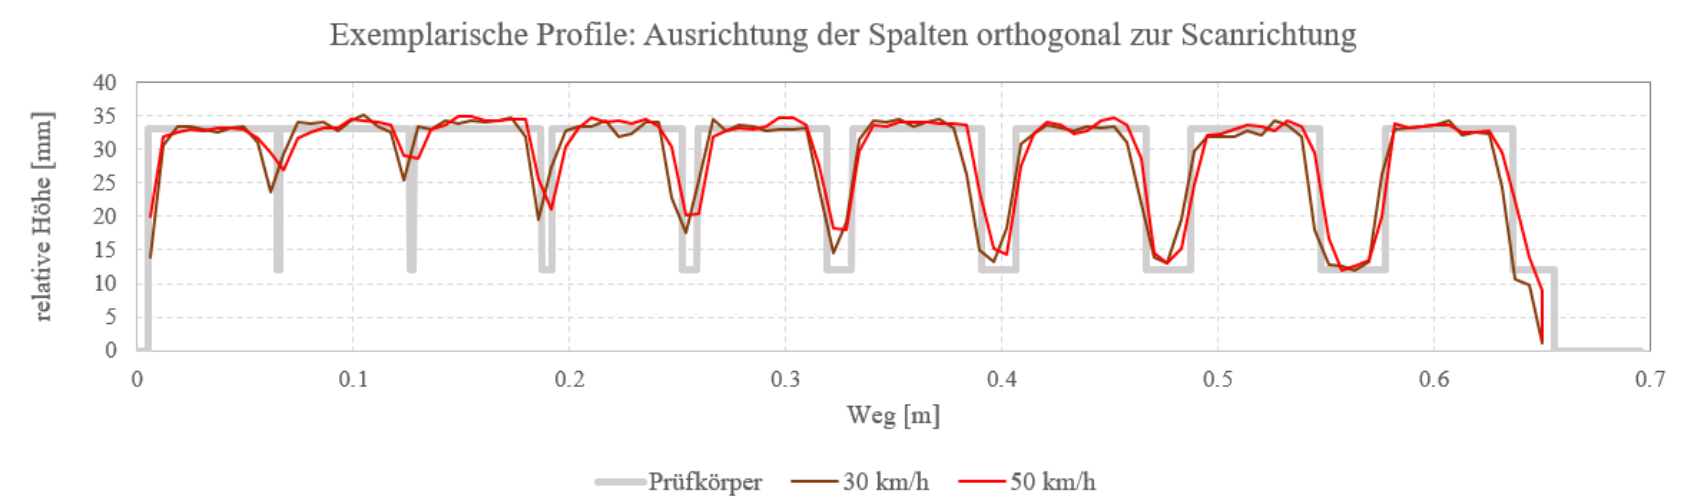

Untersuchung: Erkennbarkeit von Oberflächendiskontinuitäten

- **Ergebnis:**
  - >= 7 mm breite Spalten: sehr sicher / vollständig detektierbar
  - 5 mm breite Spalten: sicher / überwiegend vollständig detektierbar
  - <= 2 mm breite Spalten: abhängig von Ausrichtung/Geschwindigkeit detektierbar

    (Vorteil: orthogonale Ausrichtung & reduzierte Geschwindigkeit)

Prozentualer Anteil der erkannten Spaltlänge
(Mittelwert und Standardabweichung über drei Wiederholungsmessungen)

Szenario / Spaltbreite [mm]	Erfassungsgeschwindigkeit: 30 km/h		Erfassungsgeschwindigkeit: 50 km/h	
	Ausrichtung: parallel	Ausrichtung: orthogonal	Ausrichtung: parallel	Ausrichtung: orthogonal
1	46 (6)	80 (17)	26 (18)	38 (20)
2	60 (13)	100 (0)	43 (3)	100 (0)
5	64 (4)	100 (0)	64 (2)	100 (0)
7	99 (1)	99 (1)	98 (2)	98 (1)
10	100 (0)	99 (1)	98 (2)	100 (0)
15	100 (0)	100 (0)	100 (0)	100 (0)
20	100 (0)	100 (0)	100 (0)	100 (0)
30	100 (0)	100 (0)	100 (0)	100 (0)

Allgemeines: Untersuchungen zu Deep Learning (1/2)

- Arbeitsumgebung: Tensorflow mit NVIDIA GeForce RTX 2080 Ti
- Festlegung: Training von 2 getrennten Modellen
  - ein Modell zur Analyse des Datenkanals „Höheninformation“
  - ein Modell zur Analyse des Datenkanals „Intensitätsinformation“
- Evaluierung anhand von Standard-Metriken, wie z. B. F1-Score, Intersection-over-Union (IoU) und Matthews Correlation Coefficient (MCC)

Allgemeines: Untersuchungen zu Deep Learning (2/2)

- Aufgrund der verfügbaren Hardware Aufteilung der Experimente in:
  - Voruntersuchungen:
    - Reduzierter Umfang des Datensatzes
    - Finden eines universellen Parametersettings für das Training
    - Gibt es Klassen, deren Detektion gar nicht funktioniert?
    - Wie sehr streuen Trainingsergebnisse (Einfluss der zufälligen Gewichtsinitialisierung)?
    - Welche gemorphometrische Vorverarbeitung ist für die Höheninformation sinnvoll?
    - Wie lange sollte ein Training in etwa dauern?

  - Finale Trainings-Pipeline:
    - Auswahl potentiell hilfreicher neuer Trainingsdaten mithilfe der besten Detektoren aus der Voruntersuchung (Hard Negative Mining) → erweiterter Datensatz
    - Training finaler Modelle, die später den Kern der Verarbeitungs-Pipeline vom Laserscan zur automatischen Kartierung bilden

Datensatz: Untersuchungen zu Deep Learning

- Datenbasis: Laserscans aus > 20 Regionen Deutschlands
- Klassenkatalog: 8 Schad-, 4 Oberflächenmaterial- und 6 Objektklassen
- > 13500 kontur-scharf gelabelte Schadstellen auf >2700 Oberflächenmodellen (4*10m)
- Aufteilung des Datensatzes in: TRAIN und TEST (15%)
- TRAIN wurde für finale Modelle sukzessive erweitert (Hard Negative Mining)
- TEST blieb immer unangetastet (Ausnahme: Entfernen der Klasse „offener Riss“ im Intensitäts-Kanal für die finalen Trainingsprozesse)

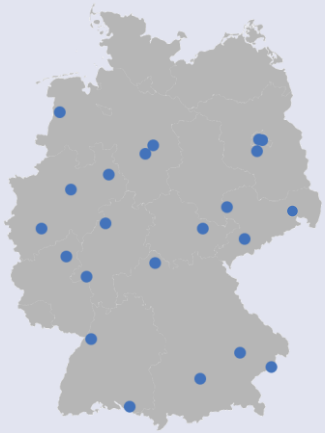

gelabelte Schadklasse	Objektanzahl	
	TRAIN	TEST
Riss (offen)	5805	1019
Riss (saniert)	1333	127
Flickstelle (eingelegt)	735	99
Flickstelle (aufgelegt)	498	42
Nahtriss	263	80
Ausbruch	2105	292
Kornausbruch	774	313
Bindemittelaustritt	139	6

Datensatz: Untersuchungen zu Deep Learning

- Manuelles Labelling von flächendeckenden Pixel-Masken

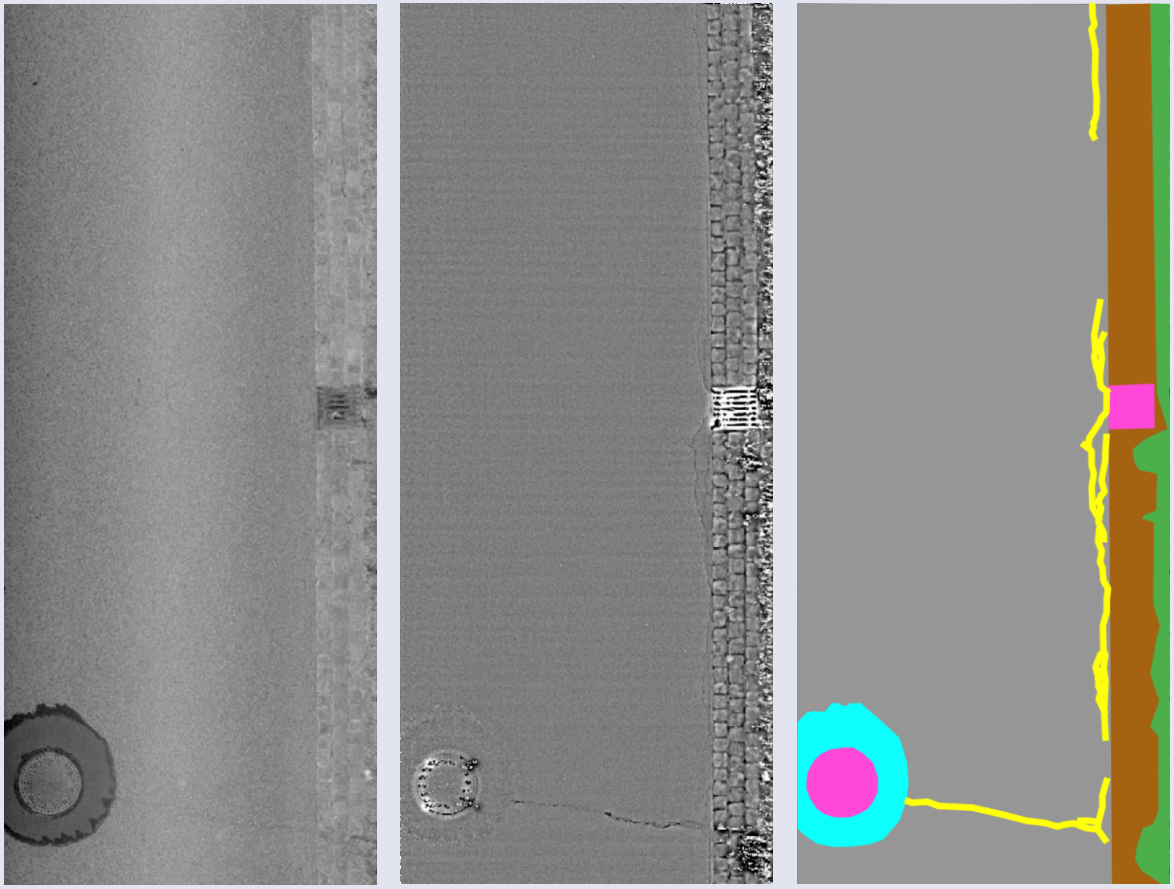

Untersuchung: Hyperparameter-Setting

- **Frage:** Welche Hyperparameter müssen für ein erfolgreiches Training eines DeepLabv3+ Modells basierend auf den zu verarbeitenden Daten eingestellt werden?
- Ablauf:
  - Wiederholte Trainingsprozesse mit variierenden Hyperparametersettings ausgehend von den default-Settings der Quellcode-Distribution von DeepLabv3+
  - Numerische Evaluation und visuelle Überprüfung der Segmentierungsergebnisse
- **Ergebnis:** Es konnte ein adäquates Hyperparamter-Setting identifiziert werden.
  - geschlossenere und eng-umschließendere Segmentierungsergebnisse durch
    a) Erhöhung der Lernrate und
    b) Veränderung des Output Strides bei der Modell-Anwendung
  - Batch Size war durch Hardware determiniert (robusterer Trainingsverlauf durch größere Batch Size)
  - Batch Normalization konnte aufgrund der Hardware nicht mit trainiert werden

	train model	output model
Model Variant	xception_65	xception_65
Atrous Rate 1	6	6
Atrous Rate 2	12	12
Atrous Rate 3	18	18
Output Stride	16	8
Decoder Output Stride	4	4
Base Learning Rate	0.004	
Crop Size	1025	1025
Steps	200000	
Batch Size	2	
Fine Tune Batch Normalization	false	

Untersuchung: Streuung des Trainings

- **Frage:** Wie zufällig ist das Training eines Detektors aufgrund der zufälligen Gewicht-Initialisierung?
- Ablauf:
  - Start von 3 identisch parametrierten Trainingsprozessen auf derselben Datengrundlage (Intensitäts-Kanal)
  - Evaluierung der entstandenen Modelle nach 150k und 300k Iterationen
- **Ergebnis:** es ist von einer zufälligen Streuung mit einer Spannweite von 0.003 Punkten für F1, 0.006 für IoU und 0.011 für MCC auszugehen (micro averaging)

Metrik	nach 150k Iterationen				nach 300k Iterationen			
	V1	V2	V3	RANGE	V1	V2	V3	RANGE
F1-Score (Micro-Averaging)	0.95	0.952	0.954	**0.003**	0.952	0.953	0.956	**0.003**
F1-Score (Macro-Averaging)	0.624	0.627	0.638	0.014	0.646	0.641	0.663	0.022
F1-Score (Weighted-Averaging)	0.949	0.95	0.952	0.003	0.951	0.951	0.953	0.003
Jaccard-Score (Micro-Averaging)	0.906	0.909	0.911	**0.006**	0.909	0.911	0.913	**0.004**
Jaccard-Score (Macro-Averaging)	0.515	0.517	0.529	0.014	0.536	0.531	0.549	0.018
Jaccard-Score (Weighted-Averaging)	0.913	0.915	0.918	0.005	0.916	0.916	0.919	0.004
Matthews Correlation Coefficient	0.832	0.838	0.842	**0.011**	0.838	0.841	0.846	**0.008**

Untersuchung: Extraktion der Oberflächeninformation

- **Frage:** Welche geomorphometrische Vorverarbeitung der Oberflächenmodelle ist zur Erkennung von Straßenschäden geeignet?
- Ablauf:
  - Recherche: Analogien von Schäden zu Formen des Georeliefs
  - Identifikation und Parametrierung der entsprechenden Terrain Analysis Algorithmen
  - Training/Evaluierung von Deep Learning Modellen mit unterschiedlich vorverarbeiteten Höhenmodellen: Topographic Position Index (Highpass Filter), Hillshade, Topographic Openness, Top Hat Transform

Paläorinne in ALS Daten

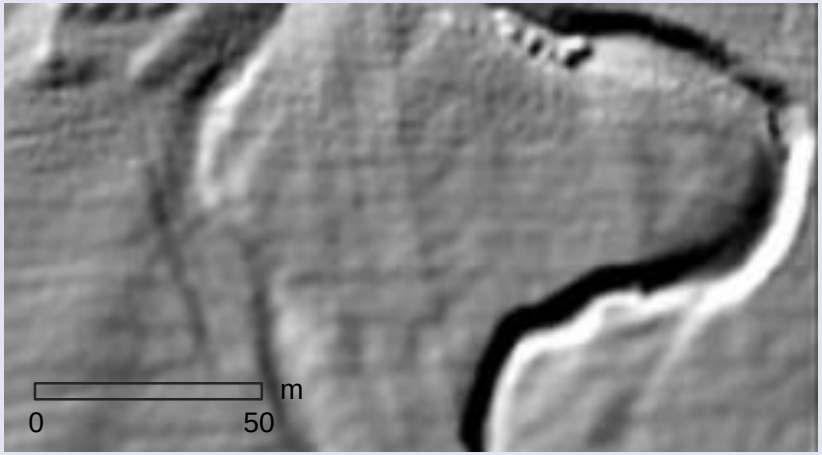

Risse in MLS Daten

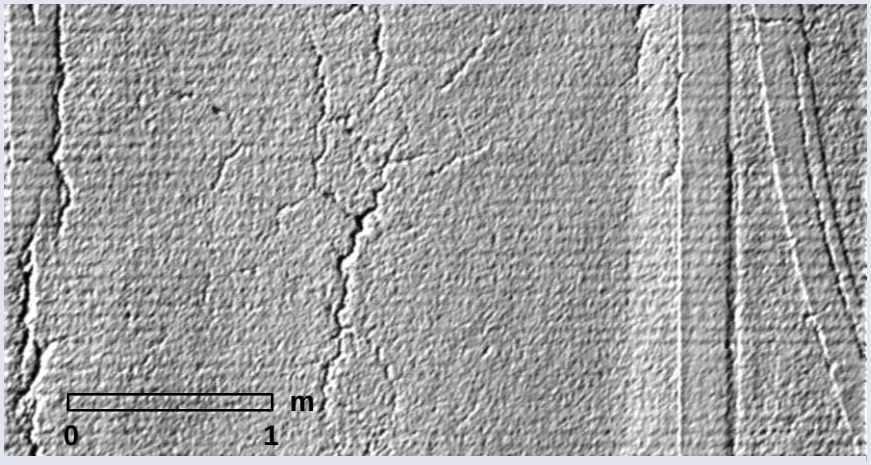

Untersuchung: Extraktion der Oberflächeninformation

- **Ergebnis:** Modelle auf Basis des Topographic Position Index liefern die besten Scores. Unterschiede sind aber (unter Berücksichtigung der Zufalls-Komponente) eher gering.

Hillshade

F1-Micro: 0.964
MCC: 0.821

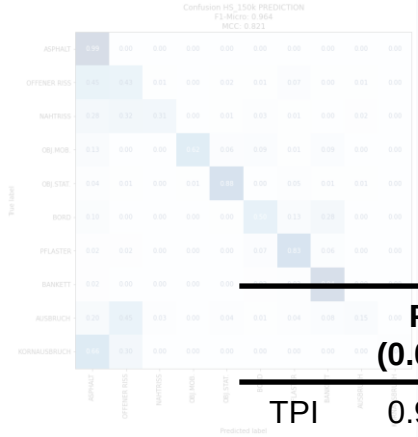

Topographic Position Index

F1-Micro: 0.974
MCC: 0.867

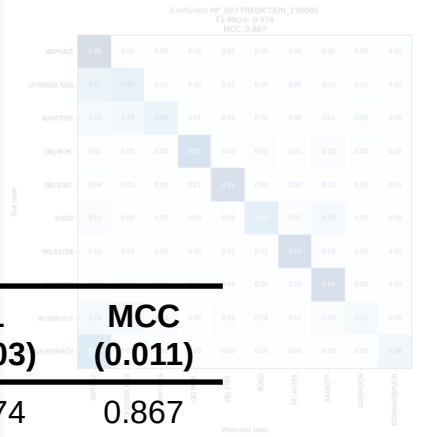

	F1 (0.003)	MCC (0.011)
TPI	0.974	0.867
TO	0.970	0.846
TH	0.967	0.832
HS	0.964	0.821

F1-Micro: 0.970
MCC: 0.846

Topographic Openness

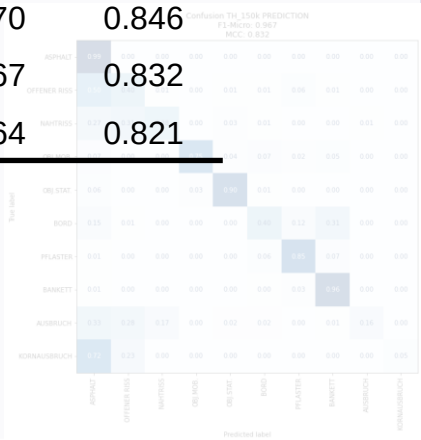

F1-Micro: 0.967
MCC: 0.832

Top Hat

Untersuchung: Ende des Trainings

- **Frage:** Ab welcher Trainingsiteration verbessert sich die Detektionsleistung des Modells nicht mehr?
- Ablauf:
  - Datengrundlage: Intensitäts-Kanal
  - Aufgrund der verfügbaren Hardware: nur diskreter Export von Modellen möglich: manuelle Modell-Evaluierung zu willkürlich bestimmten Iterations-Zeitpunkten
  - Evaluierung von Modellen bei Iteration: 40k, 60k, 120k, 150k, 300k und 500k
- **Ergebnis:** Nach 300k Iterationen ist ein Maximum der Detektionsleistung auf dem Testdatensatz erreicht.

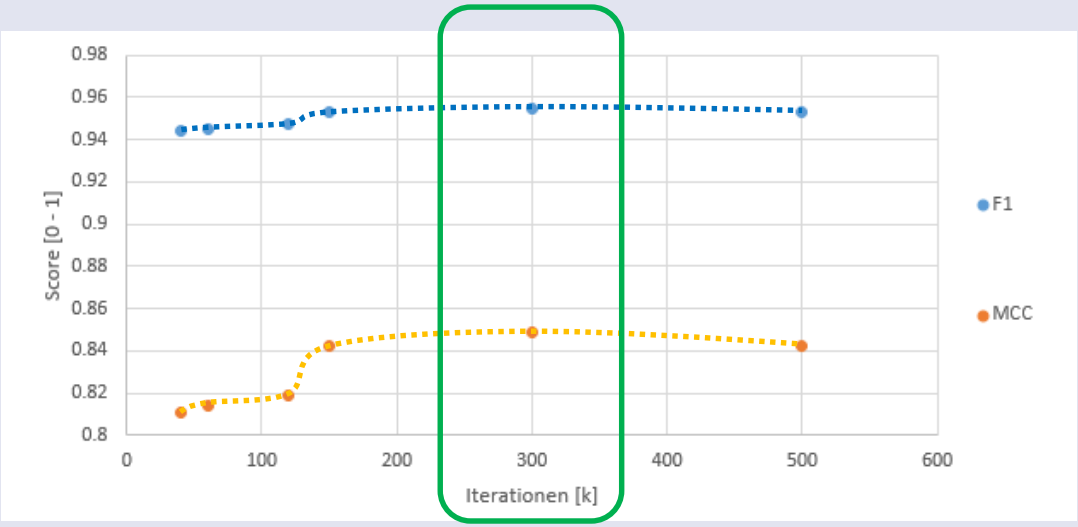

Untersuchung: Ende des Trainings

- **Frage:** Ab welcher Trainingsiteration verbessert sich die Detektionsleistung des Modells nicht mehr?
- Ablauf:
  - Datengrundlage: Intensitäts-Kanal
  - Aufgrund der verfügbaren Hardware: nur diskreter Export von Modellen möglich: manuelle Modell-Evaluierung zu willkürlich bestimmten Iterations-Zeitpunkten
  - Evaluierung von Modellen bei Iteration: 40k, 60k, 120k, 150k, 300k und 500k
- **Ergebnis:** Nach 300k Iterationen ist ein Maximum der Detektionsleistung auf dem Testdatensatz erreicht.

Segmentierungsergebnisse nach n Iteration

manuelle Labelmaske

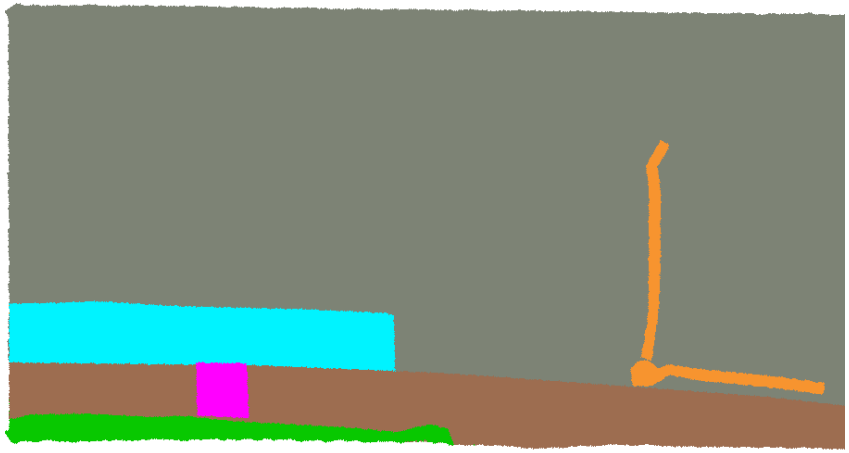

Untersuchung: Training und Evaluation finaler Modelle

- **Frage:** Wie gut ist die Klassifikations- und Segmentierungsleistung der finalen Detektoren auf dem Testdatensatz?
- Ablauf:
  - Datengrundlage: voller Trainings- und Testdatensatz
  - Tranfser Learning: auf COCO Daten vortrainierter Encoder von DeepLabv3+ (xception65 als Backbone)
  - Training von Modellen für Intensität und TPI als Input für 286 bzw. 308 Epochen (300k Iterationen)
  - Evaluierung auf Testdatensatz (Konfusionsmatrix, globale Scores)

Untersuchung: Training und Evaluation finaler Modelle

- **Ergebnis:** globale F1 | IoU | MCC Scores von 0.96 | 0.92 | 0.93 (Höheninformation)
  globale F1 | IoU | MCC Scores von 0.97 | 0.94 | 0.89 (Intensitätsinformation)

Modell zur Analyse der Höheninformation

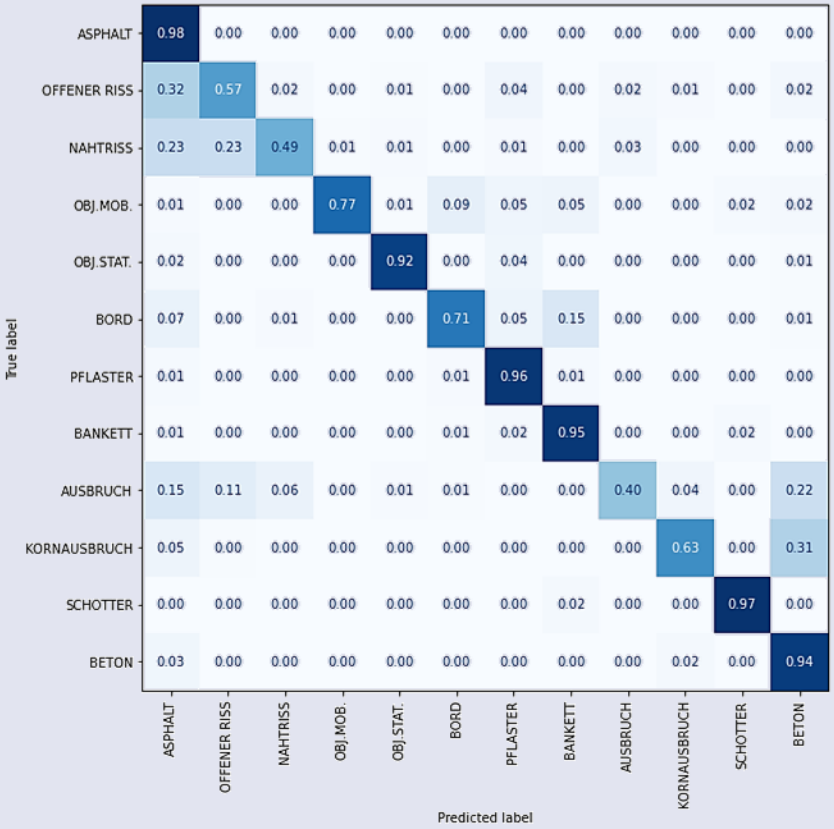

Modell zur Analyse der Intensitätsinformation

Untersuchung: Leistungsfähigkeit im Vergleich zu konventioneller Inspektion

- **Frage:** Wie leistungsfähig ist ein Deep Learning basierter, automatischer Inspektionsprozess im Vergleich zu einer konventionell-visuellen Inspektion im kommunalen Straßennetz?
- Ablauf:
  - Datengrundlage: Laserscan für ca. 1 km kommunales Straßennetz
  - Referenz: Auswertung gemäß ZTV ZEB Stb aus hochauflösenden Kamerabildern
  - synchronisiertes Auswerteraster
  - Vergleich anhand von Zustandsnoten (Substanzwert ohne Anteil Ebenheit)

Referenz: ZTV ZEB Stb konforme Auswertung der Oberflächenschäden (Daten: I.R.I.S 3 Oberflächenkamera)

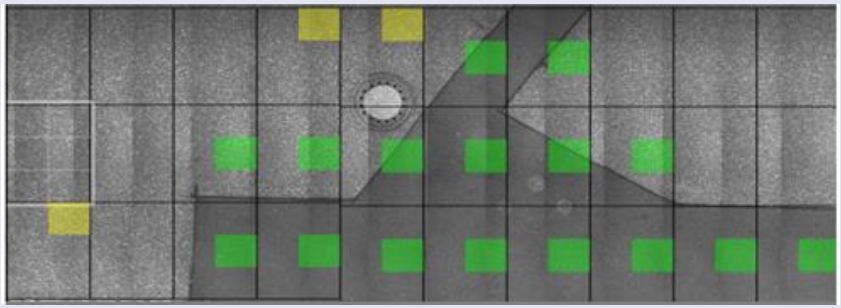

Auf Referenzraster projizierte Segmentierungsergebnisse (Daten: I.R.I.S 3 PPS GeoPNGs/GeoPackages)

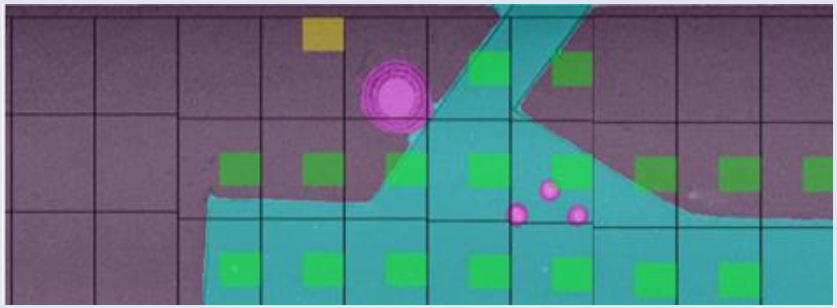

Untersuchung: Leistungsfähigkeit im Vergleich zu konventioneller Inspektion

- **Ergebnis:** hohes Maß an Übereinstimmung (Korrelationskoeffizient: 0.91)
  - Qualität auf dem Niveau menschlicher Expert*innen: Mittelwerte liegen innerhalb der von der FGSV vorgeschriebenen Toleranzen (0.5) für die Wiederholbarkeit manueller Zustandsinspektion auf Autobahnen (RISS: 0.2; FLI: 0.4)
  - mind. 10-mal schnellere Inspektionszeit (bei Nutzung nur einer GPU)

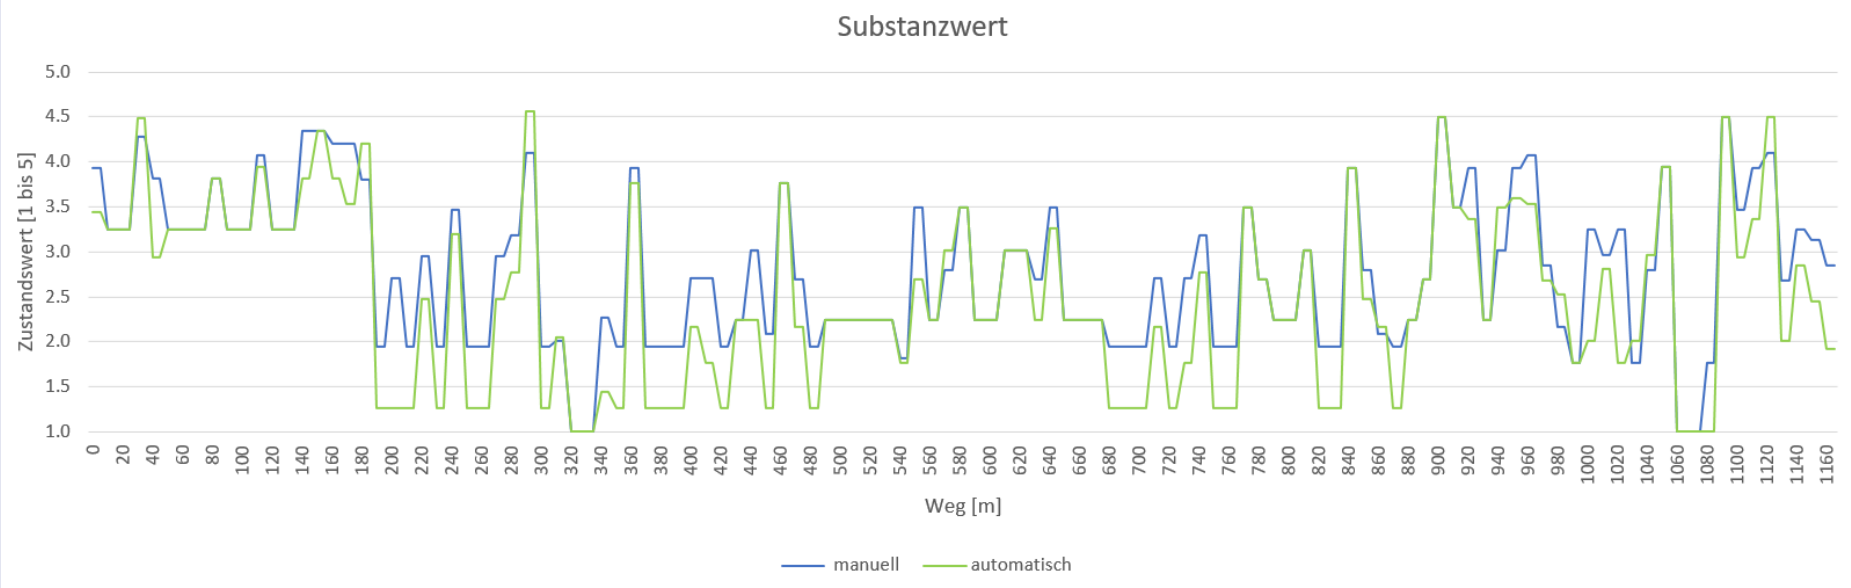

Anmerkung: Evaluierung für 70km kommunales Netz steht noch aus

aktueller Stand

Zusammenfassung: Stand der Arbeiten am PhD Projekt

- Praktische Arbeiten/Untersuchungen/Experimente
  - ✓ Untersuchungen zu relativer Genauigkeit
  - ✓ Untersuchungen zu absoluter Genauigkeit
  - ✓ Untersuchungen zur Oberflächenmodellierung
  - ✓ Untersuchungen zur geomorphometrischen Oberflächenanalyse
  - ✓ Untersuchungen zum Training von Deep Learning Modellen
  - ⚙ Vergleich zwischen automatischer Kartierung und konventioneller Inspektion im Realmassstab

- Dissertation
  - ⚙ Grundlagen
  - ✓ Daten
  - ✓ Methoden
  - ⚙ Ergebnisse

Aktueller Stand

Nächste Schritte, offene Fragen und Zielhorizont zum Ende der Dissertation

- Nächste Schritte:
  - statistische Auswertung des kommunalen Referenzprojektes
  - Schreiben ☺
- Zielhorizont:
  - Rohfassung der Dissertation bis Ende 2022
  - Abschluss 2023
- Offene Fragen:
  - Veröffentlichungen einbinden?
  - Ausblick und Diskussion

wissenschaftliche Aktivitäten

Forschungsprojekte (abgeschlossen)

- **PaveScan 4D** – Entwicklung eines portablen Gesamtsystems zur kinematischen Analyse von Schäden der Verkehrsinfrastruktur
  - Verbundprojekt mit Fraunhofer Institut für physikalische Messtechnik, Autstrian Institute of Technology und IMP Bautest AG, gefördert durch das Bundesministerium für Bildung und Forschung (BMBF)
- **ASINVOS** – Assistierendes und interaktiv lernfähiges Videoinspektionssystem für Oberflächenstrukturen am Beispiel von Straßenbelägen und Rohrleitungen.
  - Verbundprojekt mit der TU Ilmenau, OPTIMESS Engineering GmbH und Thüringer Fernwasserversorgung, gefördert durch das Bundesministerium für Bildung und Forschung (BMBF)
- **Betonfahrbahn 4.0** – Prozesssichere Herstellung von Betonfahrbahnen durch Integration neuer innovativer Maßnahmen und digitale Vernetzung zur Erhöhung von Qualität und Dauerhaftigkeit.
  - Verbundprojekt mit Heinz Schnorpfeil Bau GmbH, Betonfertiger Wirtgen GmbH, Liebherr Mischtechnik GmbH, Cavex GmbH & Co.KG, Otto Alte-Teigeler GmbH, Institut für Werkstoffe im Bauwesen (IWB), Materialprüfanstalt (MPA); gefördert durch die Bundesanstalt für Straßenwesen
- **ASFaLT** – Automatisierte Schadstellenerkennung für unterschiedliche Fahrbahnbeläge mittels Deep-Learning-Techniken.
  - Verbundprojekt mit der TU Ilmenau, der Austrian Institute of Technology GmbH und der VIA IMC GmbH; gefördert durch die Bundesanstalt für Straßenwesen

Wissenschaftliche Aktivitäten

Universität Bamberg

Konferenzen

- GeoIT GISCO 2015 – Bamberg
- Geographisches Kolloquium 2018 – Bamberg
- AGIT 2018 – Salzburg
- RPUG 2018 – Rapid City
- ERPUG 2018 – Madrid
- 13th International Symposium on Concrete Roads 2018 – Berlin
- 16. Sächsisches GIS-Forum – Dresden
- Transportation Research Board 2019 – Washington D. C.
- AGIT 2019 – Salzburg
- Symposium Straßenbautechnik und des Erhaltungsmanagement 2019 – Bergisch Gladbach
- Münchner GI-Runde 2020 – web Konferenz
- Oldenburger 3D-Tage 2022 – web Konferenz

Publikationen (nach Erscheinen)

EISENBACH, M., STRICKER, R., SEICHTER, D., AMENDE, K., DEBES, K., SESSELMANN, M., EBERSBACH, D., STOECKERT, U. & H.-M. GROSS (2017): *How to Get Pavement Distress Detection Ready for Deep Learning? A Systematic Approach*. Int. Joint Conf. on Neural Networks (IJCNN), Anchorage, USA, pp. 2039 –2047.

WIELAND, M. & M. SESSELMANN (2018): *Plattenspezifische 3D-Oberflächenanalyse im Kontext mit der rechnerischen Dimensionierung und Restsubstanzbewertung von Betonfahrbahndecken*. Straße und Autobahn, 06/2018, pp. 447-458.

SESSELMANN, M. (2018): *Automatische Detektion von Substanzmerkmalen auf 3D-Fahrbahnoberflächen*. AGIT – Journal für Angewandte Geoinformatik, 4-2018, pp. 65-74.

SESSELMANN, M., STRICKER, R. & M. EISENBACH (2019): *Einsatz von Deep Learning zur automatischen Detektion und Klassifikation von Fahrbahnschäden aus mobilen LiDAR-Daten*. AGIT – Journal für Angewandte Geoinformatik 5-2019, pp. 100 –114.

SESSELMANN, M., STRICKER, R., NABER, T. & S. SCHELLER (2020): *Automatische Detektion und objektscharfe Georeferenzierung von Fahrbahnschäden aus Bilddaten eines Mobile-Mapping-Systems mithilfe von Deep Learning*. gis.Science 1/2020, pp. 18-30.

SKALECKI, P., SESSELMANN, M.; RECHKEMMER, S., BRITZ, T., GROSSMANN, A., GARRECHT, H. & O. SAWODNY (2021): *Process Evaluation for Smart Concrete Road Construction: Road Surface and Thickness Evaluation Using High-Speed LiDAR Technology*. Automation, 2 (1), pp 31-47.

STRICKER, R., AGANIAN, D., SESSELMANN, M., SEICHTER, D., ENGELHARDT, M., SPIELHOFER, R., HAHN, M., HAUTZ, A., DEBES, K. & H.-M. GROSS (2021): *Road Surface Segmentation - Pixel-Perfect Distress and Object Detection for Road Assessment*. IEEE 17th International Conference on Automation Science and Engineering (CASE) August 2021, pp. 1789-1796.

NABER, T., SESSELMANN, M., STRICKER, R., SCHELLER, S., STELLING, N., KLOSE, D. & A. GROßMANN (2021): *Künstliche Intelligenz in der Straßenraumerfassung*. Straßenverkehrstechnik 65 (12), pp. 896-902.

SESSELMANN, M., NABER, T., SCHELLER, S., STELLING, N. & A. GROßMANN (2022): *Mobiles Laserscanning und Deep Learning für die automatische Kartierung des Straßenzustandes im kommunalen Straßennetz*. Photogrammmetrie, Laserscanning, Optische 3D-Messtechnik – Beiträge der Oldenburger 3D-Tage 2022, pp. 214-227.

Vielen Dank für Ihre Aufmerksamkeit!

Quellen

Applanix. (2019). POS LV. https://www.applanix.com/downloads/products/specs/POS-LV-Datasheet.pdf

Forschungsgesellschaft für Straßen- und Verkehrswesen FGSV (2015): *Arbeitspapiere zur Systematik der Straßenerhaltung - Reihe K: Kommunale Straßen* (AP9 K/3.1).

Fraunhofer Institute for Physical Measurement Techniques IPM (2019). PAVEMENT PROFILE SCANNER PPS / PPS-PLUS. https://www.ipm.fraunhofer.de/content/dam/ipm/en/PDFs/product-information/OF/MTS/Pavement-Profile-Scanner-PPS.pdf

Lundberg, T., Andrén, P., Wahlman, T., Eriksson, O., Sjögren, L., & P., Ekdahl (2018): *New technology for road surface measurement : transverse profile and rut depth*. Retrieved from Statens väg- och transportforskningsinstitut website: http://urn.kb.se/resolve?urn=urn:nbn:se:vti:diva-12806

Reiterer, A., Dambacher, M., Maindorfer, I., Höfler, H., Ebersbach, D., Frey, C., Scheller, S. & D. Klose (2013): *Straßenzustandsüberwachung in Sub-Millimeter*. In: T. Luhmann (Ed.), Photogrammetrie, Laserscanning, optische 3D-Messtechnik: Beiträge der Oldenburger 3D Tage 2013, pp. 78-85.