

Automatisierte Auswertung von Zugvorbeifahrten in Videodaten mittels Künstlicher Intelligenz

Andreas Schluiep, Grolimund + Partner AG, Bern, CH

Abstract

Im Rahmen dieses Projekts wurde ein System zur automatisierten Zugerkenennung entwickelt, das moderne Deep-Learning-Verfahren mit klassischer Bildverarbeitung kombiniert. Im Fokus steht der Einsatz von Transfer Learning auf Basis von YOLOv5 – einem leistungsfähigen Echtzeit-Objekterkennungsmodell. Dabei wird ein vortrainiertes Modell gezielt auf neue Aufgaben wie die Erkennung spezifischer Zugtypen oder die Bestimmung von Geschwindigkeit und Länge angepasst.

Für die Berner Alpenbahngesellschaft Bern–Lötschberg–Simplon (BLS) wurde ein feinjustiertes Modell eingesetzt, das mehrere Fahrzeugtypen wie FLIRT, DOMINO, LÖTSCHBERGER oder GÜTERZÜGE unterscheiden kann. Bei der Berner Oberland-Bahn (BOB) lag der Fokus auf einer vereinfachten Erfassung der Geschwindigkeit und Zuglänge, ohne detaillierte Typisierung. Für die Matterhorn Gotthard Bahn (MGB) kam ein hybrider Ansatz zur Anwendung, bei dem klassische Texterkennung (OCR) zur Identifikation einzelner Wagenbezeichnungen eingesetzt wurde.

Die entwickelte Datenpipeline erlaubt eine weitgehend automatisierte Verarbeitung grosser Videomengen. Detektionen erfolgen tageslichtbasiert und erlauben eine standardisierte Auswertung, die für weiterführende Analysen (z. B. Lärm- oder Erschütterungsmonitoring) genutzt werden kann. Trotz technischer Herausforderungen – wie z. B. Nachtbetrieb, Witterungseinflüsse oder komplexe Gleissituationen – zeigt das System ein hohes Potenzial für den breiten Einsatz in Bahnüberwachung, Logistik und Infrastrukturmonitoring.

Automatisierte Auswertung von Zugvorbeifahrten in Videodaten mittels Künstlicher Intelligenz Potenzial, Herausforderungen und Anwendung im Monitoring

1. Hintergrund und Motivation

Die Überwachung und Analyse von Bahnstrecken ist in Zeiten wachsender Anforderungen an Infrastrukturüberwachung ein zentrales Thema. Im Bereich Monitoring von Lärm- und Erschütterungsmessungen entlang stark frequentierter Strecken gewinnen automatisierte Verfahren zunehmend an Bedeutung. Traditionelle Methoden, die häufig auf manuelle Eingriffe oder spezialisierte, aber starre Sensorlösungen setzen, stossen bei den dynamischen Anforderungen des modernen Betriebs an ihre Grenzen.

Moderne Ansätze setzen auf Künstliche Intelligenz (KI) – speziell auf Objekterkennung mit Deep Learning. Das in diesem Projekt entwickelte System nutzt YOLOv5, um in Echtzeit Züge zu erkennen, diese zu klassifizieren und zusätzlich Informationen zur Geschwindigkeit und Richtungsbestimmung abzuleiten.

2. Anwendung im Bahnmonitoring

Ziel des Projekts ist es, ein robustes System zur Erkennung und Klassifikation von Zügen zu entwickeln. Die dabei erhobenen Daten geben Aufschluss über Umwelteinflüsse wie Lärm und Erschütterungen. In der Praxis wurde das System bei verschiedenen Bahnbetreibern eingesetzt:

- **BLS:** Hier wurde ein feinjustiertes Modell mittels Transfer Learning trainiert, das die Erkennung und Unterscheidung mehrerer Zugtypen erlaubt – darunter FLIRT, DOMINO, LÖTSCHBERGER, MIKA, NINA und GÜTERZÜGE. Die visuelle Differenzierung basiert auf Bilddaten, die in realen Einsatzumgebungen erfasst wurden.
- **BOB:** Ein vereinfachtes Modell fokussiert sich primär auf die Bestimmung von Geschwindigkeit und Zuglänge, ohne eine vollständige Typklassifikation vorzunehmen.
- **MGB:** Es wurde ein alternativer Ansatz implementiert, bei dem klassische Bildverarbeitung und Optical Character Recognition (OCR) zur Anwendung kommen. Die Beschriftungen auf den Wagen werden direkt ausgelesen, um die Fahrzeuge eindeutig zu identifizieren.

3. Technischer Ablauf und Pipeline

Das System beruht auf einer mehrstufigen Pipeline, die von der Datenerfassung bis hin zur Echtzeitanalyse reicht. Eine schematische Übersicht des Ablaufs lautet:

1. Datenerfassung:
 - Kameras an Bahnstrecken nehmen kontinuierlich Videodaten auf.
 - Trigger durch Bewegungssensoren minimieren den Speicherbedarf.
2. Vorverarbeitung:
 - Frames werden extrahiert und hinsichtlich Qualität (z. B. Helligkeit, Kontrast) optimiert.
3. Objekterkennung & Klassifikation:
Das mittels Transfer Learning angepasste YOLOv5-Modell erkennt Züge und klassifiziert

diese auf Frame-Ebene. Je nach Einsatzort variiert die Modellkomplexität (von Grobklas-
sifikation bis zur Fahrzeugtypenerkennung).

4. Tracking & Analyse:

Über Frame-Serien hinweg wird die Bewegung verfolgt, um daraus die Geschwindigkeit,
Bewegungsrichtung, Zuglänge sowie – sofern möglich – die Anzahl der Wagen und Ach-
sen zu ermitteln.

5. Auswertung & Speicherung:

Die Ergebnisse werden automatisch ausgewertet und für die weitere Verarbeitung abge-
speichert. Darauf basierend erfolgt die Extraktion von Lärm-/ Erschütterungsereignissen.

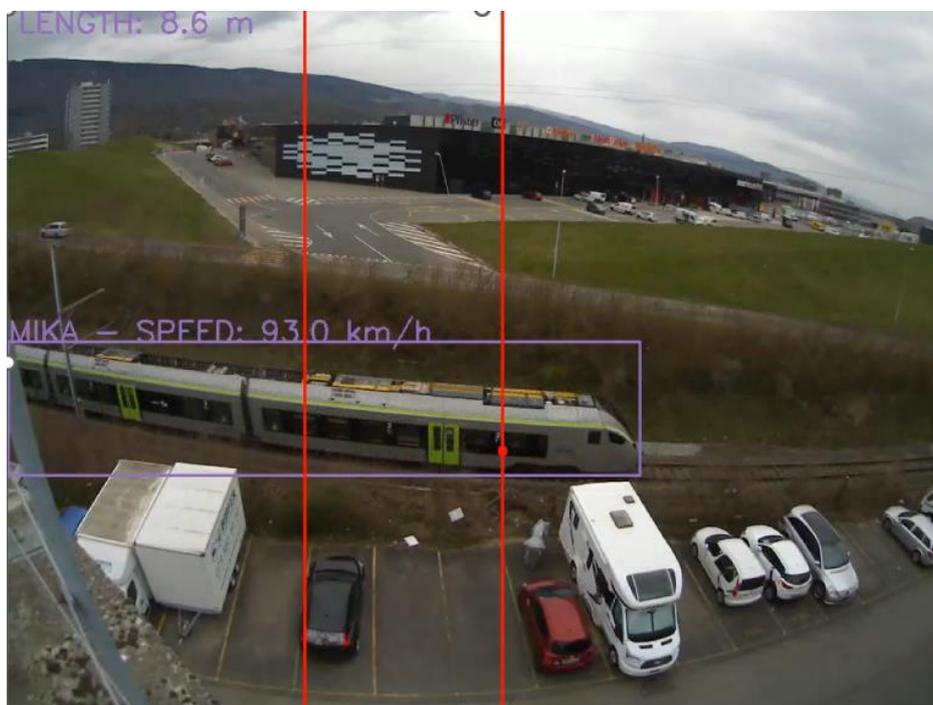


Abbildung 1: Beispiel einer klassierten MIKA-Zugvorbeifahrt (BLS)

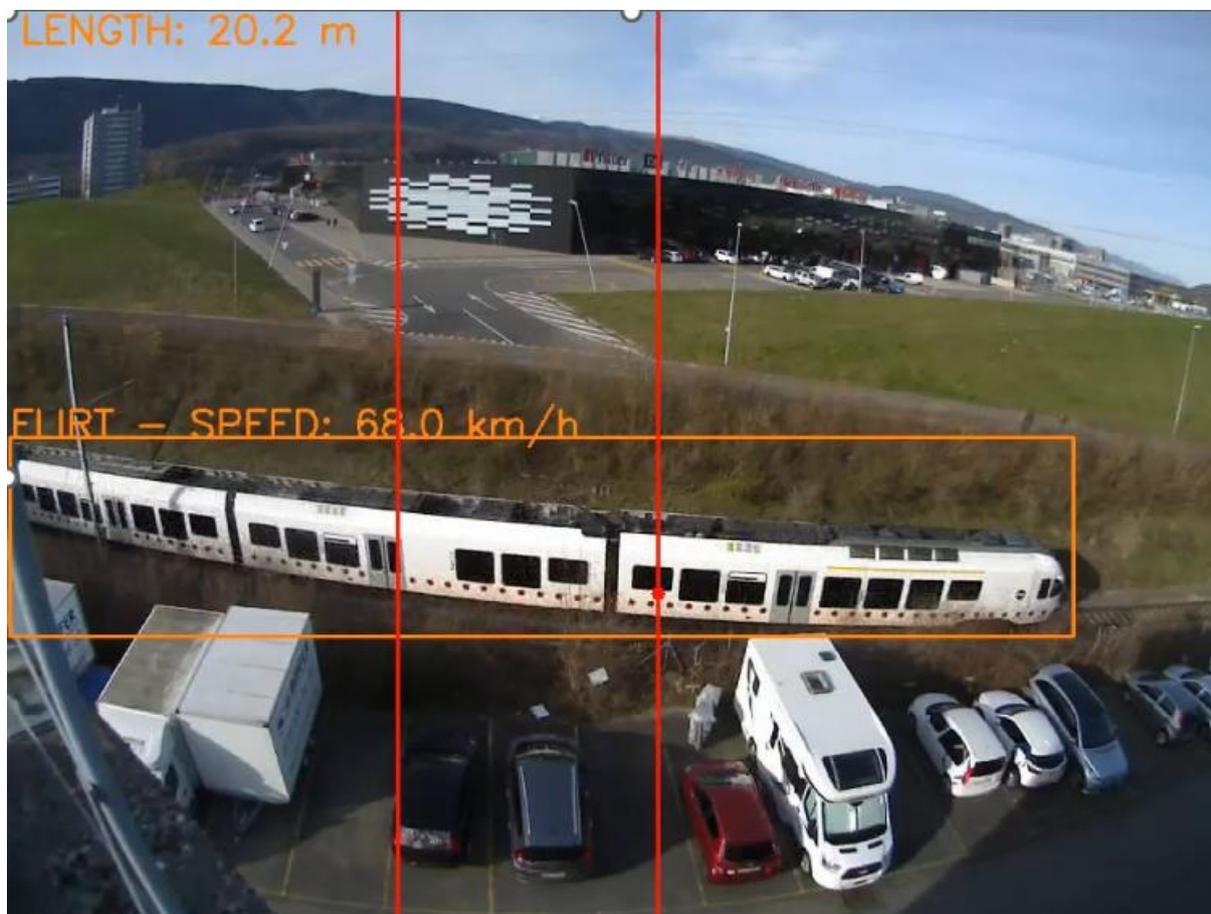


Abbildung 2: Beispiel einer klassierten FLIRT-Zugvorbeifahrt (BLS)

4. Limitationen und Grenzfälle

Obwohl das System Potenzial für eine automatisierte Zugerkennung bietet, gibt es einige wesentliche Limitationen:

- **Nachtaufnahmen:**
Die Erkennung bei Dunkelheit ist aufgrund reduzierter Lichtverhältnisse und Bildrauschen anspruchsvoll. Moderne Infrarot- oder Nachtsichtlösungen sind kostenintensiv und technisch herausfordernd.
- **Mehrere Spuren und Gleise / Weichen:**
Die gleichzeitige Präsenz mehrerer Züge auf benachbarten Gleisen führt zu Überlappungen und kann zu Fehldetektionen führen, wenn die Kamera nicht optimal ausgerichtet ist.
- **Komplexe Zugkompositionen:**
Besonders bei Güterzügen mit gemischten Wagontypen oder grossen, heterogenen Zugkompositionen kann die Klassifikation ungenau werden. Unterschiede in der Anzahl der Wagen und die Anordnung der Achsen sind oft schwer zu differenzieren.
- **Beschleunigungs- und Brems Situationen:**
Plötzliche Änderungen in der Fahrdynamik führen zu Ungenauigkeiten in der Geschwindigkeitsbestimmung.

Technische Herausforderungen:

- Datenmenge: Videoaufnahmen erzeugen schnell sehr grosse Datenmengen, die sowohl Speicher- als auch Rechenressourcen belasten.
- Kamerawahl: Die Auswahl des geeigneten Kamertyps ist entscheidend. Technische Parameter wie Auflösung, Bildrate und Nachtsichtfähigkeit beeinflussen die Erkennungsgenauigkeit massgeblich.
- Stromversorgung: Autarke Systeme auf entlegenen Strecken sind häufig auf alternative Energiequellen wie Solarzellen angewiesen. Dies bedingt allerdings Kompromisse bei der Reaktionszeit und Systemstabilität.
- Datenschutz: Insbesondere im öffentlichen Raum wird die Videoüberwachung kritisch gesehen. Anwohner äussern Bedenken hinsichtlich der Privatsphäre, was durch transparente Informationen und Anonymisierungsmassnahmen adressiert werden muss.

5. Weiterentwicklungen und Potenzial

Trotz bestehender Herausforderungen zeigt der Ansatz ein hohes Entwicklungspotenzial:

- Flexible Anwendbarkeit:
Die verwendete Methode ist nicht nur für die Bahnerkennung, sondern auch für andere Bereiche der Objekterkennung einsetzbar. Beispiele sind:
 - Strassenverkehr: Echtzeitanalyse von Fahrzeugströmen, Erkennung von Staus oder Unfällen.
 - Baustellenüberwachung: Automatische Erkennung von Einsatzfahrzeugen oder spezifischen Baumaschinen.
- Verbesserte Hardware:
Zukünftige Entwicklungen in derameratechnik, wie höhere Auflösungen und verbesserte Nachtsichtoptionen, werden die Erkennungsraten weiter steigern.
- Echtzeitübertragung und Cloudverarbeitung:
Mit der zunehmenden Verfügbarkeit von Edge-Computing und 5G-Netzwerken können grosse Datenmengen in Echtzeit verarbeitet und in umfangreiche Monitoring-Systeme integriert werden.
- Erweiterung der Analyse:
Weitere Parameter, wie das exakte Zählen von Achsen oder das Differenzieren von Beschleunigungs- und Bremsvorgängen, bieten zusätzliche Möglichkeiten zur Optimierung der Analyse

6. Fazit

Die Kombination moderner Deep-Learning-Verfahren mit bewährter Bildverarbeitung eröffnet neue Möglichkeiten im Bahnmonitoring. Das vorgestellte System demonstriert das Potenzial Züge in Echtzeit zu erkennen und zu klassifizieren damit beispielsweise Erschütterungsereignisse zu detektieren. Trotz bestehender technischer und betrieblicher Limitationen bieten Weiterentwicklungen – beispielsweise im Hinblick auf Nacht- und Mehrspurensituationen oder bezüglich flexible Anwendbarkeit in anderen Bereichen – ein breites Spektrum zukünftiger Einsatzmöglichkeiten.

++ G+P
INGENIEURE

KI basierte Videoauswertung von Zugvorbeifahrten

Ziegler Consultant Symposium 2025

24.06.2025

1

Hintergrund

- Monitorings an Bahnstrecken (Lärm/Erschütterung)
- Modellbildung pro Zugstyp (Oder gar Einzelwagen) nötig → Viele verschiedene einzelne Vorbeifahrten einzeln klassieren und auswerten
- Für vernünftige Datenbasis müssen viele Züge und Vorbeifahrten erfasst werden. → Manuell kaum zu bewältigen

2

2

Automatische Videoauswertung - Einleitung



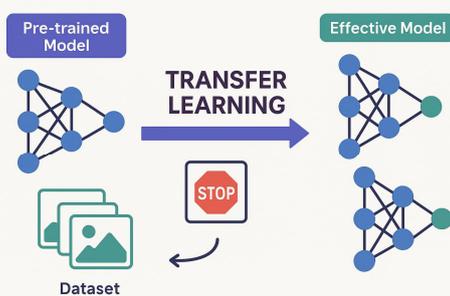
3

3

Transfer learning



Transfer Learning ist ein Machine-Learning-Ansatz, bei dem ein vortrainiertes Modell auf eine neue, aber ähnliche Aufgabe angepasst wird



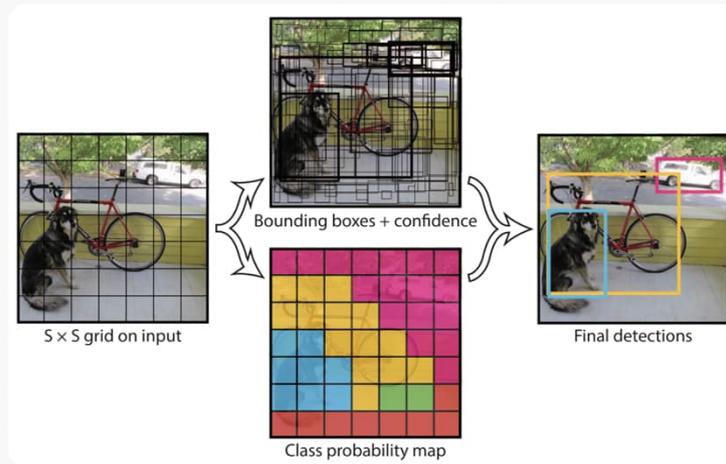
✓ Vorteile:

- Weniger Trainingsdaten erforderlich
- Schnellere Trainingszeiten
- Oft bessere Generalisierung

4

4

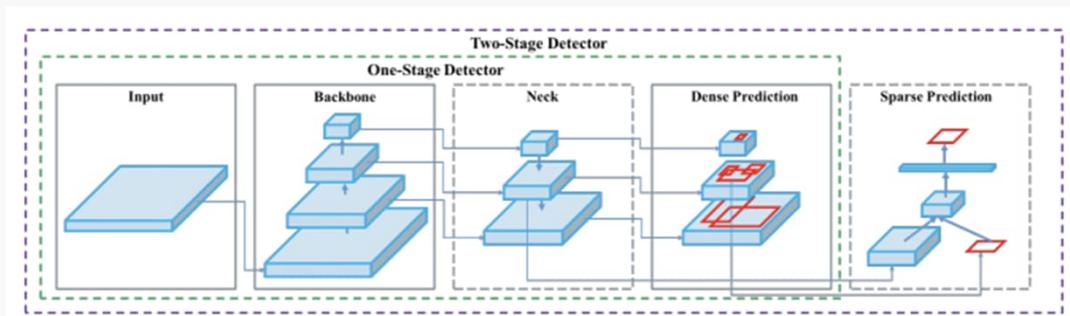
Object Detection Algorithms: YOLO (You only look once) +



5

5

Modellarchitektur YOLOv5 +



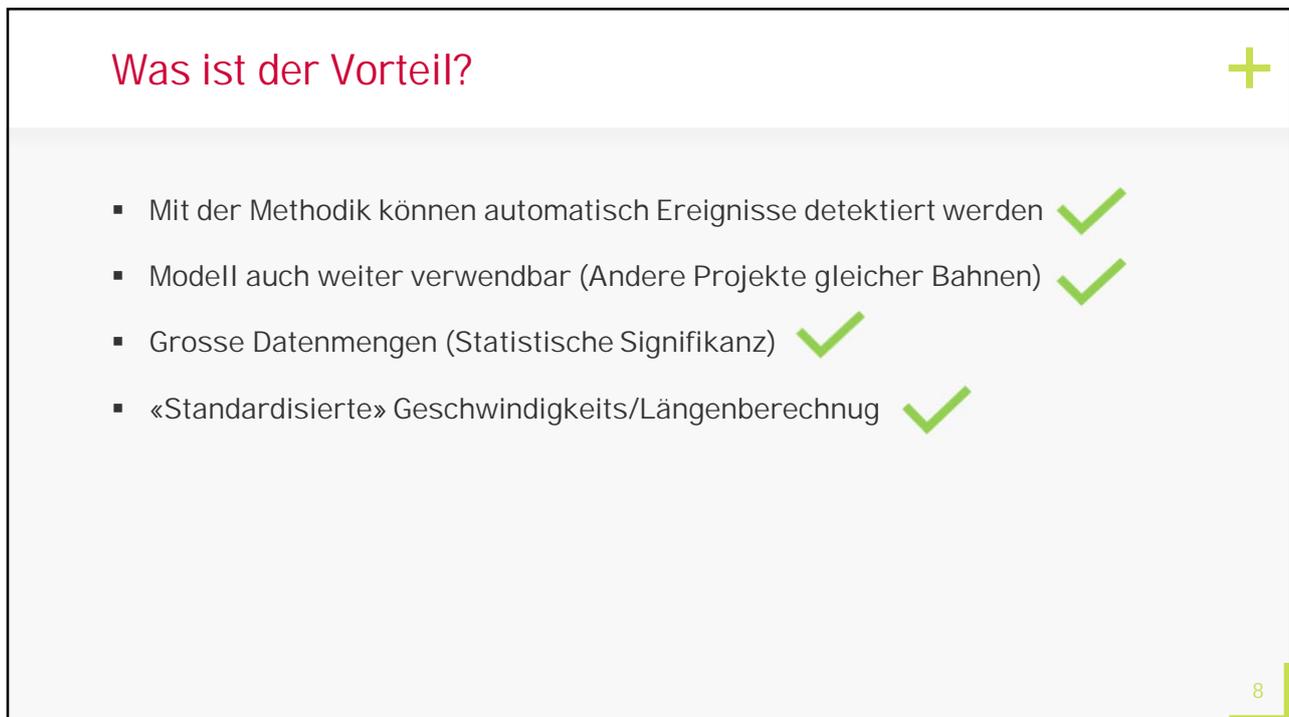
- Echtzeit-Objekterkennung aus Bildern.
- Convolutional Neural Network (CNN)
- Implementiert in 

6

6



7



8

Automatische Videoauswertung - Beispiele



9

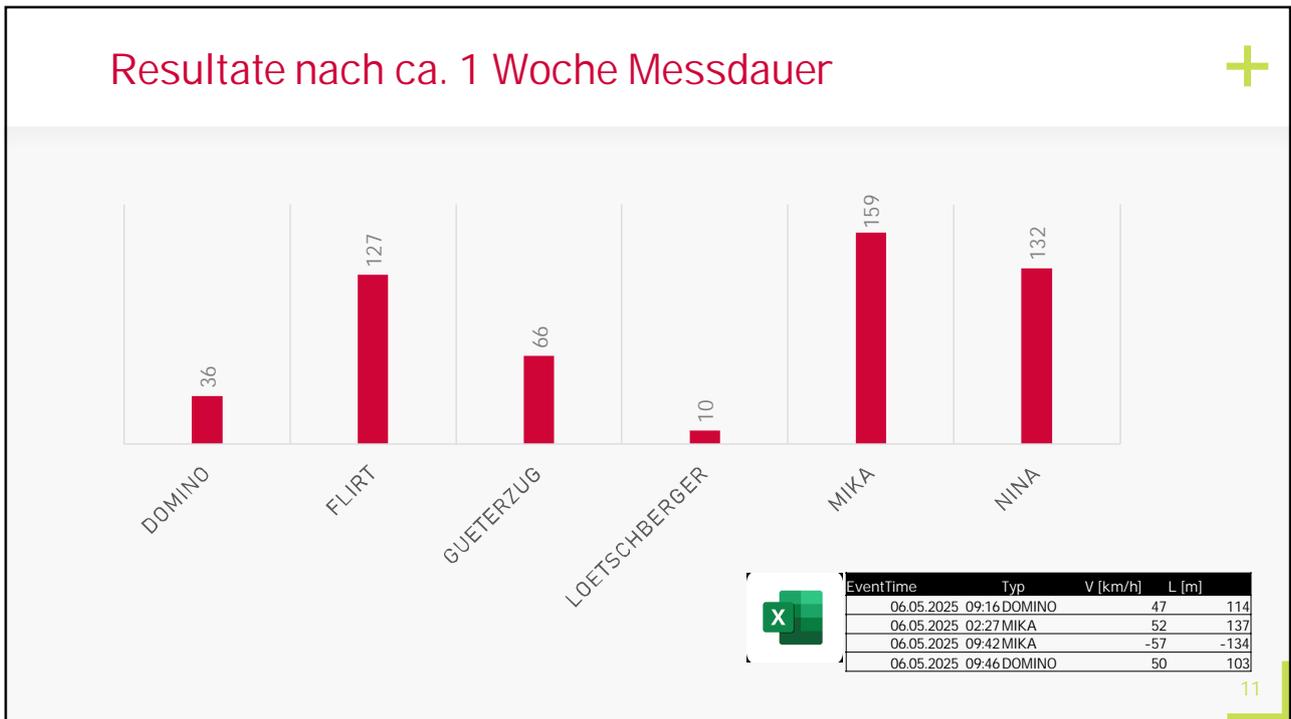
9

Automatische Videoauswertung - Beispiele

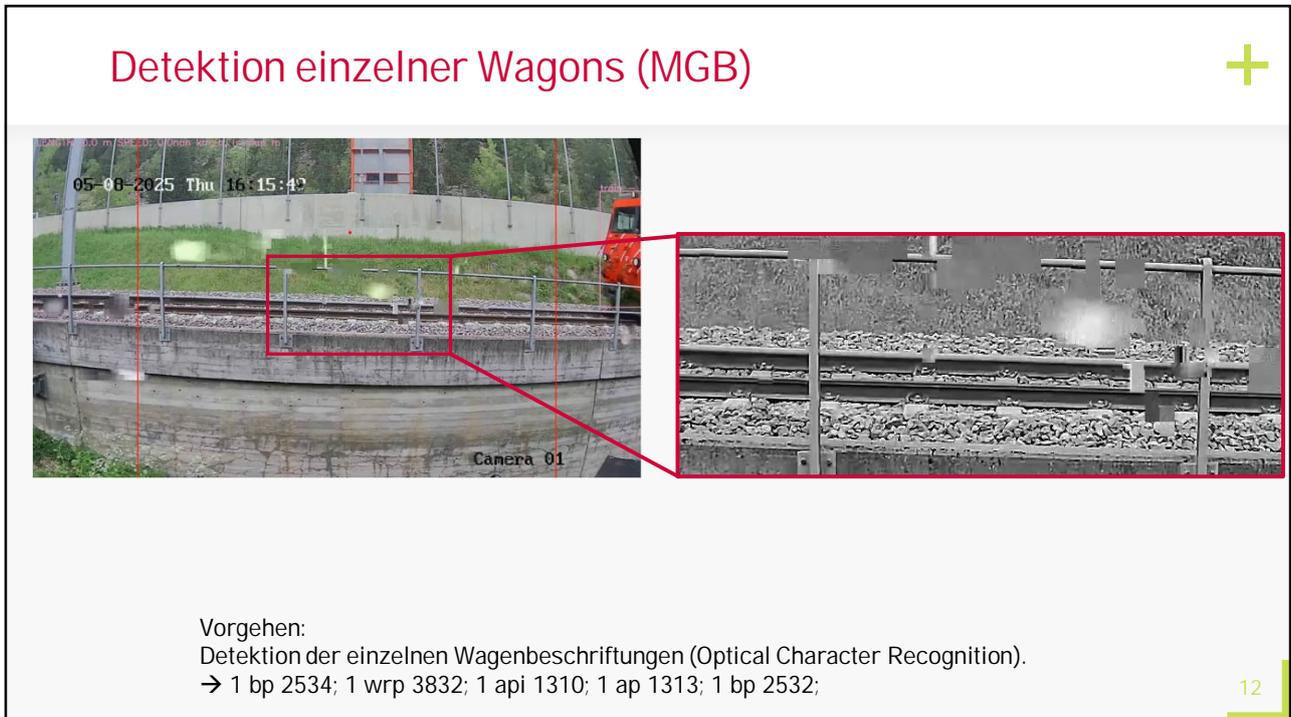


10

10



11



12

Limitationen und Grenzfälle



- Die Auswertung ist generell an Tageslicht gebunden.



13

13

Limitationen und Grenzfälle



- Beschleunigungs- / Bremsvorgänge



14

14

Herausforderungen bei Installation



Datenmenge von Videos schnell sehr gross → Speicherbedarf



- Kann durch Bewegungssensor reduziert werden

Stromversorgung
bei autarken Systemen ist die Reaktionszeit / Vorlauf ungenügend



- Versorgung über Solarpanel?

Datenschutz: Skepsis bei Anwohner



- Gute Kommunikation nötig

Aufstellungsort entscheidend



- Kamera sollte möglichst orthogonal auf die Vorbeifahrt zeigen (Stichwort perspektivische Verzerrung)

15

15

Potenzial und Ausblick



- Objekterkennung auf beliebige Situationen übertragbar. Initialaufwand für Modellbildung beachten
- Vollautomatisierte Analyse: Integration in bestehende Monitoring Systeme zur automatisierten Bildung von Emissionsmodellen
- Echtzeitübertragung und Echtzeitanalyse

16

16