

The background of the slide is a composite image. It features an aerial photograph of a city, likely Munich, with various buildings and streets. This image is overlaid with a semi-transparent green layer on the right side and a black layer on the left side. The text is centered on a dark grey rectangular background.

München Grünflächenerkennung

Deep Learning WS23/24 Abschlusspräsentation

von

Hendrik Haugg, Sebastian Huber, Sebastian Kiunke, Jonas Leitner



Gliederung

- ▶ Einführung, Motivation und Ziele
- ▶ Related Work
- ▶ Konzept & Evaluation
- ▶ Versuche
- ▶ Zeitplan - Rückblick
- ▶ Ausblick

Einführung und Motivation

- ▶ Projekt der LHS München
- ▶ Darstellung der Entwicklung des Stadtbildes in Bezug auf Grünflächen
- ▶ Datengrundlage Luftbilder:
 - ▶ jährliche Befliegung (20cm/px)
 - ▶ bayerisches Vermessungsamt (40cm/px)
- ▶ Entwicklung eines Segmentierung Verfahrens von Luftbildern in:
 - ▶ Grünfläche (Wiese, Baum, Wald, ...)
 - ▶ Alles andere
- ▶ Anwenden auf Luftbilddaten der letzten Jahre

Related Work

Drone-captured Aerial Images

“A Lightweight Deep Learning Architecture for Vegetation Segmentation using UAV-captured Aerial Images” (2023)

- ▶ LW-AerialSegNet
- ▶ [vegetation, building, road, water]
- ▶ Urban Drone - Datensatz -> IoU 82%
- ▶ NITRDrone - Datensatz -> IoU 71%

High Resolution Satellite Imagery

“Mapping Urban Green Spaces at the Metropolitan Level Using Very High Resolution Satellite Imagery and Deep Learning Techniques for Semantic Segmentation” (2021)

- ▶ U-Net
- ▶ different CNN encoders
- ▶ Urban Green Space Polygon datasets (auch z.B. OSM)
- ▶ IoU 75%

Evaluation

- ▶ Die Segmentierung stellt eine per Pixel binary Klassifikation dar
- ▶ Auswertung über TP, TN, FP, FN Pixel anzahlen.
- ▶ Die wichtigsten abgeleiteten Metriken sind:

F1-Score:

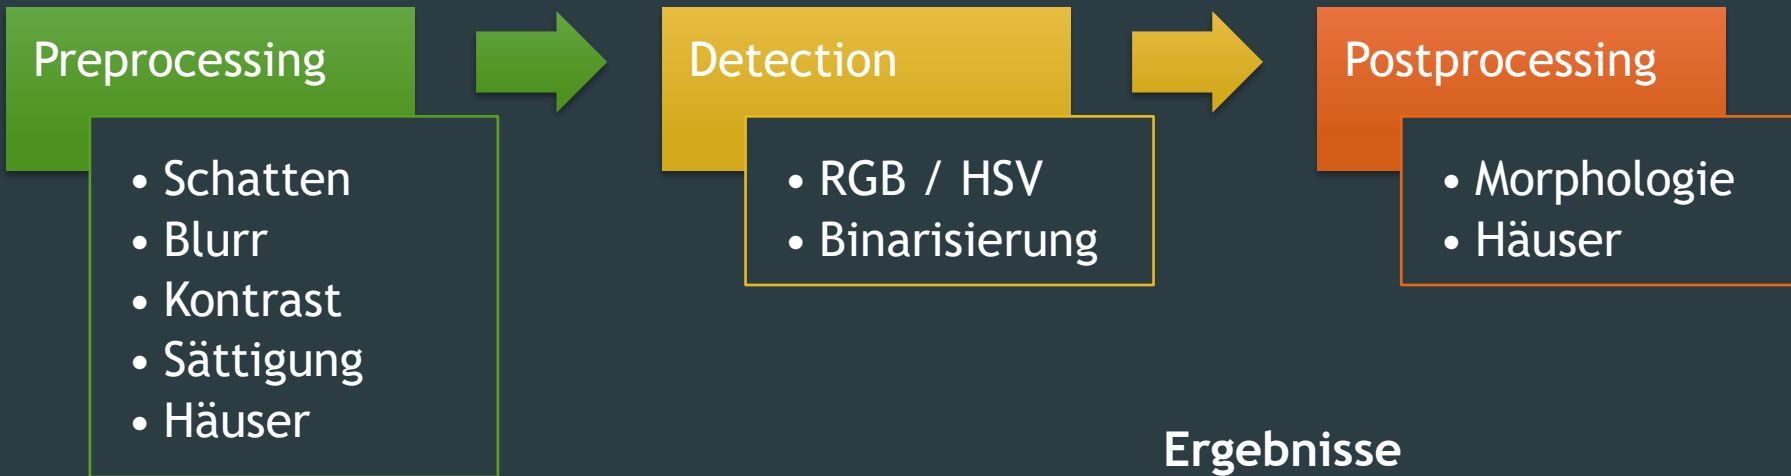
$$\begin{aligned} F1 &= 2 * (\text{precision} * \text{recall}) / \\ &(\text{precision} + \text{recall}) \\ &= 2 * TP / (2 TP + FP + FN) \end{aligned}$$

Intersection over Union
(IoU):

$$\text{IoU} = TP / (TP + FP + FN)$$

=  / 

Image Processing



- ▶ Alle Schritte parametrisiert
- ▶ Optimiert mit Genetischem Algorithmus
- ▶ Optimierungsziele IoU und F1
- ▶ Schatten langsam > statisch vorberechnet
- ▶ RGB wurde bevorzugt

Ergebnisse

IoU	0,85
F1	0,92
ACC	93 %
Precision	0,96
Recall	0,88

Image Processing - Ergebnisse

Probleme mit:

- Seitenstreifen
- Braune Wiese



Label



Output



Diff




Image Processing - Ergebnisse

Probleme mit:

- Schatten von Bäumen

Gut:

- Wege



Label



Output



Diff



Image Processing - Ergebnisse

Probleme mit:

- Isar
- Ränder




Label



Output



Diff



U-Net

Preprocessing

- Zuschneiden
- Zuordnen

Model Training


- RGB Stadtbild
- Maske

Prediction

- ▶ Preprocessing und Training automatisiert in Tensor Flow
- ▶ Training und Evaluation mit Potsdam und eigenen Datensatz
- ▶ Training Stats:
 - ▶ Loss: 0.0839
 - ▶ Accuracy: 0.9664
 - ▶ Validation loss: 0.1247
 - ▶ Validation accuracy: 0.9530

Ergebnisse

IoU	0.470
F1	0.639
ACC	60.746%
Precision	0.762
Recall	0.551



U-Net - Ergebnisse

Grünfläche mit Straßen und Gebäuden



Label



Output



Diff




U-Net - Ergebnisse

Grünfläche mit Straße und fehlerhaftem Label



Label



Output



Diff





MMSegmentation



- ▶ Semantic Segmentation Toolbox (30+ Modelle, 20+ Datensätze)

- ▶ Auswahl Datensätze

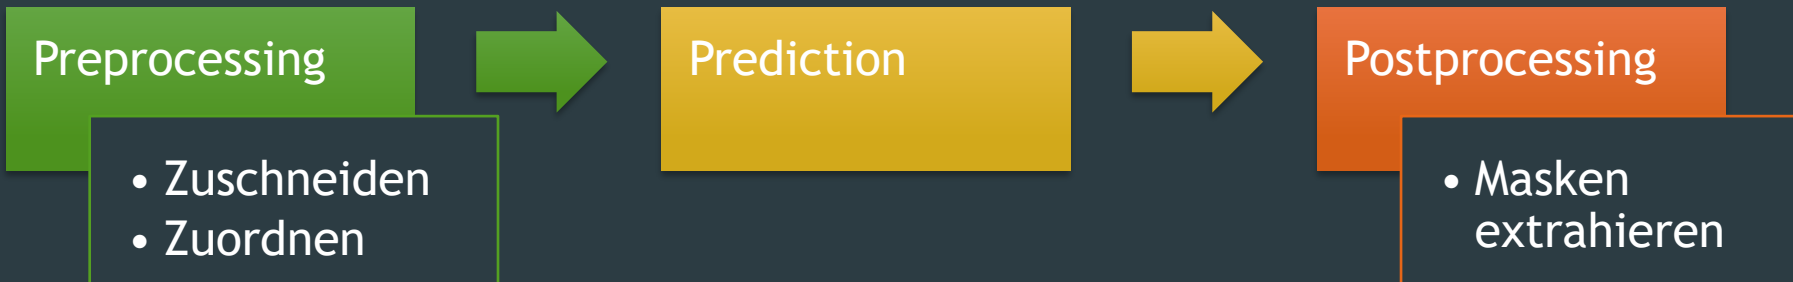
- ▶ Potsdam
- ▶ Vaihingen
- ▶ LoveDa



- ▶ Auswahl Model

- ▶ DeeplabV3+
- ▶ PSPNet
- ▶ HRNet

- ▶ Workflow

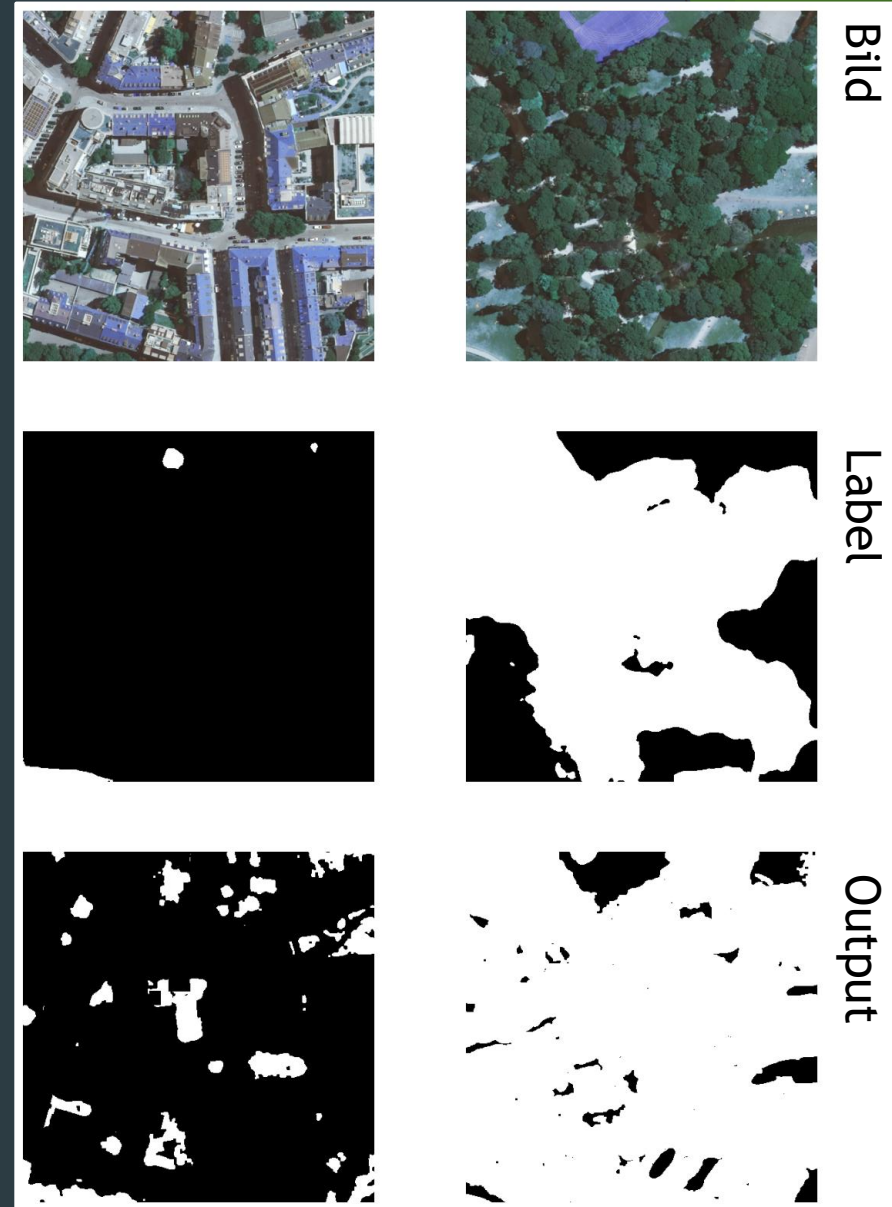


MMSegmentation - Ergebnisse


- ▶ Vergleich Datensätze (DeepLabV3+)

Dataset	IoU	F1 score	accuracy
LoveDa	0.558	0.716	80.540 %
Potsdam	0.171	0.291	41.754 %
Vaihingen	0.276	0.432	30.716 %

- ▶ Overall Results
 - ▶ Schwächen bei kleinen, verteilten Flächen
 - ▶ Ungenauigkeit bei Wiesen und Wegen



Segment Anything



- ▶ SAM zur Segmentierung
- ▶ GroundingDINO zum Erstellen von Objekt Masken per Text Prompts

Ergebnisse

IoU	0,82
F1	0,90
ACC	92 %
Precision	0,88
Recall	0,93

Segment Anything - Ergebnisse

- ▶ Hauptbahnhof



Segment Anything - Ergebnisse

- ▶ Hauptbahnhof
- ▶ False Positive in Rot
- ▶ False Negative in Blau



Segment Anything - Ergebnisse

FP (Rot), FN (Blau)



Klassifiziert häufig
Schatten mit



Übersieht einige begrünte
Innenhöfe




Probleme mit Wasser &
Artefakte durch Batch
Klassifizierung

Evaluation - Fazit

	IoU	F1-Score	Accuracy	Precision	Recall
Image Processing	0,85	0,92	93 %	0,96	0,88
Segment Anything	0,82	0,90	92 %	0,88	0,93
U-Net	0,47	0,64	61 %	0,76	0,55
MMSegmentation	0,56	0,71	81 %	9,99	0,56

Versuche

- ▶ Visualisierung von Laserdaten
 - ▶ Sehr genaue Erkennung von Bäumen
 - ▶ Offen gebliebene Frage: “In welcher Form können die Daten mit in die bestehenden Ansätze integriert werden?”

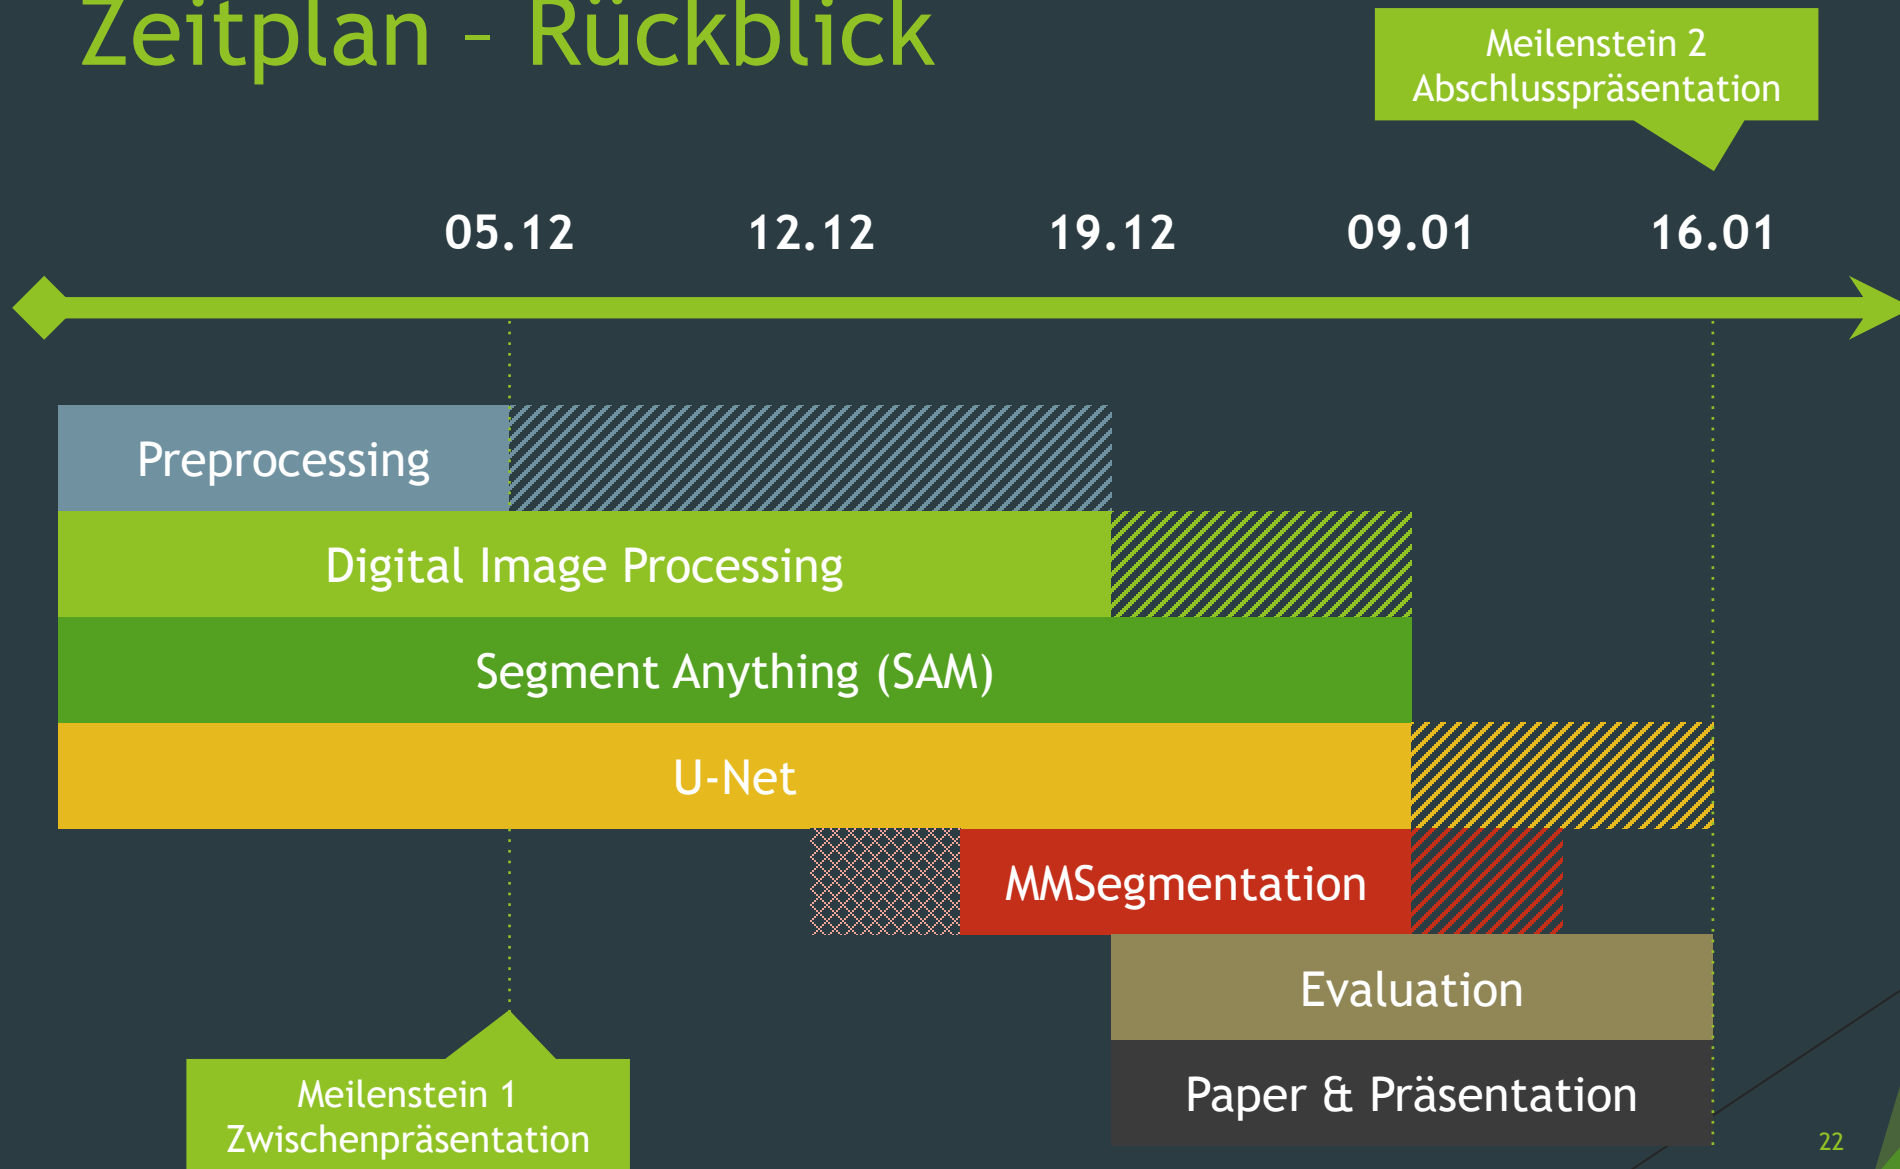


Versuche

- ▶ Segmentierung auf älteren Luftaufnahmen
 - ▶ Labeling für Auswertung notwendig
- ▶ Bsp: Luftaufnahme von 2003 mit SAM segmentiert



Zeitplan - Rückblick



Ausblick

- ▶ Image Preprocessing:
Optimierte und gute
Schattenreduktion
- ▶ U-Net:
Datengrundlage ausbauen und
verbessern 3D statt 2D als
Grundlage
- ▶ Segment Anything:
Bessere Schatten Reduktion und
SAM-hq
- ▶ MMSegmentation:
Modelle auf eigenen Daten
trainieren und mit loveda
Datensatz evaluieren

Vielen Dank
für eure
Aufmerksamkeit

Fragen?

