

## Endbericht Kurzfassung

Um schlimme Ereignisse wie Unfälle oder Brände in Straßentunneln möglichst schnell erkennen und angemessen reagieren zu können, sind Straßentunnel den Richtlinien entsprechend mit verschiedensten Sensoren ausgestattet. Diese haben aufgrund ihrer physikalischen Messprinzipien unterschiedliche Vor- und Nachteile, die zu Problemen wie Nicht-Detektion von Ereignissen, hohen Fehlalarmraten und/oder hohen Detektionszeiten führen. Die ASFINAG hat daher mit der Programmlinie VIF2013 über die FFG als Forschungsschwerpunkt die Fusion von Sensordaten in Straßentunnel ausgeschrieben. Der Forschungsantrag TSFu eingereicht von den Unternehmen TB-Traxler GmbH, Baselabs GmbH, PTV Verkehrsconsult GmbH und Transver GmbH hat den Zuschlag seitens der Vergabestelle schließlich Mitte 2014 erhalten.

Das Projekt TSFu verfolgte mehrere Ziele. Zum einen wurde analysiert, welche Sensoren sich für die Fusionsalgorithmen eignen. Parallel dazu wurde die Qualität der Sensordaten analysiert und betrachtet wie sich etwaige Fehlfunktionen auf die geplante Datenfusion auswirken. Für diese beiden ersten Arbeitspakete im Projekt waren die Firma PTV und die Firma Transver verantwortlich. Zum anderen war es das Ziel auf Basis dieser Sensordaten zu untersuchen, welche Art von Fusionsalgorithmen sich für diese Anwendung eignet. Konkret wurde „Lineare SVM“, „RBF SVM“, „Decision Tree“, „Random Forest“, „AdaBoost“, „Naive Bayes“ und „LDA“ ermittelt.

Nachdem die Sensoren und das Exportformat festgelegt waren, konnten vom Konsortialführer in mehreren Sitzungen die Daten als Sensorinformationen exportiert und manuell auf deren „Richtigkeit“ hin überprüft werden. Da es aus Datenschutzgründen nicht möglich war die Videodaten zu exportieren, wurde dies vor Ort in der BZ-Mitte zwischen Tunnel Kirchdorf und Kaltenbach durchgeführt. Gleichzeitig begann die Firma Baselabs in Zusammenarbeit mit TBT mit der Entwicklung der notwendigen Fusionsalgorithmen in Kombination mit einer entsprechenden Demonstrationsumgebung. Da keine online Schnittstellen seitens der ASFINAG zur Verfügung standen, wurden über Importer die CSV-Daten die direkt vom Tunnelkopf exportiert wurden, als Basis für die Erforschung eingesetzt.

Auf Basis der Softwareplattformen von Baselabs und TBT, konnte somit ein „Demonstrator“ entwickelt werden, der es ermöglicht in „quasi“ Echtzeit die unterschiedlichen Detektions- und Sensoralarme in den Fusionsalgorithmus zu laden und daraufhin über die Fusionsalgorithmen zu evaluieren, ob die „richtig positiv“ Alarme bestätigt und die „falsch negativ“ Alarme von der Fusionsalgorithmik richtig behandelt worden wären. Dabei wurde auch ein Algorithmus entwickelt, der „abnormale Zustände“ des Straßentunnels erkennt und vor allem dafür verwendet werden kann, im Vorfeld eines Ereignisses bereits die Aufmerksamkeit von Operatoren durch aktive Informationen zu erhöhen.

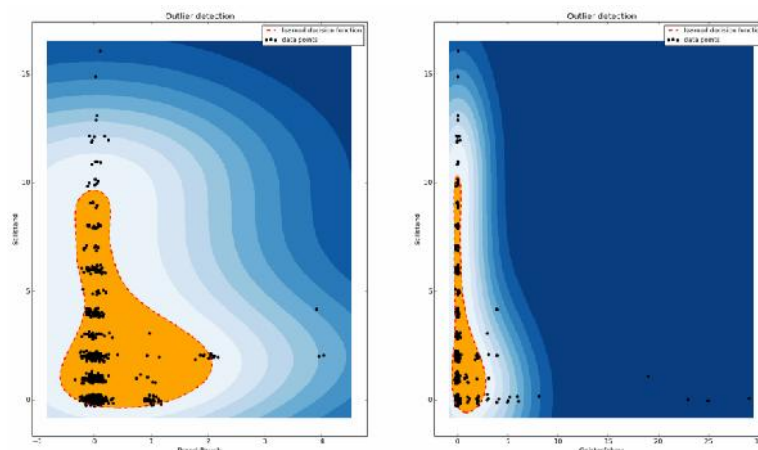
Zusammenfassend kann daher gesagt werden, dass TSFu gezeigt hat, dass die Fusion von Sensor- und Ereignisdaten am Tunnelkopf eine sinnvolle Ergänzung zu heutigen „Logikverschaltungen“ im Prozessleitsystem ist und dass die Möglichkeit der Bestimmung des aktuellen Risikozustandes des Tunnels sowohl präventiv als auch durch Reduktion der Reaktionszeiten eine Verbesserung gegenüber dem Ist-Zustand darstellt.

# Tunnelsicherheit durch intelligente Sensorfusion

## TSFu

Ein Projekt finanziert im Rahmen der  
Verkehrsinfrastrukturforschung 2013  
(VIF2013)

*Sicherheitsbeurteilung durch Sensorfusion eignet sich besonders für die Erkennung ungewöhnlicher Ereignisse. Dies kann betriebliche Prozesse und Reaktionszeiten im Alarmfall wesentlich verbessern. Gleichzeitig wird die Relevanz der Ereignismeldungen erhöht.*



## Impressum:

### Herausgeber und Programmverantwortung:

Bundesministerium für Verkehr, Innovation und Technologie

Abteilung Mobilitäts- und Verkehrstechnologien

Radetzkystraße 2

A - 1030 Wien



ÖBB-Infrastruktur AG

Praterstern 3

A - 1020 Wien



Autobahnen- und Schnellstraßen-Finanzierungs  
Aktiengesellschaft

Rotenturmstraße 5-9

A - 1010 Wien



**Für den Inhalt verantwortlich:**

TB-Traxler GmbH

Dr. Franz Wilhelmstrasse 2A

3500 Krems a.d. Donau



**Programmmanagement:**

Österreichische Forschungsförderungsgesellschaft mbH

Bereich Thematische Programme

Sensengasse 1

A – 1090 Wien



# Tunnelsicherheit durch intelligente Sensorfusion

Ein Projekt finanziert im Rahmen der  
Verkehrsinfrastrukturforschung  
(VIF2013)

**AutorInnen:**

**DI Johannes TRAXLER**

**Dr.-Ing. Georg MAYER**

**Dr. Marcus OBST**

**DI Thomas HEINRICH**

**Auftraggeber:**

Bundesministerium für Verkehr, Innovation und Technologie

ÖBB-Infrastruktur AG

Autobahnen- und Schnellstraßen-Finanzierungs-Aktiengesellschaft

**Auftragnehmer:**

TB-Traxler GmbH

Transver GmbH

Baselabs GmbH

PTV Transport Consult GmbH

## INHALTSVERZEICHNIS

<b>INHALTSVERZEICHNIS .....</b>	<b>5</b>
<b>ABBILDUNGSVERZEICHNIS .....</b>	<b>8</b>
<b>1 PROJEKTDATEN .....</b>	<b>9</b>
<b>2 EINLEITUNG .....</b>	<b>10</b>
<b>2.1 SYNOPSIS.....</b>	<b>10</b>
<b>3 ANFORDERUNGSANALYSE.....</b>	<b>11</b>
<b>3.1 EREIGNISARTEN IM TUNNEL.....</b>	<b>11</b>
3.1.1 ÜBERHÖHTE / NICHT ANGEPASSTE GESCHWINDIGKEIT .....	11
3.1.2 HOHE VERKEHRSDICHTE / STOCKENDER VERKEHR .....	11
3.1.3 STAU, STAUGEFAHR.....	12
3.1.4 LANGSAMFAHRER / LANGSAMES FAHRZEUG.....	13
3.1.5 FAHRZEUGSTILLSTAND (EINZELFAHRZEUG).....	13
3.1.6 BELEGUNG PANNENBUCHT .....	14
3.1.7 FALSCHFAHRER / GEISTERFAHRER.....	15
3.1.8 FAHRBAHNFREMDE GEGENSTÄNDE AUF FAHRBAHN / PANNENBUCHT .....	15
3.1.9 MENSCH / TIER AUF DER FAHRBAHN.....	16
3.1.10 AUSLÖSUNG HÖHENKONTROLLE .....	16
3.1.11 GLATTE FAHRBAHN .....	17
3.1.12 UNFALL/KOLLISION.....	17
3.1.13 NUTZUNG VON NOTRUFEINRICHTUNGEN .....	18
3.1.14 ÜBERHITZTES FAHRZEUG .....	21
<b>3.2 FEUER / FAHRZEUGBRAND .....</b>	<b>21</b>
<b>3.3 GEFAHRGUTFREISETZUNG.....</b>	<b>22</b>
3.3.1 TS-GRENZWERTÜBERSCHREITUNG (SICHTEINSCHRÄNKUNG, TRÜBUNG, RAUCH).....	23

3.3.2	CO-GRENZWERTÜBERSCHREITUNG .....	24
3.3.3	NO <sub>x</sub> -GRENZWERTÜBERSCHREITUNG .....	25
3.3.4	AUSFALL LÜFTUNGSANLAGE .....	25
3.3.5	AUSFALL BELEUCHTUNGSANLAGE .....	26
3.3.6	AUSFALL ENERGIEVERSORGUNG.....	28
3.3.7	ZUSAMMENFASSUNG UND PRIORISIERUNG DER EREIGNISARTEN .....	30
<b>3.4</b>	<b>ANFORDERUNGSMATRIX.....</b>	<b>34</b>
<b>4</b>	<b>QUALITÄTSUNTERSUCHUNG.....</b>	<b>38</b>
<b>4.1</b>	<b>METHODIK.....</b>	<b>38</b>
<b>4.2</b>	<b>QUALITÄTSUNTERSUCHUNG VERKEHRSDATENERFASSUNG (INDUKTIVSCHLEIFEN).....</b>	<b>40</b>
4.2.1	OSTRICHTUNG .....	40
4.2.2	WESTRICHTUNG.....	41
4.2.3	FAZIT.....	41
<b>4.3</b>	<b>QUALITÄTSUNTERSUCHUNG EREIGNISDETEKTION (VIDEO- UND SCHALLDETEKTION) ....</b>	<b>41</b>
<b>5</b>	<b>DATENFUSION .....</b>	<b>42</b>
<b>5.1</b>	<b>MOTIVATION .....</b>	<b>42</b>
<b>5.2</b>	<b>KONZEPT UND METHODIK.....</b>	<b>42</b>
5.2.1	OBJEKTBASIERTE DATENFUSION MITTELS BASELABS CREATE.....	43
5.2.2	ZUSAMMENFASSUNG .....	46
5.2.3	DATENANALYSE .....	47
5.2.4	DATENFUSION AUF MERKMALSEBENE.....	48
<b>5.3</b>	<b>UMSETZUNG .....</b>	<b>52</b>
5.3.1	DATENLABELING.....	52
5.3.2	MERKMALSVEKTOR .....	53
5.3.3	EVENT-KLASSIFIZIERUNG.....	54
<b>5.4</b>	<b>DATENGRUNDLAGE.....</b>	<b>56</b>
5.4.1	BEISPIELERGEBNIS FÜR KLASSIFIKATOR AUF STAU-EREIGNIS .....	57
<b>6</b>	<b>SCHNITTSTELLEN UND INTEGRATION.....</b>	<b>59</b>

<b>6.1</b>	<b>DATENEXPORT.....</b>	<b>59</b>
<b>6.2</b>	<b>SCHNITTSTELLENINTEGRATION.....</b>	<b>61</b>
<b>7</b>	<b>DEMONSTRATOR.....</b>	<b>63</b>
<b>8</b>	<b>ERGEBNISSE DATENFUSION .....</b>	<b>66</b>
8.1.1	KLASSIFIKATIONSERGEBNISSE .....	66
8.1.2	ERKENNUNG UNGEWÖHNLICHER SITUATIONEN (UNUSUAL EVENT DETECTION) .....	77
<b>8.2</b>	<b>BEISPIELEREIGNISSE.....</b>	<b>81</b>
	<b>LITERATUR .....</b>	<b>86</b>
	<b>ANHANG – I.....</b>	<b>87</b>



## ABBILDUNGSVERZEICHNIS

Tabelle 1: Priorisierung von Ereignissen .....	30
Tabelle 2: Priorisierungsmatrix Ereignisarten .....	32
Tabelle 3: Sehr wichtige Ereignisarten .....	32
Tabelle 4: Ereignisarten im Tunnel Kirchdorf .....	33
Tabelle 5: TSFu - Anforderungsmatrixüberblick .....	36
Tabelle 6 Statistik für die Labels für die Klasse langsam fahrendes Fahrzeug .....	69
Tabelle 7: Ergebnisse des Klassifikators "langsam fahrendes Fahrzeug" auf dem Testset .....	70
Tabelle 8 Statistik zu den vorhandenen Labels für die Klasse „Rauch im Tunnel“ .....	71
Tabelle 9: Ergebnisse des Klassifikators "Rauch im Tunnel" auf dem Testset .....	72
Tabelle 10 Statistik zu den vorhandenen Labels für die Klasse „stehendes Fahrzeug“ ....	74
Tabelle 11 Ergebnisse des Klassifikators " stehendes Fahrzeug" auf dem Testset .....	75
Tabelle 12 Statistik zu den vorhandenen Labels für die Klasse „Geisterfahrer“ .....	76
Tabelle 13 Ergebnisse des Klassifikators "Geisterfahrer" auf dem Testset .....	77
Tabelle 14 Ergebnis der Unusual Event detections .....	78
Tabelle 15: Unfall am 18.2.2015 Chronologie .....	84

## 1 PROJEKTDATEN

<b>Kurztitel</b>	TSFu
<b>Langtitel</b>	Tunnelsicherheit durch intelligente Sensorfusion
<b>Projektnummer</b>	845671
<b>Programm/ Programmlinie</b>	VIF2013
<b>AntragstellerIn</b>	TB-Traxler GmbH, DI Johannes Traxler
<b>ProjektpartnerInnen</b>	Transver GmbH Baselabs GmbH PTV Transport Consult GmbH
<b>Berichtszeitraum</b>	von 1.07.2014 bis 30.10.2015
<b>Anzahl Forscher/Forscherinnen</b>	Weiblich: ...1..... Total: ...0,5..... (VZÄ) Position (z.B. Projektleitung, -mitarbeit): Projektmitarbeiterin.....

## 2 EINLEITUNG

Dieses Dokument umfasst den im Leitfaden VIF2013 geforderten wissenschaftlichen Endbericht, der die erzielten Ergebnisse aus wissenschaftlicher und Projektsicht reflektiert. Diese Reflexion umfasst eine Detaillierung der wissenschaftlichen Zielerreichung der im Projektantrag avisierten Innovationen.

### 2.1 Synopsis

Ereignisse wie z.B. Unfälle oder Brände in Straßentunneln können besonders schlimme Folgen haben. Um diese Ereignisse möglichst schnell erkennen und angemessen reagieren zu können, sind Straßentunnel den Richtlinien entsprechend mit verschiedensten Sensoren ausgestattet. Diese Sensoren haben aufgrund ihrer physikalischen Messprinzipien unterschiedliche Vor- und Nachteile, die zu Problemen wie Nicht-Detektion von Ereignissen, hohen Detektionszeiten und/oder Fehlalarmen führen. Das Ziel des Projektes TSFu war es daher, durch die intelligente Fusion ausgewählter Sensoren diese Probleme zu beheben und somit gefährliche Ereignisse schneller und zuverlässiger erkennen zu können.

Zur Überwachung von Straßentunneln kommen sehr viele unterschiedliche Sensoriken zum Einsatz. Jedes Sensorsystem funktioniert hierbei innerhalb der gesteckten Anforderungsziele und erfüllt eine definierte Detektions- bzw. Fehldetektionsrate (auch Sensitivität und Spezifität genannt). Da die einzelnen Systeme jedoch entkoppelt sind, d.h. unabhängig voneinander die jeweiligen Ereignistypen analysieren, addieren sich statistisch z.B. die Fehlalarmraten mit jedem weiteren Subsystem. In einer gekoppelten Betrachtung durch die Fusion von einzelnen Sensordaten erhöht sich die Anzahl unabhängiger Eingangswerte für ein zu detektierendes Ereignis und führt somit zu einer Reduzierung der Fehlalarmrate bzw. Verbesserung der Zuverlässigkeit für die Detektion eines Ereignisses.

**3 ANFORDERUNGSANALYSE** Im Projekt TSFu wurde der Tunnel Kirchdorf an der S35 in der Steiermark als Testobjekt seitens der ASFINAG benannt und auch entsprechend der Zugang zu den Daten des Tunnels ermöglicht. Grund für diese Auswahl war, dass der Tunnel Kirchdorf der erste weltweit mit akustischer Ereignisdetektion ausgerüstet ist. Dies ist vor allem im Hinblick auf die Fusionsmöglichkeiten zwischen den Subsystemen interessant, da davon ausgegangen wurde, dass sich die unterschiedlichen Sensormodalitäten in Bezug auf die Relevanz der Ereignisinformationen verstärken können.

Um die Anforderungen an eine Sensorfusionsalgorithmik für einen höherrangigen Straßentunnel und im konkreten Fall für den Tunnel Kirchdorf definieren zu können ist es erforderlich die unterschiedlichen Ereignistypen zu definieren und daraus dann die notwendigen Fusionsalgorithmen abzuleiten. Im Folgenden werden daher für Tunnel typische Ereignisarten systematisch aufbereitet und beschrieben. Darauf aufbauend werden Möglichkeiten zu deren Erfassung aufgezeigt, sowie die nach erfolgter Detektion erforderlichen Aktionen bzw. Anweisungen kurz beschrieben. Grundlage bildet das normative Regelwerk sowie die Planungshandbücher der ASFINAG.

### 3.1 Ereignisarten im Tunnel

#### 3.1.1 Überhöhte / nicht angepasste Geschwindigkeit

Überhöhte Geschwindigkeit ist immer wieder Ursache von schweren Unfällen. Da die kinetische Energie eines Fahrzeugs exponentiell mit der Geschwindigkeit zunimmt, kommt der Geschwindigkeitsüberwachung als präventive Maßnahme eine bedeutende Rolle zu.

Mögliche Messgeräte:

- Videodetektion
- Radar/Laser Sensoren

Aktion:

Erzieherische Maßnahmen wie z.B.

- Bußgeldbescheid
- Entzug der Fahrerlaubnis

#### 3.1.2 Hohe Verkehrsdichte / stockender Verkehr

Aufgrund einer hohen Verkehrsdichte bzw. von stockendem Verkehr im Tunnel, steigt die Anzahl potentiell betroffener Personen im Fall eines Brandes bzw. eines Ereignisses mit einer Gefahrgutfreisetzung. Außerdem kann dadurch der Zugang von Rettungskräften

erschwert sein. Daher sind derartige Situationen auf ein Minimum zu begrenzen bzw. geeignete Maßnahmen zur Reduzierung der Risiken einzuleiten.

Mögliche Messgeräte:

- Videodetektion
- Induktionsschleifen
- Radar/Laser Sensoren

Aktion:

- Anhalten des nachfließenden Verkehrs vor dem Tunnelportal (Einfahrtsportal)

Anweisung:

- Tunnelsperre laut RVS 09.02.22, Nr. 23
- Aufschaltung der Kameras im betroffenen Bereich
- Start Alarmaufzeichnung
- Lüfterprogramme nach Bedarf

### **3.1.3 Stau, Staugefahr**

Ein Stau im Tunnel stellt eine besondere Gefährdung dar, da durch nachfolgende Verkehrsteilnehmer ein Stauende ggf. nicht rechtzeitig erkannt wird und somit die Gefahr von Auffahrunfällen besteht. Dies gilt insbesondere vor dem Hintergrund, dass Abstände und Geschwindigkeiten in Tunneln durch die Verkehrsteilnehmer oftmals nicht richtig eingeschätzt werden. Aufgrund der hohen kinetischen Energie von auf das Stauende auffahrenden Fahrzeugen nimmt außerdem die Gefährdung von Bränden infolge einer Kollision zu. Dem Erkennen von Stau kommt daher eine bedeutende Rolle zu.

Mögliche Messgeräte:

- Videodetektion
- Induktionsschleifen
- Radar/Laser Sensoren

Aktion:

- Der nachfließende Verkehr ist vor dem Tunnelportal anzuhalten.

Anweisung:

- Tunnelsperre laut RVS 09.02.22, Nr. 23
- Aufschaltung der Kameras im betroffenen Bereich

- Start Alarmaufzeichnung
- Lüfterprogramme nach Bedarf

### **3.1.4 Langsamfahrer / Langsames Fahrzeug**

Aufgrund großer Geschwindigkeitsdifferenzen zwischen frei fließendem Verkehr und einem langsam fahrenden Fahrzeug besteht die Gefahr von Auffahrkollisionen. Da im Fall einer Kollision die kinetische Energie des auffahrenden Fahrzeugs innerhalb kürzester Distanz abgebaut werden muss, steigt die Gefahr von schweren Unfällen bzw. Ereignissen mit Brandfolge. Das Erkennen von langsam fahrenden Fahrzeugen, sowie die Warnung weiterer Verkehrsteilnehmer vor dieser Gefährdung ist für einen sicheren Betrieb von großer Bedeutung.

#### Mögliche Messgeräte:

- Videodetektion
- Induktionsschleifen
- Radar/Laser Sensoren

#### Aktion:

- Es wird keine automatische Aktion gestartet.

#### Anweisung (optional):

- VLSA gelb blinken
- Geschwindigkeit um eine Stufe senken
- Aufschaltung der Kameras im betroffenen Bereich
- Start Alarmaufzeichnung der Kameras

### **3.1.5 Fahrzeugstillstand (Einzelfahrzeug)**

Der Stillstand eines einzelnen Fahrzeugs innerhalb eines normal fließenden Verkehrsstromes stellt eine äußerst große Gefahrenquelle für den nachfolgenden Verkehr dar. Aufgrund einer maximalen Relativgeschwindigkeit zwischen stillstehendem Fahrzeug und darauf zufahrendem Verkehr sind Auffahrunfälle mit schwersten Unfallfolgen bzw. mit Bränden sehr wahrscheinlich. Eine schnelle Detektion des liegengebliebenen Fahrzeugs, sowie die unmittelbare Warnung der zufahrenden Verkehrsteilnehmer vor der Gefahrenstelle ist daher zwingend notwendig.

#### Mögliche Messgeräte:

- Videodetektion
- Induktionsschleifen

- Radar/Laser Sensoren

Aktion:

- Es wird keine automatische Aktion gestartet.

Anweisung (optional):

- VLSA gelb blinken
- Geschwindigkeit um eine Stufe senken
- Aufschaltung der Kameras im betroffenen Bereich
- Start Alarmaufzeichnung der Kameras

### 3.1.6 Belegung Pannenbucht

Das Anfahren einer Pannenbucht durch Verkehrsteilnehmer kann verschiedenste Ursachen haben. Das Spektrum kann hierbei von technischem Defekt, über medizinischem Notfall bis zum Abstellen eines brennenden Fahrzeugs reichen. Eine schnelle Erkennung ist daher zum Einleiten entsprechender Maßnahmen zwingend erforderlich. Die PLaNT 170.020.2000<sup>1</sup>, fordert die Belegung einer Pannenbucht vom Stillstand eines Fahrzeugs bis zur Detektion innerhalb von 5 Sekunden zu detektieren. Da Fahrzeuge in den mit Verkehr belegten Fahrstreifen reichen können oder sich im Bereich der Pannenbucht umherlaufende Personen befinden, ist der nachfolgende Verkehr vor der Pannenbucht zu warnen.

Mögliche Messgeräte:

- Videodetektion
- Induktionsschleife

Aktion:

Der nachfließende Verkehr ist vor der Pannenbucht zu warnen.

Anweisung:

- Schaltbild laut RVS 09.02.22, Nr. 27 -30
- Aufschaltung der Kameras im betroffenen Bereich
- Start Alarmaufzeichnung
- Pannenbuchtbeleuchtung auf 100%

---

<sup>1</sup> PLaNT (170.020.2000) Abschnitt: 3.16.4.5.2 Stillstand

### 3.1.7 Falschfahrer / Geisterfahrer

Als Falschfahrer bzw. Geisterfahrer werden Fahrzeuge bezeichnet, die sich auf einer Fahrspur oder einem Fahrstreifen entgegen der vorgeschriebenen Fahrtrichtung bewegen.<sup>2</sup> Dies stellt ein schwerwiegendes Ereignis dar, das zur Gefährdung anderer Verkehrsteilnehmer führen kann. Aufgrund der sehr großen Relativgeschwindigkeiten ist im Fall von Kollisionen mit schwerwiegenden Unfallfolgen bzw. Bränden zu rechnen. In der Geschwindigkeitsmessung wird dieses Ereignis durch eine negative Geschwindigkeit angezeigt.

#### Mögliche Messgeräte:

- Videodetektion
- Induktionsschleifen
- Radar/Laser Sensoren

#### Aktion:

Der nachfließende Verkehr ist vor dem Tunnelportal anzuhalten.

#### Anweisung:

- Tunnelsperre laut RVS 09.02.22, Nr. 19
- Aufschaltung der Kameras im betroffenen Bereich
- Start Alarmaufzeichnung

### 3.1.8 Fahrbahnfremde Gegenstände auf Fahrbahn / Pannenbucht

Fahrbahnfremde Gegenstände, wie beispielsweise verlorene Ladungen, können zu unvorhersehbaren Reaktionen der Verkehrsteilnehmer (z.B. abruptes Bremsen, plötzliche Spur- / Fahrstreifenwechsel, Ausweichen in den Gegenverkehr oder zu Kollisionen mit diesen Gegenständen führen. Fahrbahnfremde Gegenstände sind daher möglichst zeitnah zu detektieren und der nachfließende Verkehr vor der Gefahrenstelle zu warnen. Nach den PLaNT 170.020.2000<sup>3</sup> sind daher fahrbahnfremde Gegenstände innerhalb von 10 s zu detektieren.

#### Mögliche Messgeräte:

- Videodetektion

---

<sup>2</sup> PLaNT (170.020.2000) Abschnitt: 3.16.4.5.1 Geisterfahrer

<sup>3</sup> PLaNT (170.020.2000) Abschnitt: 3.16.4.5.6 Fahrbahnfremde Gegenstände



Aktion:

Warnung der zufahrenden Verkehrsteilnehmer vor der Gefahrenstelle

Anweisung:

- VLSA gelb blinken
- Geschwindigkeit um eine Stufe senken bis zum Ereignisort
- Aufschaltung der Kameras im betroffenen Bereich
- Start Alarmaufzeichnung der Kameras

### **3.1.9 Mensch / Tier auf der Fahrbahn**

Menschen oder Tiere auf der Fahrbahn gefährden sich selbst und andere Verkehrsteilnehmer. Sie können unvorhersehbare Fahrmanöver auslösen oder durch den fließenden Verkehr erfasst werden. Personen auf der Fahrbahn können auch ein Indiz für vorausgegangene Ereignisse wie beispielsweise Unfall, Panne etc. sein. Zu Ihrem Schutz ist das Ereignis Mensch / Tier auf der Fahrbahn möglichst zeitnah zu detektieren und die weiteren Verkehrsteilnehmer vor der Gefahr zu warnen.

Mögliche Messgeräte:

- Videodetektion

Aktion:

Warnung der zufahrenden Verkehrsteilnehmer vor der Gefahrenstelle

Anweisung:

- VLSA gelb blinken
- Geschwindigkeit um eine Stufe senken bis zum Ereignisort
- Aufschaltung der Kameras im betroffenen Bereich
- Start Alarmaufzeichnung der Kameras

### **3.1.10 Auslösung Höhenkontrolle**

Die Höhenkontrolle dient zum Schutz der an den Tunneldecken installierten betriebs- und sicherheitstechnischen Einrichtungen vor überhohen Fahrzeugen. Sie besteht i.d.R. aus zwei Wechsellichtschranken, einer Induktionsschleife sowie einer Auswerteeinheit. Nach Auslösung durch ein zu hohes Fahrzeug, ist dieses durch Rotschaltung gemäß RVS 09.02.22 vor dem Einfahrtsportal anzuhalten. In besonderen Fällen können auch mechanischen Höhenkontrollen zum Einsatz kommen.

#### Mögliche Messgeräte:

- Wechsellichtschranken + Induktionsschleife
- Laser Reflektions-Lichtschranken (*Laser-Sensor*)
- Infrarot Einweg-Lichtschranken (*1 Sender und 1 Empfänger*)
- Infrarot Doppel-Lichtschranken (*2 Sender und 2 Empfänger*)

#### Aktion:

Das auslösende Fahrzeug muss vor dem Tunnelportal gestoppt werden.

#### Anweisung:

- Portalsperre laut RVS 09.02.22, Nr. 14
- Aufschaltung der Kameras im betroffenen Bereich (Höhenkontrolle, Portal)
- Start der Alarmaufzeichnung

### **3.1.11 Glatte Fahrbahn**

Durch überfrierende Nässe aufgrund von Schleppwassereintrag oder eindringendes Berg- oder Grundwasser kann die Verkehrssicherheit stark beeinträchtigt sein. Verkehrsteilnehmer können die Kontrolle über ihr Fahrzeug infolge reduzierter Brems- und Lenkwirkung verlieren und mit Fahrzeugen kollidieren oder ins Schleudern geraten. Der Fahrbahnzustand ist daher insbesondere im Portalbereich über geeignete Detektoren zu erfassen. Im Fall von Glättebildung ist zulässige Geschwindigkeit abzusenken oder die Einfahrt in den Tunnel zu unterbinden.

#### Mögliche Messgeräte:

- Umweltdatenerfassung
- Temperaturfühler

#### Aktion:

- Geschwindigkeitsreduktion
- Tunnelsperrung

### **3.1.12 Unfall/Kollision**

Unfälle stellen ein äußerst schwerwiegendes Ereignis in Tunneln dar und erfordern das umgehende Einleiten von Verkehrssteuerungs-, Sicherungs- und Rettungsmaßnahmen. Sie können auch Ausgangspunkt für noch gravierendere Ereignisse wie Brände und

Gefahrgutfreisetzen bilden. Einer zeitnahen Erkennung von Unfällen kommt daher eine zentrale Rolle bei der Überwachung von Tunneln zu.

Mögliche Messgeräte:

- Akustische Unfalldetektion (AKUT)
- Videodetektion von Stillstand bzw. Objekt auf der Fahrbahn

Aktion:

- Fahrstreifensperrung / Tunnelsperrung

### **3.1.13 Nutzung von Notruffeinrichtungen**

Notrufnischen / Notrufrkabinen dienen der Kommunikation mit der überwachenden Stelle und beinhalten folgende überwachte Komponenten

- Notruftür
- Notruffeinrichtung
- Handgefahrenmelder SOS
- Handgefahrenmelder Brand
- Fach für Feuerlöscher

#### **3.1.13.1 Öffnung Tür der Notrufnische**

Das Öffnen der Notrufnischentür zeigt an, dass sich eine Person in eine Notrufnische begeben hat, um Hilfe zu erhalten. Ursachen hierfür können sein: Medizinischer Notfall, technischer Defekt am Fahrzeug, Unfall, etc. Das Öffnen einer Notrufnischentür ist somit ein Indiz für ein vorausgegangenes Ereignis und weist auf Personen im Fahrraum hin.

Mögliche Messgeräte:

- Türkontakt

Aktion:

Warnung des nachkommenden Verkehrs.

Anweisung:

- Schaltbild laut RVS 09.02.22, Nr. 24
- Aufschaltung der Kameras im betroffenen Bereich
- Start Alarmaufzeichnung
- Innenstreckenbeleuchtung auf 100%

### **3.1.13.2 Nutzung von Notruffeinrichtungen**

Notruffeinrichtungen dienen zur Kommunikation mit einer ständig besetzten Stelle. Durch das Betätigen der Notruffeinrichtung erfolgen der Verbindungsaufbau zur BZ / ÜZ sowie die Lokalisierung der Sprechstelle. Das Betätigen der Notruffeinrichtung weist auf ein vorangegangenes Ereignis sowie auf Personen im Fahrraum hin.

#### Mögliche Messgeräte:

- Taster für Hörerabnahme bzw. Gabelumschalter

#### Aktion:

- Warnung des nachfolgenden Verkehrs

#### Anweisung:

- Schaltbild laut RVS 09.02.22, Nr. 24
- Aufschaltung der Kameras im betroffenen Bereich
- Start Alarmaufzeichnung
- Innenstreckenbeleuchtung auf 100%

### **3.1.13.3 Betätigung SOS-Taster**

Um im Bedarfsfall Hilfe anfordern zu können, sind an den Außenseiten von Notruffeinrichtungen barrierefrei bedienbare Drucktaster angebracht. Durch das Betätigen des SOS-Tasters signalisiert eine Person, dass sie Hilfe vor Ort benötigt. Der Auslöseort wird in der BZ / ÜZ angezeigt.

#### Mögliche Messgeräte:

- Handgefahrenmelder SOS

#### Aktion:

- Warnung des nachfolgenden Verkehrs.

#### Anweisung:

- Schaltbild laut RVS 09.02.22, Nr. 24
- Aufschaltung der Kameras im betroffenen Bereich
- Start der Alarmaufzeichnung
- Innenstreckenbeleuchtung auf 100%

### **3.1.13.4 Betätigung Feueralarm (Brand-Taster)**

Zur Meldung eines Brandes sind an den Außenseiten von Notruffeinrichtungen barrierefrei bedienbare Drucktaster angebracht. Das Betätigen des Tasters löst einen Brandalarm aus und zeigt in der BZ / ÜZ den Ort des gedrückten Tasters an.

Mögliche Messgeräte:

- Handgefahrenmelder Brand

Aktion:

- Feueralarmprogramm auslösen

Anweisung:

- Schaltbild laut RVS 09.02.22, Nr. 10 -12
- Aufschaltung der Kameras im betroffenen Bereich
- Start Alarmaufzeichnung
- Innenstreckenbeleuchtung auf 100%

**3.1.13.5 Öffnung des Feuerlöschabteils**

Das Öffnen Feuerlöscher-Tür zeigt an, dass eine Person beabsichtigt, einen Feuerlöscher aus dem Feuerlöschabteil zu entnehmen. Es deutet auf ein Brandereignis (Entstehungsbrand) in einem bestimmten Abschnitt und weist auf Personen im Fahrraum hin.

Mögliche Messgeräte:

- Türkontakt

Aktion:

- Warnung des nachfolgenden Verkehrs

Anweisung:

- Schaltbild laut RVS 09.02.22, Nr. 24
- Aufschaltung der Kameras im betroffenen Bereich
- Start Alarmaufzeichnung
- Innenstreckenbeleuchtung auf 100%

**3.1.13.6 Entnahme Feuerlöscher**

Durch die Entnahme eines Feuerlöschers wird in der BZ / ÜZ der Ort der Entnahme angezeigt und ein Brandalarm ausgelöst. Die Tunnelsperrung wird aktiviert und die Tunnelbeleuchtung auf ihre höchste Beleuchtungsstufe geschaltet. Außerdem erfolgt die automatische Aufschaltung der in diesem Bereich angeordneten Videokameras.

Mögliche Messgeräte:

- Entnahmekontakt

Aktion:

- Feueralarmprogramm auslösen

Anweisung:

- Schaltbild laut RVS 09.02.22, Nr. 10 -12
- Aufschaltung der Kameras im betroffenen Bereich
- Start Alarmaufzeichnung
- Innenstreckenbeleuchtung auf 100%

### **3.1.14 Überhitztes Fahrzeug**

Fahrzeuge mit überhitzten Fahrzeugteilen wie Motor, Bremsen, Räder oder signifikanter Wärmeentwicklung im Laderaum stellen während einer Tunneldurchfahrt eine potentielle Brandgefahr dar. Dem rechtzeitigen Erkennen und Anhalten von überhitzten Fahrzeugen vor der Einfahrt in einen Tunnel kommt daher eine besondere Bedeutung hinsichtlich des präventiven Brandschutzes zu.

Mögliche Messgeräte:

- Videokameras
- Infrarotkameras
- Laserscanner
- Thermoscanner

Aktion:

- Anhalten und Abkühlen des überhitzten Fahrzeugs am Ort der Überprüfung

## **3.2 Feuer / Fahrzeugbrand**

Fahrzeugbrände in Tunneln stellen aufgrund der Rauch- und Wärmeentwicklung eine außerordentliche Bedrohung für die Tunnelnutzer dar. Zahlreiche Sicherheitssysteme zielen daher darauf ab, Brände möglichst frühzeitig zu erkennen um die Verkehrsteilnehmer durch Anweisungen und Sicherheitseinrichtungen zu bestimmtem Verhalten zu bewegen. Während der Entstehungsphase sind Brände meist durch eine starke Rauchentwicklung gekennzeichnet. Die Rauchdetektion ist daher üblicherweise das primäre Ereignis eines Fahrzeugbrandes. Im weiteren Verlauf schreitet der Brand allerdings voran bis es zu einer offenen Flamme kommt.

Mögliche Messgeräte:

- Linienbrandmeldekabel (= Temperaturmesswerte)
- Videodetektion Brand-/Rauchdetektion

- Rauchmelder
- Trübsichtmessgeräte
- Betätigung des Handgefahrenmelders Brand
- Entnahme eines Feuerlöschers
- Absetzen eines Notrufs

Aktion:

- Eine automatische Tunnelsperre wird ausgelöst.

Anweisung:

- Tunnelsperre laut RVS 09 02 22, Nr. 6-9,
- Innenstreckenbeleuchtung auf 100%
- Auslösen entsprechender Lüfterprogramme
- Aufschaltung der Kameras im betroffenen Bereich
- Start der Alarmaufzeichnung, Ansteuerung von Querschlagtüren (bei Offenstellung)

### **3.3 Gefahrgutfreisetzung**

Im Fall einer Gefahrgutfreisetzung sind Tunnelnutzer durch verschiedene Einwirkungen bedroht. Bei Bränden infolge einer Freisetzung von großen Mengen an brennbaren Flüssigkeiten oder druckverflüssigter Gase steht die Bedrohung durch Wärmeeinwirkung im Vordergrund. Im Fall von Explosionen dominiert die Druckwirkung und bei Schadgasfreisetzungen die toxische Wirkung. Hinsichtlich der Ausbreitungscharakteristik bestehen sowohl in zeitlicher Hinsicht als auch im Hinblick auf das Schichtausbildungsverhalten signifikante Unterschiede. Während Explosionen innerhalb von Millisekunden ablaufen, vollziehen sich schnell ablaufende Brände innerhalb von mehreren Minuten. Hinsichtlich der Schichtung bestehen deutliche Unterschiede zwischen der Ausbreitung von Rauchgasen und Schadgasen. Während Rauchgase aufgrund des thermischen Auftriebs zur Tunneldecke aufsteigen, breiten sich Schadgase, die in der Regel eine höhere Dichte als Luft aufweisen, im unteren Tunnelquerschnittsbereich aus. Sämtlichen Freisetzungen gemein ist jedoch, dass die Tunnelstruktur lediglich eine Ausbreitung in Längsrichtung zulässt und somit Tunnelnutzer den Einwirkungen aussetzt. Die Freisetzung selbst als auch die Art der Gefahrgüter ist daher möglichst schnell zu detektieren.

Mögliche Messgeräte:

- Gefahrgutplakettenleser

- Wim Sensor
- Linienbrandmeldekabel (= Temperaturmesswerte)
- Videodetektion Brand-/Rauchdetektion
- Rauchmelder
- Trübsichtmessgeräte
- Betätigung des Handgefahrenmelders Brand
- Entnahme eines Feuerlöschers
- Absetzen eines Notrufs

Aktion:

- Eine automatische Tunnelsperre wird ausgelöst.

Anweisung:

- Tunnelsperre laut RVS 09 02 22, Nr. 6-9,
- Innenstreckenbeleuchtung auf 100%
- Auslösen entsprechender Lüfterprogramme bei Brandereignissen
- Aufschaltung der Kameras im betroffenen Bereich
- Start der Alarmaufzeichnung, Ansteuerung von Querschlagtüren (bei Offenstellung)

### **3.3.1 TS-Grenzwertüberschreitung (Sichteinschränkung, Trübung, Rauch)**

Eine mit Partikel beladene Luft infolge der Emission von Rußpartikel aus Kraftfahrzeugabgasen, einer Resuspension von Stäuben sowie durch Nebelbildung infolge eines Nässeintrags kann zu einer Verschlechterung der Sichtverhältnisse innerhalb eines Tunnels führen und die Verkehrssicherheit einschränken. Ein signifikanter Anstieg der Trübung ist auch im Fall eines Brandes infolge der damit verbundenen Rauchproduktion zu verzeichnen. Im Regelbetrieb dient die Erfassung der Sichttrübung zur Steuerung der Lüftung zur Gewährleistung ausreichender Sichtbedingungen. Im Brandfall kann Sie zur Erkennung eines Brandereignisses mit herangezogen werden. Der Tunnel ist nach PLaPB 800.566.1650<sup>4</sup> (TSt) zu sperren, wenn der Alarmgrenzwert für die Sichttrübung in einem Mittelwert über eine Minute überschritten wird.

Mögliche Messgeräte:

---

<sup>4</sup> PLaPB 800.566.1600 (SLT) Abschnitt 2.12 Überwachung der Luftverhältnisse LQ-03



- Sichttrübmesseinrichtung

Aktion:

- Automatische Tunnelsperrung

Anweisung:

- Tunnelsperre laut RVS 09. 02. 22, Nr. 16,
- Innenstreckenbeleuchtung auf 100%
- Auslösen entsprechender Lüfterprogramme

### **3.3.2 CO-Grenzwertüberschreitung**

Kohlenmonoxid (CO) entsteht bei jeglicher Form der Verbrennung, an der Kohlenwasserstoffe beteiligt sind. Es gehört zu der Gruppe der farb- und geruchslosen Gase. Es ist darüber hinaus schwer wasserlöslich und dringt daher bis in tiefe Lungenregionen vor. Seine schädigende Wirkung liegt in der gegenüber dem Sauerstoff ca. 250-fach höheren Affinität zum Blutfarbstoff Hämoglobin. Das dabei entstehende Carboxyhämoglobin (CO-Hb) reduziert den Sauerstofftransport im Blut. Bereits ab einem Anteil von ca. 20% CO-Hb im Blut treten erste toxische Wirkungen auf und führen ab einem Anteil von ca. 40% zur Bewusstlosigkeit. CO-Hb-Konzentrationen zwischen 50% und 70% führen schließlich zum Tod. Die CO-Erfassung dient im Regelbetrieb der Steuerung der Lüftung zur Vermeidung von unzulässig hohen CO-Konzentrationen. Im Brandfall kann die CO Erfassung ebenfalls zur Erkennung eines Brandereignisses mit herangezogen werden. Gemäß dem PLaPB 800.566.1650<sup>5</sup> (TSt) ist ein Tunnel zu sperren, wenn der Alarmgrenzwert für CO in einem Mittelwert über eine Minute überschritten wird. Im Zuge der Einführung von Katalysatoren in Kraftfahrzeugen zur Abgasreinigung haben sich die CO Emissionen aus Verbrennungsmotoren über die Jahre jedoch sukzessive verringert, so dass die Steuerung der Lüftung im Regelbetrieb über die CO Messwerterfassung an Bedeutung verliert.

Mögliche Messgeräte:

- CO-Messanlage

Aktion:

- Automatische Tunnelsperrung

Anweisung:

- Tunnelsperre laut RVS 09. 02. 22, Nr. 15

---

<sup>5</sup> PLaPB 800.566.1600 (SLT) Abschnitt 2.12 Überwachung der Luftverhältnisse LQ-02

- Innenstreckenbeleuchtung auf 100%
- Auslösen entsprechender Lüfterprogramme

### 3.3.3 NO<sub>x</sub>-Grenzwertüberschreitung

Da sich im Zuge der Einführung von Katalysatoren in Kraftfahrzeugen zur Abgasreinigung die CO Emissionen aus Verbrennungsmotoren über die Jahre sukzessive verringert haben gewinnt die Erfassung von Sickoxiden (NO<sub>x</sub>), Stickstoffmonoxid (NO) und Stickstoffdioxid (NO<sub>2</sub>), als eine Leitgröße zur Steuerung der Lüftung zunehmend an Bedeutung. Sie entstehen bei hohen Verbrennungstemperaturen durch Oxidation des in der Luft vorhandenen Sickstoffes (N<sub>2</sub>). Auf den menschlichen Organismus wirkt insbesondere NO<sub>2</sub> auf die Atmungsorgane reizend und schädigend. Nach dem PLaPB 800.566.1650<sup>6</sup> (TSt) ist ein Tunnel zu sperren, wenn der Alarmgrenzwert für NO<sub>x</sub> in einem Mittelwert über eine Minute überschritten wird.

#### Mögliche Messgeräte:

- NO<sub>x</sub>-Messanlage

#### Aktion:

- Automatische Tunnelsperrung

#### Anweisung:

- Tunnelsperre laut RVS 09. 02. 22, Nr. 15
- Innenstreckenbeleuchtung auf 100%
- Auslösen entsprechender Lüfterprogramme

### 3.3.4 Ausfall Lüftungsanlage

Die Lüftungsanlage ist ein zentrales Element der sicherheitstechnischen Einrichtungen eines Tunnels. Im Regelbetrieb dient sie der Versorgung der Tunnelnutzer mit ausreichend reiner Atemluft, der Sicherstellung ausreichender Sichtverhältnisse sowie zur Vermeidung von unzulässig hohen Schadstoffkonzentrationen durch die Tunnelabluft an die Umgebung des Tunnels. Im Brandfall dient sie der Verringerung von Rauch- und Wärmeeinwirkungen auf Tunnelnutzer während der Selbstrettung sowie zur Unterstützung der Feuerwehr während der Fremdrettungsphase. Eine Lüftungsanlage kann durch Ausfall von Ventilatoren (Strahlventilator, Axialventilator) oder weiterer Systemkomponenten wie beispielsweise Lüftungsklappen (Abluftklappe, Frischluftimpulsklappe, Kanalabsperklappe) nicht verfügbar sein. Ursache für einen Ausfall kann eine Unterbrechung in der Energieversorgung, ein technischer Defekt in der

---

<sup>6</sup> PLaPB 800.566.1600 (SLT)Abschnitt: 2.12 Überwachung der Luftverhältnisse LQ-04

Ventilator- bzw. Klappeneinheit oder eine planmäßige Außerbetriebssetzung (Revisionschaltung) sein.

#### **3.3.4.1 Lüfterausfall**

##### Mögliche Messgeräte:

- Drehzahlmesser
- Schwingungssensoren
- Leistungsmesser

##### Aktion:

- Die letzten Regelzustände müssen ausfallsicher abgespeichert und nach Wiederkehr der Spannungsversorgung wieder übernommen werden.
- Im Falle eines irreversiblen Ausfalls muss die Einhaltung der in der RVS 09.02.31 vorgeschriebenen Grenzwerte sichergestellt sein oder gegebenenfalls eine Tunnelsperre veranlasst werden.

##### Anweisung im Fall einer Tunnelsperrung:

- Tunnelsperre laut RVS 09. 02. 22, Nr. 16
- Innenstreckenbeleuchtung auf 100%

#### **3.3.4.2 Ausfall von Lüftungsklappen**

##### Mögliche Messgeräte:

- Taster (Endschalter)

##### Aktion:

- Im Falle eines Ausfalls muss die Einhaltung der in der RVS 09.02.31 vorgeschriebenen Grenzwerte sichergestellt sein oder gegebenenfalls eine Tunnelsperre veranlasst werden.

##### Anweisung im Fall einer Tunnelsperrung:

- Tunnelsperre laut RVS 09. 02. 22, Nr. 16
- Innenstreckenbeleuchtung auf 100%

#### **3.3.5 Ausfall Beleuchtungsanlage**

Zur Gewährleistung eines sicheren Betriebs werden Tunnel mit einer Beleuchtungsanlage ausgestattet. Im Regelbetrieb dient die Beleuchtung dazu, dass ein mit der zulässigen Höchstgeschwindigkeit fahrender Fahrzeugführer die Fahrbahn und die Fahrstreifenbegrenzungen, andere Fahrzeuge sowie Hindernisse auf der Fahrbahn

mindestens über die Länge der Haltesichtweite deutlich erkennen kann (RVS 09.02.41). Im Ereignisfall wird die Beleuchtung auf höchster Beleuchtungsstufe betrieben, damit sich Tunnelnutzer schnell und sicher orientieren können. Hinsichtlich des Leuchtdichteniveaus ist zu unterscheiden zwischen der Beleuchtung in der Einfahrtsstrecke und in der Tunnelinnenstrecke. Die Einfahrtsstrecke dient zur Adaption des Auges an das Leuchtdichteniveau in der Tunnelinnenstrecke beim Übergang von der freien Strecke in den Tunnel am Tage. Nachts wird die gesamte Tunnelstrecke mit dem Leuchtdichteniveau der Tunnelinnenstrecke betrieben. Ein Ausfall der Beleuchtungsanlage wirkt sich somit auf die Verkehrs- und Betriebssicherheit eines Tunnels aus. Ursache für einen Beleuchtungsausfall kann ein technischer Defekt in der Beleuchtungssteuerung, ein Defekt in der Verkabelung sowie ein Ausfall der Energieversorgung sein. Zum Abfangen eines Stromausfalls ist die für nachts vorgesehene Durchfahrtsbeleuchtung an die SSV angeschlossen.

#### **3.3.5.1 Ausfall Einfahrtsbeleuchtung**

Fällt die Einfahrtsbeleuchtung aus ist die Einfahrtsgeschwindigkeit zu reduzieren, damit das Auge des Fahrzeugführers ausreichend Zeit zur Adaption beim Übergang von der freien Strecke in die Tunnelstrecke erhält.

##### Mögliche Messgeräte:

- Leuchtdichtekamera
- Videokamera

##### Aktion:

- Die Einfahrtsgeschwindigkeit muss dem zu großen Helligkeitsunterschied angepasst werden.

##### Anweisung:

- Die Einfahrtsgeschwindigkeit muss laut RVS 09.02.22, Nr. 25<sup>7</sup> auf 60 km/h reduziert werden.

#### **3.3.5.2 Ausfall Innenstreckenbeleuchtung**

Beim Ausfall der Innenstreckenbeleuchtung infolge einer Unterbrechung der Energieversorgung werden zur Aufrechterhaltung einer Notbeleuchtung die hierfür vorgesehenen Leuchtmittel SSV versorgt.

##### Mögliche Messgeräte:

- Leuchtdichtekamera
- Videokamera

---

<sup>7</sup> PLaPB 800.566.1600 (SLT) Abschnitt: 2.7.1 Einfahrtsbeleuchtung (Kurzzzeichen EFB-05)

Aktion:

- Die SSV-versorgten Lampen übernehmen die Beleuchtung.
- Die letzten Regelzustände müssen ausfallsicher abgespeichert und nach Wiederkehr der Spannungsversorgung sowie Ablauf der Einbrennzeit wieder übernommen werden.
- Im Falle eines SSV-Ausfalls tritt der dort vorgesehene Störfall in Kraft.

### **3.3.6 Ausfall Energieversorgung**

Zahlreiche Sicherheitsanlagen im Tunnel werden über elektrische Energie betrieben. Um einen sicheren Betrieb zu ermöglichen sind die zentralen Anlagen redundant ausgebildet. Hinsichtlich der zentralen Anlagen ist zu unterscheiden zwischen Anlagen auf Mittelspannungsebene (1 kV – 30 kV) und Anlagen auf Niederspannungsebene (50 – 1000 V).

#### **3.3.6.1 Ausfall Mittelspannungsanlage**

Die Versorgung eines Tunnels auf Mittelspannungsebene erfolgt entweder über eine einseitige oder zweiseitige Einspeisung in die Mittelspannungsanlage eines Tunnels. Eine Mittelspannungsanlage besteht typischerweise aus einer bestimmten Anzahl von Trafostationen, die miteinander verbunden sind. Jede Trafostation ist aus Gründen der Redundanz mit zwei Transformatoren bestückt von denen aus die Niederspannungsanlage versorgt wird. Aufgrund der hohen Redundanz ist ein Ausfall der Mittelspannungsanlage lediglich bei einem Netzausfall (Ausfall zweiseitiger Versorgung) wahrscheinlich.

Mögliche Messgeräte:

- Spannungsüberwachung
- Lastschalter

Aktion:

- Tunnelsperre

Anweisungen:

- Verkehrsmatrix laut RVS 09.02.22, Nr. 13<sup>8</sup> (Energieausfall)
- zusätzlich Innenstreckenbeleuchtung 100% (nur USV-versorgt) für zweimal die Räumzeit
- anschließend Reduktion der Innenstreckenbeleuchtung auf 50%

---

<sup>8</sup> PLaPB 800.566.1600 (SLT) Abschnitt: 2.2 Mittelspannungsanlage (Kurzzeichen MSP-06)

### 3.3.6.2 Ausfall Niederspannungsanlage

Die Niederspannungsanlage dient zur Versorgung der Verbraucher innerhalb eines Tunnels mit elektrischer Energie. Sie besteht aus Verteileranlagen mit Leistungsabgängen und Kopplungsschaltern zwischen diesen Abgängen. Die Verteiler werden im Regelbetrieb von zwei Transformatoren der Mittelspannungsanlage aus versorgt, die auf NSP-Seite getrennt sind. Die Versorgung ist so aufgeteilt, dass jeweils ein Transformator eine Tunnelröhre versorgt. Aufgrund der redundanten Ausbildung ist ein Ausfall der Niederspannungsanlage lediglich bei einem Ausfall der zweiseitigen Versorgung (Netzausfall) wahrscheinlich.

#### Mögliche Messgeräte:

- Kontaktleistungsschalter
- Offene Leistungsschalter
- Leistungsschutzschalter
- Sicherungslasttrenner

#### Aktion:

- Tunnelsperre

#### Anweisungen:

- Verkehrsmatrix laut RVS 09.02.22, Nr. 13<sup>9</sup> (Energieausfall)
- zusätzlich Innenstreckenbeleuchtung 100% (nur USV-versorgt) für zweimal die Räumzeit
- anschließend Reduktion der Innenstreckenbeleuchtung auf 50%

### 3.3.7 Zusammenfassung und Priorisierung der Ereignisarten

Das Planungshandbuch der ASFINAG zur Steuerungslogik von Tunnelanlagen (800.566.1600 SLT) sieht eine Priorisierung der Ereignisse gemäß nachfolgender Tabelle 1 vor. Diese Einteilung der Ereignisse dient als Orientierung für die Zusammenfassung und Priorisierung der Ereignisarten.

Priorität der Ereignisse				
Prioritäten	Ereignisse	Subsysteme		
		Lüftung	Beleuchtung	Verkehr
20				
19	Brand hochprior			
18	Brand (Linienbrand) niederprior	X	X	X
17	Brandlinie händische Auslösung	X	X	X
16	Brand (Handfeuermelder)		X	X
15	TS- Alarm	X	X	X
14	CO- Alarm	X	X	X
13	Spannungsausfall	X	X	X
12	Lüftung Test	x		
11	Ausfall DFB (Innenstreckenbeleuchtung)		X	X
10				
9	HK-Auslösung			X
8	Notruf			X
7	Stau			X
6				
5	Warnung TS			X
4	Warnung CO			X
3	Ausfall EFB (Einfahrtsbeleuchtung)			X
2	Überschreitung Leuchtdichte L20			x
1				

Tabelle 1: Priorisierung von Ereignissen<sup>10</sup>

<sup>10</sup> PLaPB 800.566.1600 (SLT) Abschnitt: 4.2.2.3

Über diese Ereignisse hinaus kann können die in den vorherigen Abschnitten beschriebenen Ereignisarten in „sehr wichtig“, „wichtig“ und „weniger wichtig“ eingeteilt werden. In Tabelle 2 werden die von heutigen Tunnelsystemen detektierbaren Ereignisarten entsprechend kategorisiert.

<b>Detektierbare Ereignisse</b>	<b>Gewichtung</b>
Nicht angepasste Geschwindigkeit	wichtig
Zu geringer Abstand	wichtig
Riskante Überholvorgänge (Rechtsüberholen, Überholen in GV-Tunnel)	wichtig
Auffälliges Fahrverhalten (Schlingern)	weniger wichtig
Stau / stockender Verkehr	wichtig
Fahrzeugstillstand (Einzelfahrzeug)	sehr wichtig
Falschfahrer / Rückwärtsfahrer / Wendemanöver	sehr wichtig
Langsamfahrer	wichtig
Pannengeburtbelegung	wichtig
Personen / Tiere auf der Fahrbahn	sehr wichtig
Anforderung von Hilfe für Personen mit eingeschränkter Mobilität	weniger wichtig
Gegenstände auf der Fahrbahn	wichtig
Straßenverhältnisse (Nasse Fahrbahn, Ölspur, Glätte)	wichtig
Überladung von Fahrzeugen	wichtig
Überhohe Fahrzeuge	wichtig
Überhitzte Fahrzeuge	wichtig
Einfahrt von Schwertransporten	wichtig
Einfahrt von Gefahrguttransporten	wichtig
Art und Menge von transportierten Gefahrgütern	wichtig
Unfall / Kollision	sehr wichtig
Unfall / Kollision mit Beteiligung von Gefahrguttransporten	sehr wichtig
Gefahrgutfreisetzung infolge eines Lecks	sehr wichtig
Ungenügende Sichtverhältnisse innerhalb eines Tunnels	wichtig



<b>Detektierbare Ereignisse</b>	<b>Gewichtung</b>
Ungenügende Sichtverhältnisse im Vorportalbereich durch Nebel	wichtig
Rauchentwicklung an einem Fahrzeug	sehr wichtig
Fahrzeugbrand	sehr wichtig
Grenzwertüberschreitung	wichtig
Beleuchtungsausfall	weniger wichtig
Lüftungsausfall	wichtig
Stromausfall	sehr wichtig
Technische Störung	wichtig

Tabelle 2: Priorisierungsmatrix Ereignisarten

Fasst man die „sehr wichtigen“ Ereignisse zusammen dann erhält man Tabelle 3. Die davon mit der im Tunnel Kirchdorf detektierbaren Ereignisse sind Übereinstimmung mit der Auflistung der automatisch Ereignisse aus der PLaNT 170.020.2000 für Videodetektionssysteme.

<b>Detektierbare Ereignisse</b>	<b>Gewichtung</b>
Fahrzeugstillstand (Einzelfahrzeug)	sehr wichtig
Falschfahrer / Rückwärtsfahrer / Wendemanöver	sehr wichtig
Personen / Tiere auf der Fahrbahn	sehr wichtig
Unfall / Kollision mit Beteiligung von Gefahrguttransporten	sehr wichtig
Gefahrgutfreisetzung infolge eines Lecks	sehr wichtig
Rauchentwicklung an einem Fahrzeug	sehr wichtig
Fahrzeugbrand	sehr wichtig

Tabelle 3: Sehr wichtige Ereignisarten

Bezogen auf die im Tunnel Kirchdorf installierten Sicherheitssysteme sind daher die in Tabelle 4 aufgelisteten Ereignisarten detektierbar.

Detektierbare Ereignisse	Gewichtung
Fahrzeugstillstand (Einzelfahrzeug)	sehr wichtig
Falschfahrer / Rückwärtsfahrer / Wendemanöver	sehr wichtig
Unfall / Kollision mit Beteiligung von Gefahrguttransporten	sehr wichtig
Rauchentwicklung an einem Fahrzeug	sehr wichtig
Fahrzeugbrand	sehr wichtig

Tabelle 4: Ereignisarten im Tunnel Kirchdorf

Fahrzeugstillstand, Unfall und Kollision wird in dieser Liste dabei von den Systemen Videodetektion der Firma PKE mit dem Produkt VBTC Tunnel und dem System AKUT des Joanneum Research aus Graz erkannt. Falschfahrer/Rückwärtsfahrer/Wendemanöver werden von dem Videodetektionssystem VBTC erkannt. Rauchentwicklung wird von dem Videodetektionssystem, dem Trübsichtmessgeräten, den CO-Meldern und den NOx-Meldern detektiert.

Das Videodetektionssystem setzt dabei die auflaufenden analogen Videosignale in digitale Helligkeits- und Farbwerte um und führt eine Echtzeitanalyse der Inhalte der der Bilder durch. Dabei werden mehrere Detektionsalgorithmen gleichzeitig angewandt um unterschiedliche Arten von Objekten und Ereignissen zu erkennen. In Abbildung 1 wird der prinzipielle Aufbau eines Videodetektionssystem veranschaulicht.

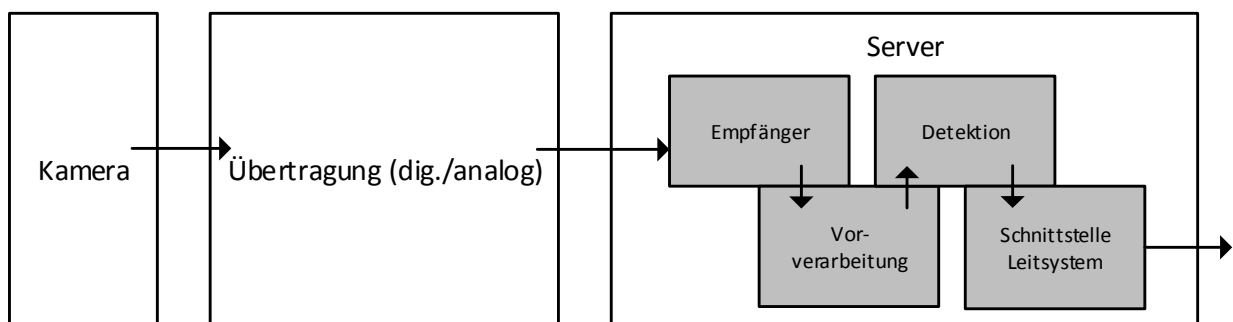


Abbildung 1: Schematischer Aufbau eines Videodetektionssystems

Der tatsächliche Brand wird durch Linienbrandmelder erkannt. Ein Linienbrandmelder ist ein bis zu mehreren Kilometer langes Brandmeldesystem in Form eines Kabels, welches

typischerweise an der Tunneldecke verlegt wird. In diesem Kabel sind, gegen Schmutz, mechanische Einwirkung und elektromagnetische Strahlung geschützt, alle 0,5m bis 8m Temperatursensoren, insgesamt bis zu 1024, untergebracht, die von einem zentralen Steuergerät periodisch ausgewertet werden. Damit ist im Falle eines Brandes die Lokalisierung des Brandherdes im Tunnel auf wenige Meter genau möglich.

Die relevanten Ereignisarten für den Tunnel Kirchdorf, welche im Speziellen beim Projekt TSFu untersucht wurden, sind die in Tabelle 4 aufgelisteten „sehr wichtigen“ Ereignisse. Mit diesen wurde nun in erster Linie untersucht in wie weit lässt sich die Relevanz der Ereignisse, also das Verhältnis der „richtig positiv“ erkannten Ereignisse zur Anzahl aller erkannten Ereignisse steigern, ohne die Detektionszeiten dabei wesentlich zu verschlechtern.

### 3.4 Anforderungsmatrix

Um die Anforderungen an die TSFu Einheit zu dokumentieren und entsprechend nachverfolgen zu können wurden in Form eine Anforderungsmatrix mit den Kategorien nach FURPS+ die Anforderungen erfasst.

Nr.	Name	Anforderungsbeschreibung (Was?)	Kategorie
0	<b>Allgemein</b>		
0.1	<b>System</b>		
0.1.1	Betrieb 24/7	Die Software muss für einen 24/7 Betrieb ausgelegt sein. Sie muss als Softwareprozess automatisch gestartet werden.	Zuverlässigkeit
0.1.2	Betriebssystem Windows 7,8,10 oder Server 2013	Der TSFu Softwareprozess muss unter Windows lauffähig sein und muss ohne zusätzliche Hardwareanforderungen an das Betriebssystem auskommen.	Benutzbarkeit
0.1.3	Virtualisierbarkeit	Die TSFu Software muss auf einem virtualisierten Server lauffähig sein	Benutzbarkeit
	Echtzeitfähigkeit	Die Software muss in der Lage sein Ereignisse und ungewöhnliche Situationen innerhalb von wenigen Sekunden zu erkennen und ein entsprechendes Telegramm an die Leitebene abzusetzen.	Funktionalität
	Sprachunterstützung	Als Sprache wird Deutsch gefordert	Funktionalität

0.2	<b>Installation</b>		
0.2.1	Setup	Die Software muss mittels eines Setup Programmes soweit einrichtbar sein, dass sie auf einem virtualisierten Server installiert werden kann. Ein entsprechender Kopierschutz ist dafür vorzusehen.	Funktionalität
1	<b>Schnittstellen</b>		
1.1	Anlagenebene	Die TSFu Software muss um eine Schnittstelle, welche noch genauer spezifiziert werden muss, erweiterbar sein, welche eine Echtzeit Übertragung der Sensordaten in die TSFu Software ermöglicht.	Funktionalität
1.2	Leitebene	Über eine Schnittstelle, welche noch genauer spezifiziert werden muss, müssen die Fusionsmeldungen ich Echtzeit zum Leitsystem übertragen werden. Diese Software muss in der Lage sein um diese Schnittstelle erweitert werden zu können.	Funktionalität
2	<b>Sensorarten</b>	<b>Siehe ANHANG - I</b>	
2.1	Videodetektion	Ereignismeldungen die über die Tunnelkopschnittstelle an TSFu gemeldet werden	Funktionalität
2.2	AKUT	Ereignismeldungen die über die Tunnelkopschnittstelle an TSFu gemeldet werden	Funktionalität
2.3	Verkehrsdaten (ind. Schleifen)	Zyklische Daten, die in Form von Messwerten 1x pro Minute vom Tunnelkopf pro Baugruppe gemeldet werden. Zusätzliche Alarmmeldungen, die im Ereignisfall über den Tunnelkopf gemeldet werden	Funktionalität
2.4	Brandmeldekabel	Zyklische Temperaturdaten und Ereignisdaten die über den Tunnelkopf gemeldet werden	Funktionalität
2.5	Leuchtdichte	Zyklische Messdaten die über den Tunnelkopf gemeldet werden	Funktionalität
2.6	CO-Melder	Zyklische Messdaten die über den Tunnelkopf gemeldet werden	Funktionalität
3	<b>Ereignisarten</b>		
3.1	Fahrzeugstillstand/Unfall	TSFu muss durch Fusion von AKUT und VBTC Videodetektion die Relevanz dieses Alarms erhöhen	Funktionalität
3.2	Falschfahrer	TSFu muss durch Fusion mehrere Detektionssensoren (ind. Schleife) und Kameras evaluiert werden	Funktionalität

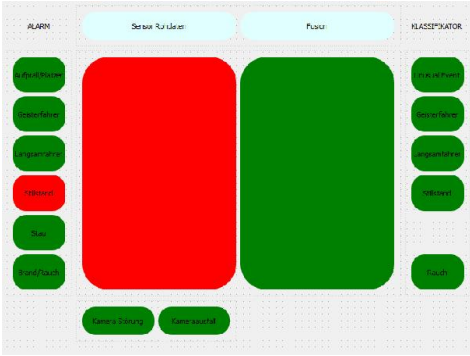
3.3	Rauchentwicklung	TSFu muss hier Fusion von Kamerarauchentwicklung, Brandmeldekabel, CO-Meldern und NOx sowie Leuchtdichtmessgeräten ermöglichen. Ein Beispiel für ein solches Ereignis wird in Abbildung 3 wiedergegeben.	Funktionalität
3.4	Ungewöhnliche Zustände	TSFu muss in der Lage sein aus der Gesamtbetrachtung der Sensordaten des Tunnels ungewöhnliche Zustände zu erkennen und als gesonderte Meldung abzusetzen.	Funktionalität
4	<b>Bedienung</b>		
0.1.3	Demonstrator GUI	<p>Der TSFu Demonstrator um die Funktion der Fusion der Standardlösung gegenüberzustellen. Dabei muss der Demonstrator sowohl die Ergebnisse als auch das Zeitverhalten visualisieren können.</p>  <p>Abbildung 2: Beispieldarstellung des Demonstrator GUI</p>	Funktionalität

Tabelle 5: TSFu - Anforderungsmatrixüberblick

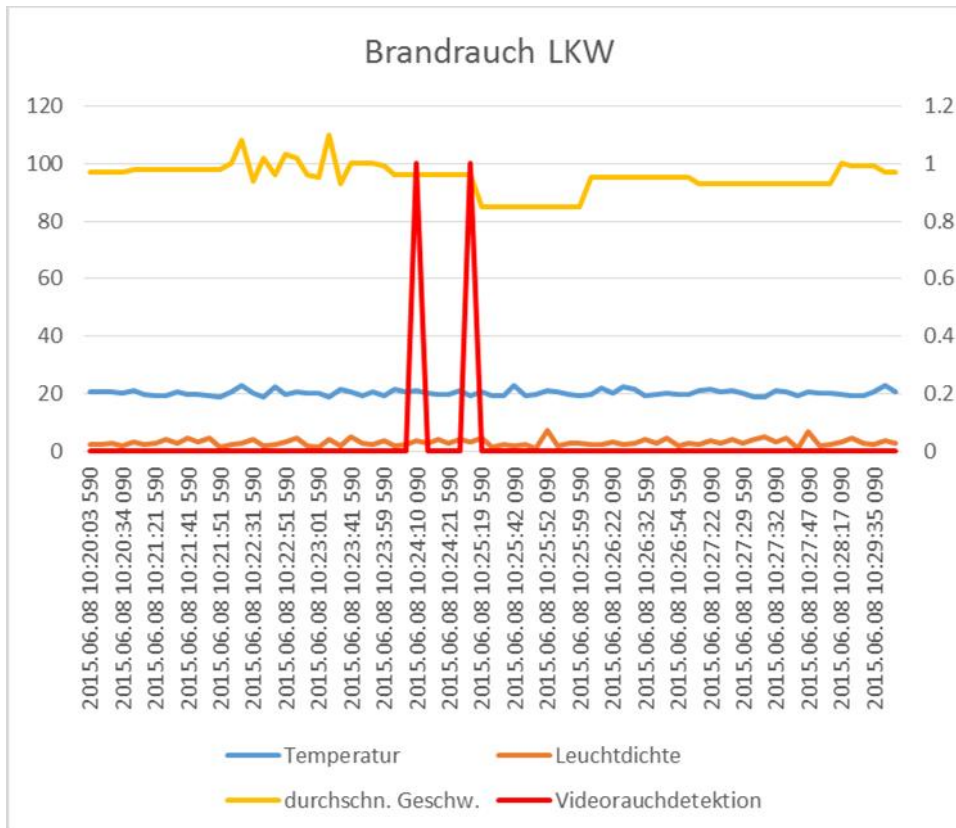


Abbildung 3: grafische Darstellung Brandrauch LKW am 8. Juni 2015

## 4 QUALITÄTSUNTERSUCHUNG

### 4.1 Methodik

Eine Grundlage für die Verbesserung der Qualität der Ereignisdetektion durch die Fusion verschiedener Datenquellen ist die Kenntnis der Qualität der einzelnen Datenquellen.

Deshalb wurde die Qualität der **von den Induktivschleifen gelieferten Verkehrsdaten** anhand der vom Arbeitskreis (AK) 3.5.20 der Forschungsgesellschaft für Straßen- und Verkehrswesen (FGSV) in den „Hinweisen zur Qualitätsanforderung und Qualitätssicherung der lokalen Verkehrserfassung“ vorgeschlagenen Qualitätskenngrößen ermittelt (Abbildung 4).

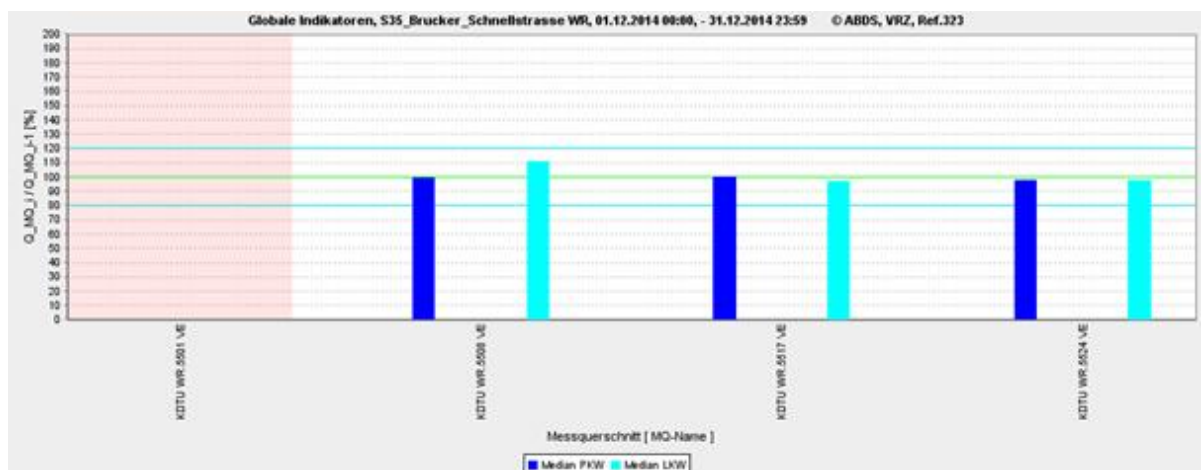


Abbildung 4: Verhältnis der Zählwerte für Pkw (dunkelblau) und Lkw (hellblau) am Messquerschnitt (MQ) zu den entsprechenden Zählwerten am vorherigen MQ – im Idealfall 100 % (OR)

Um die Qualität der **Ereignisdetektion mittels Video- und Schalldetektion** zu ermitteln, wurden zum einen Häufungen von Alarmen der Video- und Schalldetektion identifiziert (Abbildung 5) und zum anderen aus den von den Induktivschleifen gelieferten Verkehrsdaten mittels der Anisotropic Smoothing Method (ASM) die räumlich-zeitlichen Verkehrslage je Tag und Richtung rekonstruiert, als sogenannte Kontourplots visualisiert (Abbildung 6) und interessante Ereignisse (Verkehrsstörungen) herausgesucht (visuell und Clusterverfahren). Für die so identifizierten Alarme und Ereignisse wurden zwecks Bewertung der Detektionsqualität gezielt die zugehörigen Videoaufzeichnungen

(Alarmvideos) herausgesucht, gesichtet und beurteilt (true positive, false positive und false negative).




Abbildung 5: Häufungen von Alarmen






Abbildung 6: Beispiel für einen Kontourplot (eingefärbte Geschwindigkeitswerte je Weg-Zeit-Segment) mit mehreren Verkehrsstörungen (rot)

## 4.2 Qualitätsuntersuchung Verkehrsdatenerfassung (Induktivschleifen)

### 4.2.1 Ostrichtung

In Ostrichtung (OR) sind im Dezember 2014 nur Plausibilitätsfehler, insbesondere am Detektor OR 5601 VE – DE 2 (linker Fahrstreifen am 1. Detektor) aufgetreten, welche nur die Plausibilitätskenngrößen m15, m16, m17 und m20 (alles Geschwindigkeitsprüfungen) und nur den linken Fahrstreifen betreffen. Der Grund dafür sind Minutenintervalle mit nur einem oder wenigen Fahrzeugen, die im Mittel mit Geschwindigkeiten höher als der Schwellenwert vorbeigefahren sind. Darüber hinaus gab es Überzählungsprobleme am ersten und letzten Messquerschnitt, die nicht auf Klassifizierungsprobleme zurückzuführen sind, da die Überzählung sowohl Lkws als auch Pkws betrifft. Ansonsten stimmen die Zählungen am 2. und 3. MQ sehr gut überein (siehe Abbildung 6).

Im Februar 2015 sieht die Situation sehr ähnlich aus. Die gleichen Probleme (Plausibilitätsfehlermeldungen bzw. Überzählungsprobleme) wurden an denselben MQ detektiert.

#### **4.2.2 Westrichtung**

In Westrichtung (WR) wurden im Dezember 2014 Plausibilitätsfehler insbesondere am 2. und 3. MQ (WR 5508 VE – DE4 und WR 5517 VE – DE6) auf dem linken Fahrstreifen sowie wenige fehlende Daten am zweiten MQ ermittelt. Wie für die OR beschrieben, sind nur bei Geschwindigkeitsprüfungen (m15, m16, m17, m20 und m22) Probleme aufgetreten. Die Ursache sind auch hier wieder Intervalle mit nur einem oder wenige Fahrzeugen mit hohen Geschwindigkeiten. Ferner hat eine Unterzählung von Lkws am ersten MQ stattgefunden, was aber nicht auf Klassifizierungsprobleme zurückgeführt werden kann, da die Zählung von Pkws sehr gut mit dem 2. und 3. MQ übereinstimmt.

#### **4.2.3 Fazit**

Die Untersuchung hat ergeben, dass die Qualität der mittels Induktivschleifen erfassten Verkehrsdaten, bis auf geringe Abweichungen bei der Zählung, ausgezeichnet ist. Die Abweichungen bei der Zählung könnten z. B. auf häufigere Spurwechsel an einzelnen Messquerschnitten (gleichzeitige Zählung eines Fahrzeugs auf zwei Fahrstreifen) zurückzuführen sein.

### **4.3 Qualitätsuntersuchung Ereignisdetektion (Video- und Schalldetektion)**

Im Dezember 2014 gab es nur wenige Verkehrsstörungen (Geschwindigkeiten i.d.R. zwischen 50 und 70 km). Die identifizierten Verkehrsstörungen erstreckten sich immer über die gesamte Länge des Tunnels (alle MQ). Das deutet darauf hin, dass die Ursachen der Störungen stromabwärts außerhalb des Tunnels lagen. Ansonsten ist noch zu erwähnen, dass sich die „Verkehrsstörungen“ (Geschwindigkeitseinbrüche) sehr schnell ausgebreitet haben. Als Ursache hierfür werden dynamische Geschwindigkeitsbeschränkungen (Trichterschaltungen) über die Wechselverkehrszeichen vermutet.

## 5 DATENFUSION

### 5.1 Motivation

In heutigen Tunnel ist eine Vielzahl verschiedenartiger Sensoren installiert. Diese Sensorsysteme liefern im allgemeinen Fall zu verschiedenen Zeitpunkten Alarme zu vordefinierten Ereignissen. Dabei kann es aufgrund von fehlerhaften Messdaten bei Einzelsensoren zu sogenannten Fehlalarmen kommen. Eine logische Verknüpfung von Sensorergebnissen alleine ist dabei nicht ausreichend. Beispielsweise kann ein Fahrzeug durch ein Videosystem oder eine Induktionsschleife detektiert werden. Beide Systeme weisen Fehler im Sinne von Falsch-Negativen [FN] (=nicht erkannte, aber vorhandene Fahrzeuge) sowie Falsch-Positiven [FP] (=erkannte, aber nicht vorhandene Fahrzeuge) auf. Durch eine logische Verknüpfung im Sinn eines „UND“ könnte zwar ein Teil der FP als solcher erkannt werden, allerdings würden sich die FN beider Sensoren addieren. Im Falle einer „ODER“-Verknüpfung würden die FN reduziert, während sich die FP addierten. Beide Fälle würden daher zu keiner Verbesserung der Detektionsleistung führen.

Einen Ausweg bieten probabilistische, d. h. auf der Wahrscheinlichkeitslehre beruhende Verfahren, welche die Detektionseigenschaften jedes Sensors in einem so genannten Sensormodell wahrscheinlichkeitstheoretisch abbilden und dabei Abhängigkeiten von weiteren Größen berücksichtigt. So kann die FP-Rate eines Videosystems von der Beleuchtung abhängen, während eine Induktionsschleife durch Nässe, Schnee und elektrische Störfelder verfälschte Ergebnisse liefern kann. Eine probabilistische Datenfusion berücksichtigt daher die individuelle Wahrscheinlichkeit jedes Detektionsergebnisses und kann damit die Detektionsleistung des Gesamtsystems signifikant erhöhen.

### 5.2 Konzept und Methodik

Die BASELABS GmbH beschäftigt sich intensiv mit der Thematik der Umfeldwahrnehmung für Fahrzeuge im zivilen Straßenverkehr. Ähnlich wie bei der Installation in einem Tunnel, kommen dabei typischerweise verschiedenartige Sensoren mit heterogenem Messprinzip (bspw. Radar, Lidar oder Kamera) zum Einsatz, um das Umfeld um das Fahrzeug robust zu detektieren und in einem Modell abzubilden. Auch

hier sind die Messungen der Sensoren prinzipiell als fehlerhaft und unsicher zu betrachten. Praktisch heißt das, dass man anhand einer Einzelmessung niemals vollständig auf den tatsächlichen Zustand des beobachteten Systems (z.B. die relative Position eines vorausfahrenden Fahrzeuges im Bezug zum Eigenfahrzeug) schließen kann. Vielmehr ist es notwendig, das System über eine gewisse Zeit kontinuierlich zu beobachten und anhand der ermittelten (oder angenommenen) Statistik der Sensorsysteme sowie in Kombination mit Modellwissen (ein Auto bewegt sich z.B. typischerweise entlang der Ausrichtung mit einer nahezu konstanten Beschleunigung) zu bewerten. Diese Vorgehensweise wird oft als zeitliche Filterung bzw. probabilistische Datenfusion bezeichnet. Mit dem skizzierten Ansatz der probabilistischen Datenfusion lassen sich komplexe Umfeldmodelle für Fahrerassistenzfunktionen bzw. das autonome Fahren realisieren [5].

Wie im Antrag des Vorhabens TSFu dargelegt, sollte der Versuch unternommen werden, zu evaluieren, inwiefern sich eine Multisensordatenfusion aus dem Bereich der Umfeldwahrnehmung für Fahrzeuge auf eine Infrastrukturapplikation (Tunnel) übertragen lässt. Die Ergebnisse dieser Evaluierung sollen im Folgenden dargestellt werden.

### **5.2.1 Objektbasierte Datenfusion mittels BASELABS Create**

Neben dem Know-How im Bereich der praktischen Datenfusion entwickelt die BASELABS GmbH auch ein Softwaretool (BASELABS Create) welches die Umsetzung und Implementierung einer Multi-Sensordatenfusion in prototypischer Art und Weise erlaubt [1]. Dabei wird prinzipiell davon ausgegangen, dass die konkreten Messungen der verwendeten Sensorsysteme als eine Art Objekt beschrieben werden können. Ein Objekt kann dabei u.a. durch Position, Ausdehnung, Geschwindigkeit oder Orientierung beschrieben sein. Das Produkt BASELABS Create ist ein mathematisches Software Framework mit dem sich die individuellen Teile einer Datenfusion in geeigneter Weise anordnen lassen. In Abbildung 7 ist die Struktur einer Multisensordatenfusion zur Umfeldwahrnehmung, so wie sie in BASELABS Create vorgesehen ist, illustriert. Die einzelnen Komponenten einer Sensordatenfusion lassen sich dabei in folgende unabhängige Teile zerlegen.

### 5.2.1.1 Zustandsraum

Der Zustandsraum des zu beobachtenden Systems stellt das „interne Wissen“ der Datenfusion da. Er wird üblicherweise durch einen Experten festgelegt und ist u.a. abhängig vom den antizipierten Anwendungsfall und den zu verwendenden Sensoren. Für die Schätzung einer Fahrzeugposition relativ zum Eingang eines Tunnels (Tunnelportal) zum Zeitpunkt  $k$  könnte man den Zustandsraum  $\mathbf{x}_k$  beispielsweise durch

$$\mathbf{x}_k = [\Delta x \ \Delta y]^T$$

beschreiben, wobei  $\Delta x$  und  $\Delta y$  jeweils den relativen Abstand zum Fixpunkt des Tunnelportals in kartesischen Koordinaten beschreiben. Aufgabe der Datenfusion ist es nun, die Messungen aller Sensoren mit diesem Zustandsraum über der Zeit abzugleichen.

### 5.2.1.2 Systemmodell

Die Zustandsraumdarstellung gibt den internen Zustand eines Systems (z.B. der Positionsschätzung eines Fahrzeuges) zum Zeitpunkt  $t$  an. Da eine Multisensordatenfusion allerdings typischerweise mit mehreren asynchronen Sensoren betrieben wird, ist es notwendig, den Zustand auf den Zeitpunkt der tatsächlichen Messungen zu synchronisieren. Dies wird durch die Implementierung eines Systemmodells  $f(\cdot)$  realisiert. In der Praxis ist es oft notwendig, den aktuellen Systemzustand vom Zeitpunkt  $k-1$  auf die letzte Messung von Zeitpunkt  $k$  zu synchronisieren. Diese Form der Extrapolation wird dann durch folgende im Allgemeinen nichtlineare Funktion realisiert:

$$x_k = f(x_{k-1})$$

Für Fahrerassistenzsysteme kommen als Systemmodell typischerweise zweidimensionale Modelle in Frage, die entweder die Geschwindigkeit oder die Beschleunigung als konstant annehmen, zum Einsatz. Eine detaillierte Evaluierung der verschiedenen Modelle für typische Use-Cases findet sich in [3].

### 5.2.1.3 Messmodell

Für jeden im System vorhandenen Sensor existiert ein Messmodell. Das Messmodell beschreibt, in welchem Bezug die konkrete Messung zum Zeitpunkt  $k$  (Messvektor  $z_k$ ) eines Sensors (z.B. relative Positionsmessung in Abstand und Winkel) zu dem internen Wissen (z.B. Repräsentierung der Position durch kartesische Koordinaten) der Datenfusion, also dem Zustandsraum  $x_k$ , steht. Somit ist es auch Aufgabe des Messmodells, die Einbauposition eines Sensors zu berücksichtigen. Für das oben genannte Beispiel wäre der Messvektor durch

$$z_k = [r \ \phi]^T$$

beschrieben, wobei  $r$  die Entfernung zum gemessenen Objekt und  $\phi$  den beobachteten Winkel repräsentieren. Das Messmodell (allgemein als  $h(\cdot)$  formuliert) gibt nun eine mathematische Transformationsvorschrift an, um aus dem aktuellen Systemzustand  $x_k$  eine wahrscheinliche Messung  $\hat{z}_k$  vorherzusagen:

$$\hat{z}_k = h(x_k)$$

Die so vorhergesagte Messung  $\hat{z}_k$  kann dann mit der tatsächlichen Messung  $z_k$  von Zeitpunkt  $k$  verglichen werden. Aus der Abweichung der beiden Größen lässt sich schließlich ermitteln, wie gut das Wissen der Datenfusion dem beobachteten Systemzustand entspricht. Eine detaillierte Erläuterung dieses Verfahrens findet sich in [2]. Es ist hervorzuheben, dass neben der Einbauposition der Sensoren auch deren Leistungsfähigkeit in Form des Messrauschens als Parameter für das Messmodell angegeben werden muss.

### 5.2.1.4 Inferenzalgorithmus

Innerhalb von BASELABS Create stehen mehrere Implementierungen von probabilistischen Inferenzverfahren zur Verfügung. Praktisch relevante Vertreter davon

sind der lineare Kalman Filter, der Extended Kalman Filter, sowie der Unscented Kalman Filter [17] (geordnet nach Komplexität). Die Auswahl einer Implementierung richtet sich dabei nach dem Anwendungsfall und den gewählten Modellen. Während für lineare Problem typischerweise ein Standard Kalman Filter gewählt wird, erfordert die Behandlung stark nichtlineare Prozesse in der Regel ein Implementierung wie den Unscented Kalman Filter, der explizit damit umgehen kann. Im wissenschaftlichen Umfeld bzw. zur Berechnung von Referenzlösungen werden oft auf Monte-Carlo-basierte Methoden wie der Partikelfilter eingesetzt.

### 5.2.2 Zusammenfassung

Unabhängig vom verwendeten Algorithmus sowie dem physikalischen System und Messmodellen ist es notwendig die Grunddaten zeitlich zu synchronisieren (in BASELABS Create erfolgt dies üblicherweise über sogenannte System- bzw. Bewegungsmodelle) um einen „Vergleich“ und damit eine Steigerung der Robustheit sowie Zuverlässigkeit im Sinne von reduzierten Falschalarmen zu realisieren.

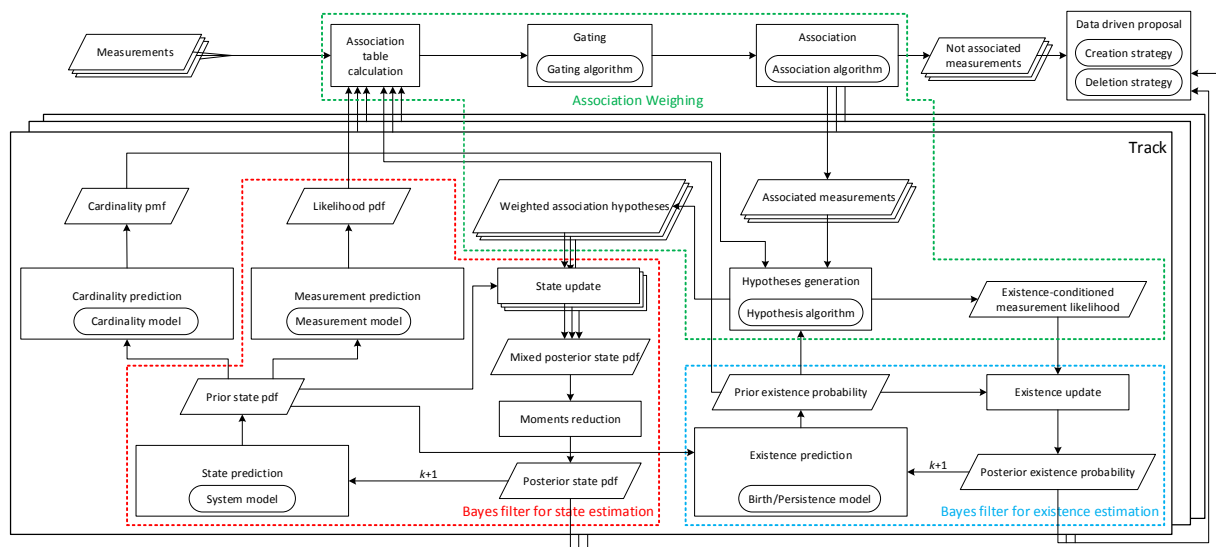


Abbildung 7: Struktur eine Datenfusion zur Umfeldwahrnehmung in BASELABS Create

### 5.2.3 Datenanalyse

Innerhalb von AP3 (Qualitätsuntersuchung Ereignisdetektionssensoren) erfolgte im Unterarbeitspaket AP3.2 die Analyse der Grunddaten. Nachdem die Messdaten in exportierter Form als eine Menge von CSV-Dateien bereitstanden, wurde damit begonnen eine weitere Analyse durchzuführen. Dazu wurde von BASELABS in AP3.2 eigens eine Applikation (DatabaseViewer) in C# entwickelt. Diese Applikation beinhaltet folgende Funktionen:

- Import der exportierten CSV-Daten in eine relationale Datenbank auf Basis von SQLite (siehe Abbildung 8)
- Flexible und schnelle Auswertung der in der SQLite-Datenbank vorhandenen Daten

Mittels dieser Applikation ist es möglich, den zeitlichen Verlauf der einzelnen Messgrößen darzustellen und erste Rückschlüsse auf eine räumliche Korrelation zu ziehen. Gleichzeitig lassen sich damit Sensorausfälle erkennen. Des Weiteren ist die Applikation in der Lage selektiv, verschiedene Messgrößen zu überlagern um somit die Untersuchung auf Korrelationen im Hinblick auf die interessanten Ereignisse zu unterstützen.

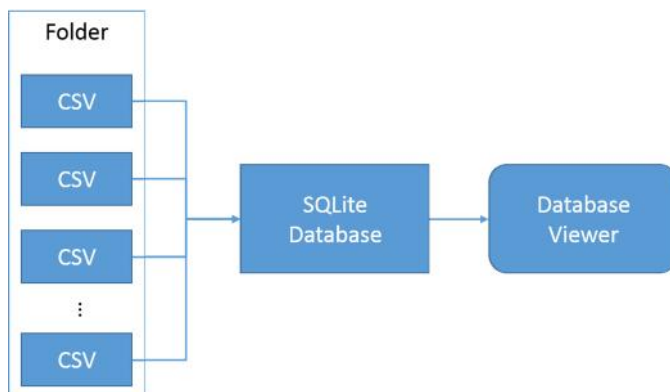


Abbildung 8 Schematische Darstellung des Workflows zum Export und zur Analyse der Sensordaten






Abbildung 9 Ansicht der DatabaseViewer-Applikation zur Korrelationsanalyse

## 5.2.4 Datenfusion auf Merkmalsebene

Nach der detaillierten Analyse der zur Verfügung stehenden Sensordaten für den ausgewählten Tunnel in Abschnitt 5.2.3 wurde sehr schnell klar, dass eine probabilistische Sensordatenfusion auf Merkmalsebene (siehe Abschnitt 5.2.1) wie sie zum heutigen Stand durch das Tool BASELABS Create zur Verfügung gestellt wird, nicht ohne weiteres genutzt werden kann. Grund dafür sind u.a. die in Abschnitt 5.2.1 genannten Voraussetzungen. Für die praktische Implementierung mittels einer Datenfusion auf Basis von BASELABS Create müssten u.a. folgende Bedingungen erfüllt sein:

- Die Einbauposition der Tunnelsensoren müsste exakt bekannt sein, um das physikalische Messmodell zu implementieren
- Die Statistik der Sensormessungen (Sensorrauschen) müsste bekannt sein oder sich zumindest ermitteln lassen. Da die Sensoren aber meistens nur eine Detektion im Falle eines erkannten Ereignisses liefern, ist diese Information nicht ohne weiteres zu rekonstruieren

- Die Sensordaten müssten exakte und synchronisierte Zeitstempel enthalten um den Systemzustand der Datenfusion mit Hilfe des Systemmodells korrekt in der Zeit zu präzisieren.

Diese Voraussetzung wurde bei der bestehenden Tunnelkonfiguration nicht vorgefunden. Daher wurde vom ursprünglichen Plan einer objektbasierten Datenfusion abgewichen und stattdessen eine Datenfusion auf Merkmalsebene implementiert um das Potential der Nutzung von mehreren Sensoren im Tunnelbetrieb zu untersuchen.

Für die Datenfusion auf Merkmalsebenen kommen mehrere praktisch erprobte Verfahren aus dem Bereich der Robotik bzw. des Maschinellen Lernens in Frage. Im Folgenden werden relevante Vertreter<sup>11</sup> vorgestellt und anschließend im Ergebniskapitel analysiert. Dabei wird jeweils auf die grundlegenden Eigenschaften und die erwartete Leistungsfähigkeit eingegangen.

#### 5.2.4.1 Nearest Neighbor

Die Nearest-Neighbor-Klassifikation stellt ein probabilistisches Schätzverfahren zum Bestimmen einer Wahrscheinlichkeitsdichtefunktion dar. Der daraus abgeleitete k-Nearest-Neighbor-Algorithmus ist ein parameterfreies Klassifikationsverfahren, welches eine zu untersuchende Stichprobe (z.B. die konkrete Messung von Staudetektion und Brandmeldeanlage zu einem Zeitpunkt t) einer Klasse (z.B. „Stau im Tunnel“) zuordnet und dabei die k nächsten Nachbarn berücksichtigt. Der Klassifikator muss mit gelabelten Messdaten (d.h. bekannten Klassenzugehörigkeiten) angelern werden, wobei das konkrete Training dann im Abspeichern der Trainingsdaten besteht. Während der Klassifikation wird die Zugehörigkeit zu einer vorab angelerten Klasse dann auf Basis eines Abstandsmaßes (z.B. euklidisch) bestimmt, wobei die Klassenhypothese mit dem kleinsten Abstandsmaß üblicherweise als Ergebnis ausgewählt wird. Eine detaillierte Erläuterung zur Funktionsweise findet sich in [12]. Es ist erwähnenswert, dass der Nearest Neighbour-Klassifikator im Allgemeinen nicht die besten Ergebnisse liefert. Er dient jedoch meist als Referenzlösung, da er sich mit verhältnismäßig wenig Aufwand implementieren lässt. Des Weiteren kann man sich seine Funktionsweise gut vorstellen und so die prinzipielle Funktion des Systems validieren. Die Erfahrung zeigt allerdings

---

<sup>11</sup> Verfahren wie neuronale Netze, Gauß Prozesse oder Hidden Markov Modelle sind nicht Gegenstand dieser Betrachtung.

auch, dass die Leistungsfähigkeit des Verfahrens bei komplexen Problemen abnimmt, da der Algorithmus schlecht „verallgemeinern“ kann.

#### **5.2.4.2 Linear SVM und RBF SVM**

Eine Support Vector Machine (SVM) ist ein Klassifikationsalgorithmus zum Zuordnen von Stichproben zu einer vorher angelernten Menge von Klassen (im Kontext des TSFu sind Klassen als konkrete Ereignisse z.B. einen Brand im Tunnel zu verstehen). Für die Anlernphase einer SVM ist es notwendig, dass eine ausreichend große Menge von Trainingsdaten mit bekannter Klassenzugehörigkeit vorliegt. Während des Trainings versucht die SVM dann anhand der vorliegenden Messdaten (d.h. Stichproben die sowohl der zu trainierenden Klasse zugehörig sind als auch nicht) eine Hyperebene (Trennfläche) zu definieren, die diese beiden Klassen (zugehörig und nicht zugehörig) möglichst gut voneinander trennt. Diese Messdaten sollten dabei räumlich möglichst weit weg von der Hyperebene liegen, damit beim späteren Klassifizieren auch Daten korrekt zugeordnet werden, die nicht exakt den Trainingsdaten entsprechen. Sind die Messdaten linear trennbar kann eine lineare SVM-Implementierung genutzt werden. Ist dies nicht der Fall, kommt typischerweise die Nutzung des „Kernel-Tricks“ in Frage. Ein typischer Vertreter ist dabei der sogenannte radial basis function (RBF) Kernel [13].

#### **5.2.4.3 Decision Tree**

Decision Trees oder auch Entscheidungsbäume sind eine Verfahren zur Zuordnung von Stichproben aus Messdaten zu einer bekannten Klasse. Ein Decision Tree kann dabei immer nur eine konkrete Frage beantworten (z.B. gehört die gerade beobachtete Abfolge von Messdaten zu dem Ereignis Tunnelbrand?). Decision Trees stellen ein baumartiges Regelwerk dar, das von der Wurzel entlang bis zu einem Blatt (die zu untersuchende Klasse) traversiert wird. Bei jedem dabei auftretenden Knoten wird ein konkretes Merkmal der Stichprobe untersucht und anhand des Ergebnisses eine Entscheidung über den nächsten zu untersuchenden Knoten getroffen. Decision Trees können entweder von Experten manuell aufgestellt oder durch maschinelles Lernen aus gelabelten Messdaten erstellt werden. Dies wird oft als Induktion von Entscheidungsbäumen bezeichnet [14].

#### 5.2.4.4 Random Forest

Ein Random Forest ist ein Klassifikationsverfahren, bei dem mehrere Decision Trees parallel genutzt werden. Für die eigentliche Klassifikation wird jeder Decision Tree unabhängig befragt. Die Klasse mit den meisten Stimmen entscheidet letztendlich über das finale Klassifikationsergebnis. Random Forests sind besonders für große Datenmengen, die schnell analysiert und klassifiziert werden müssen von Vorteil.

#### 5.2.4.5 AdaBoost

Adaptive Boosting (kurz AdaBoost) ist ein Verfahren, bei dem mehrere sogenannte schwache Klassifikatoren kombiniert werden um einen einzelnen leistungsfähigen Klassifikator zu erzeugen. Schwache Klassifikatoren berücksichtigen dabei meist nur ein Merkmal der Stichprobe und sind dadurch sehr schnell aber auch nicht besonders robust. Durch die Zusammenführung (Boosting) mittels einer Gewichtung kann ein starker Klassifikator erzeugt werden.

#### 5.2.4.6 Naïve Bayes

Das Naïve Bayes-Verfahren stellt einen probabilistischen Klassifikator auf Basis des Bayes-Theorems dar. Dabei gilt die Annahme, dass die einzelnen Elemente des Merkmalsvektors (z.B. Brandalarm und Stillstand) für das Ereignis (z.B. Tunnelbrand) unabhängig sind (daher auch der Name naïve). Der Hauptvorteil dieses Klassifikationsverfahrens besteht in der relativ niedrigen Anzahl von notwendigen Trainingsdaten um den Klassifikator entsprechend zu trainieren. Für komplexe Zusammenhänge liefert der Naïve Bayes-Klassifikator erfahrungsgemäß schlechtere Ergebnisse als komplexere Verfahren wie AdaBoost oder Random Forest [16].

#### 5.2.4.7 Lineare Diskriminanzanalyse

Die lineare Diskriminanzanalyse (LDA) ist ein Klassifikationsverfahren zum Trennen von Daten in mehrere Klassen. Der Algorithmus prüft dabei auf geeignete und ungeeignete Merkmale des Eingangsvektors und reduziert ggf. die zu betrachtenden Dimensionen. Die Trennung der Klassen wird durch lineare Grenzen realisiert.

#### 5.2.4.8 Zusammenfassung

Nachdem sogenannte Merkmalsvektoren festgelegt sind (eine Art zeitliche Synchronisierung kann z.B. über die Zusammenstellung verschiedenen Messwerter über mehrere Tunnelquerschnitte erreicht werden) können die verschiedenen Klassifikatoren angelernt und mittels der verfügbaren Testdaten evaluiert werden. Der Nearest-Neighbor-Ansatz wird dabei aufgrund seiner bereits erwähnten Eigenschaften als ein Referenz-Algorithmus verstanden. Die anderen Kandidaten müssen sich dann hinsichtlich ihrer Erkennungsleistung an diesem messen.

### 5.3 Umsetzung

Aufgrund der Eigenschaften der Messdaten wurde eine Datenfusionsstrategie mittels Klassifikationsansatz gewählt. Dazu wurden zwei prinzipielle Vorgehensweisen untersucht:

1. Design, Entwurf und Training spezifischer Detektoren für die einzelnen Events wie „Geisterfahrer“, „Stillstand“, „Langsamfahrer“ und „Rauch“.
2. Design und Entwurf eines generischen Verfahrens zur Erkennung von „ungewöhnlichen Ereignissen“

Die prinzipielle Idee beruht dabei darauf, die Robustheit der Einzelsensoralarme zu erhöhen (weniger falsch positive Auslösungen) bzw. eine bessere Klassifikationsrate zu erreichen. Für den Entwurf spezifischer Detektoren/Klassifikatoren ist ein Anlernprozess mit repräsentativen und gelabelten Daten notwendig.

#### 5.3.1 Datenlabeling

Die rohen Messdaten der verschiedenen Tunnelsensoren liegen nach dem Export in einer zeitgestempelten Form bereit. Um den Ansatz der merkmalsbasierten Datenfusion mit Klassifikation durchzuführen, ist es im Anlernprozess in der Regel notwendig, dem zu trainierenden Klassifikator sowohl Messdaten, die der Klasse zugehören, als auch Messdaten die nicht der Klasse entsprechen, vorzulegen. Wenn man beispielsweise einen Klassifikator zum Erkennen von langsam fahrenden Fahrzeugen trainieren möchte, müssen sowohl Geschwindigkeitsmessungen mit niedriger Geschwindigkeit (Positive) als auch Geschwindigkeitsmessungen mit normaler oder hoher Geschwindigkeit (Negative) vorliegen. Dieses Verfahren lässt sich selbstverständlich auch auf mehrere Merkmale ausdehnen. Es ist allerdings zur berücksichtigen, dass mit der Erweiterung des Merkmalsvektors auch die Anzahl der notwendigen Testdaten ansteigt. Das Verhältnis ist

dabei in der Regel nicht linear (außer bei dem Naïve Bayes-Klassifikator), d.h mit zunehmender Länge des Merkmalsvektors müssen überproportional mehr gelabelte Trainingsdaten vorliegen. Die Messdaten wurden im Rahmen von TSFu durch einen manuellen Vorgang auf Basis von Kamerabildern im entsprechen Zeitraum durchgeführt. Dabei wurden anhand der Messdaten die Klassen Geisterfahrer, Stillstand, Langsamfahrer, Rauch abgeleitet. Ein Label besteht dabei aus:

- Zeit bzw. Datum
- Klasse
- True Positive oder False Postive Label

### 5.3.2 Merkmalsvektor

Für die Umsetzung der Datenfusion auf Merkmalsebenen ist es notwendig aus den zur Verfügung stehenden Messdaten einen sogenannten n-dimensionalen Merkmalsvektor  $x \in \mathbb{R}^n$  zusammenzustellen. Dabei ist es im ersten Schritt prinzipiell unerheblich, ob die im Merkmalsvektor zusammengefassten Einzelereignisse korreliert bzw. aussagekräftig sind. Eine elementare Aufgabe des Anlernvorgangs in der Klassifikationstheorie ist es, genau diese Zusammenhänge herauszufinden und intern durch geeignete Trennmechanismen zu realisieren.

Die initiale Idee, einen Merkmalsvektor für jeden Tunnelquerschnitt individuell zu erstellen wurde verworfen, da die Anzahl der Sensoren pro Tunnelquerschnitt nicht konstant ist und die räumlichen Informationen über die Anordnung nicht in der notwendigen Genauigkeit vorliegen.

Stattdessen wird jeweils ein Zeitbereich mit einer Art Sliding Window-Ansatz betrachtet und in diesem Zeitraum die Anzahl der Alarme aller Sensoren gezählt. Ein Dimension des Merkmalsvektor entspricht somit also der Anzahl der ausgelösten Alarme einer Sensorgruppe (z.B. Falschfahrer) im betrachteten Zeitraum. Die Idee dahinter beruht darauf, dass man davon ausgeht, dass z.B. ein tatsächlicher Falschfahrer im Mittel im Tunnel von mehreren unterschiedlichen Sensoren an unterschiedlichen Orten detektiert wird. Als Merkmalsvektor  $x \in \mathbb{R}^n$  wurde folgende konkrete Konfiguration gewählt:

$$x = [WrongWayDriverCounter, SlowVehicleCount, SmokeCount, StoppedCount]^T$$

Ein beobachteter Merkmalsvektor im Falle eines Geisterfahrers im Tunnel mit einem Sliding Window von  $t = 30s$  hatte dabei die folgende Ausprägung:

$$x_{t=30s} = [2, 3, 0, 0]^T$$

d.h, es wurden innerhalb von 30s 2 Falschfahreralarme sowie 3 Langsamfahreralarme ausgelöst. Die Restlichen Sensoralarme waren offensichtlich in dem konkreten Fall nicht relevant.

### 5.3.3 Event-Klassifizierung

Die Implementierung der verschiedenen Klassifikatorkandidaten aus Abschnitt 5.2.4 geschah auf Grundlage der Bibliothek scikit-learn<sup>12</sup> und wurde in der Programmiersprache Python implementiert. Der in Abschnitt 5.3.2 eingeführte Merkmalsvektor wurde dabei verwendet und die Gesamtmenge der gelabelten Daten entsprechend der Tabellen in Abschnitt 8.1.1 in Trainings- und Testset aufgeteilt. Anschließend erfolgte ein beobachtetes Anlernen (supervised learning) mit den zufällig selektierten Trainingsdaten. Dabei wurde zusätzlich darauf geachtet, dass die Trainingsdaten sowohl positive als auch negative Samples enthalten. Der Vorgang wurde für jeden Ereignis-Klassifikator (also z.B. Falschfahrer oder Rauch im Tunnel) und jeden Klassifikatortyp entsprechend wiederholt.

Nach dem erfolgten Anlernen wurde der trainierte Klassifikator mit bisher unbekanntem Messdaten getestet bzw. evaluiert. Der Klassifikationsprozess akkumuliert dazu die Messdaten bis der erreichte Schwellwert (z.B.  $t = 30s$ ) für das Sliding Window erreicht ist und erstellt daraus einen konkreten Merkmalsvektor analog zu 3.2. Im Anschluss daran wird der Merkmalsvektor an die entsprechenden Klassifikatoren (z.B. Klassifikator für Falschfahrer) übergeben. Das Ergebnis jedes Klassifikators ist dabei die Antwort auf die Frage, ob das zu testende Ereignis gerade eingetreten ist oder nicht. Je nach Implementierung eines Klassifikators kann die Aussage dabei binär sein (Ja/Nein) oder aber durch eine Wahrscheinlichkeit abgebildet sein. Dieser Prozess wird kontinuierlich wiederholt und das Ergebnis visualisiert. Unusual Event Detection

In Abschnitt 3.2.1 wurde die Implementierung spezifischer Klassifikatoren für die a priori bekannten Ereignisse bzw. Klassen Geisterfahrer, Stillstand, Langsamfahrer, Rauch vorgestellt. Das Verfahren beruhte darauf, dass gelabelte (bereits klassifizierte) Daten

---

<sup>12</sup> <http://scikit-learn.org/>



durch ein überwachtes Lernen zum Trainieren eines Klassifikators genutzt werden. Diese Methodik eignet sich sehr gut um konkrete Fragen nach vorher bekannten Ereignissen zu beantworten und somit die Robustheit gegenüber Falschalarmen (wie es im Ein-Sensor-Fall oft vorkommt) zu reduzieren. Sie setzt allerdings auch voraus, dass umfangreiche und konsistente Messdaten inkl. einer korrekten Klassenzuordnung für das Training vorliegen.

Im Rahmen von TSFu wurde daher ein weiterer probabilistischer Ansatz untersucht, der ohne vorab gelabelte Trainingsdaten auskommt. Dabei wurde der Versuch unternommen, ebenfalls auf Grundlage der merkmalsbasierten Datenfusion algorithmisch zu erkennen, ob das gerade durch die Sensoren beobachtete Verhalten im Tunnel von dem typischen Normalfall abweicht. Dieses Verfahren wird im Folgenden als *Unusual Event Detection* (UED) bezeichnet.

Die Anlernphase für die UED basiert ebenfalls auf einem umfangreichen Satz von Trainingsdaten, die allerdings im Gegensatz zu der in Abschnitt 3.2.1 vorgestellten Klassifikation nicht vorgelabelt sein müssen. Stattdessen wird ausschließlich durch den Nutzer bzw. einen Experten angegeben, wieviel Prozent der im Trainingsset befindlichen Messdaten das Normalverhalten beschreiben. Da in einem Tunnel in der Regel Normalbetrieb herrscht, kann hier z.B. mit einer Zahl wie 95% als Ausgangswert gearbeitet werden. Verfahren dieser Art werden daher in der Literatur auch als *unsupervised learning* bezeichnet. Intern lernt die UED die Statistik der einzelnen Sensordaten bzw. Merkmale unter Berücksichtigung der angegebenen Häufigkeit für Normalbetrieb auf Basis einer normalverteilten Wahrscheinlichkeitsdichtefunktion (Covariance Estimation). In der Klassifikationsphase erkennt der Algorithmus dann ein abweichendes Verhalten im Tunnel als sogenannten Ausreißer (Outlier).

Ein wesentlicher Vorteil dieses Ansatzes besteht darin, dass er mit einer deutlich größeren Datenmenge angelern werden kann, da das aufwändige labeln der Messdaten entfällt. In der Regel stellt sich dadurch eine höhere Robustheit ein. Außerdem können ebenfalls Ereignisse erkannt werden, für die ein dedizierter Klassifikator nur schwer



anzulernen ist, da eine statistisch relevante Grundmenge von Beobachtungen fehlt<sup>13</sup>. Im operativen Betrieb wäre dieses Verfahren zum Beispiel als Unterstützung für die Operatoren in der Leitstelle denkbar um deren Aufmerksamkeit im Falle eines detektierten abnormalen Verhaltens gezielt auf den entsprechenden Tunnel bzw. Tunnelquerschnitt zu lenken.

Das Erkennen von ungewöhnlichen Events basiert ausschließlich auf den Sensordaten und erfordert keine gelabelten Eingangsdaten zum Training. Es erfolgt ausschließlich eine Validierung mit den tatsächlichen Labels um die Detektionsleistung des Verfahrens zu evaluieren. Die Featurevektoren werden dabei analog zu dem eingangs beschriebenen Verfahren gebildet.

## 5.4 Datengrundlage

Grundlage der Entwicklung und Evaluierung waren die Excel/CSV-Export aus dem Tunnel Kirchdorf. Die rohen Messdatensequenzen wurden durch den Projektpartner TBT mit Labels versehen um eine Einordnung in „falsch positiv“ und „falsch negativ“ vornehmen zu können.

Anhand der gelabelten Messdaten werden dann über eine Art „Sliding Window“ die Sensoralarme in einem sogenannten Featurevektor zusammengefasst. Folgendes Beispiel soll dies verdeutlichen:

Beispiel: timeslice 30s -> 2 Events vom Typ Geisterfahrer und 3 vom Typ Langsamfahrer

Feature [GhostCount,SlowCount,SmokeCount,...] => [2,3,0,....]

Dadurch entsteht ein großer gelabelter Datensatz welcher mit klassischen supervised Machine Learning Algorithmen gelernt wird (siehe Ergebnisse unten).

Anschließend kann man "unbekannte" Features die im Tunnel auftreten klassifizieren => Anwendung läuft live mit und sammelt Alarme im Zeitfenster (z.B. 30 sek breite überlappende Fenster) -> Aussage immer erst am Ende des Zeitfensters (nach 30 sek)

---

<sup>13</sup> Zum Beispiel ist diese im Falle eines Klassifikators für das Ereignis „Falschfahrer“ bereits zu beobachten, da dieses Ereignis in der Realität nicht so oft in einem konkreten Tunnel vorkommt, als das sich daraus eine statistisch signifikante und robuste Modellierung ableiten ließe.

Im Folgenden sind für die implementierten Klassifikationen und Algorithmen die erreichten Ergebnisse aufgelistet.

#### 5.4.1 Beispielergebnis für Klassifikator auf Stau-Ereignis

Nearest Neighbors 0.92735042735

Linear SVM 0.92735042735

RBF SVM 0.918803418803

Decision Tree 0.92735042735

Random Forest 0.92735042735

AdaBoost 0.92735042735

Naive Bayes 0.713675213675

LDA 0.92735042735

Verglichen mit einer einfachen Heuristik, bei der bereits nach einem Sensoralarm der tatsächliche Event ausgelöst wird, ergibt sich eine Steigerung in der Genauigkeit von 0.1239 auf ca. 0.93 (1 ist das theoretische Maximum und impliziert, dass mit den getesteten Daten niemals ein Fehler aufgetreten ist). Selbst mit einer defensiveren Heuristik (z.B. ein Sensor muss mindestens vier Mal in Folge ausgelöst haben ist nur eine Genauigkeit von ca. 0.5 zu erreichen).

Im Folgenden sind die Eigenschaften der genutzten Klassifikationsalgorithmen für das Beispiel „Stau“ grafisch dargestellt:

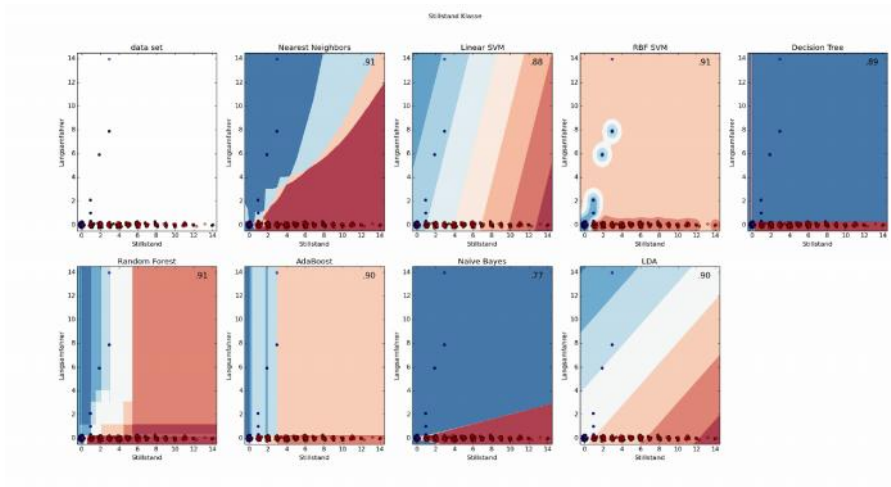


Abbildung 10: Beispiel für Klassifikationsdiagramme

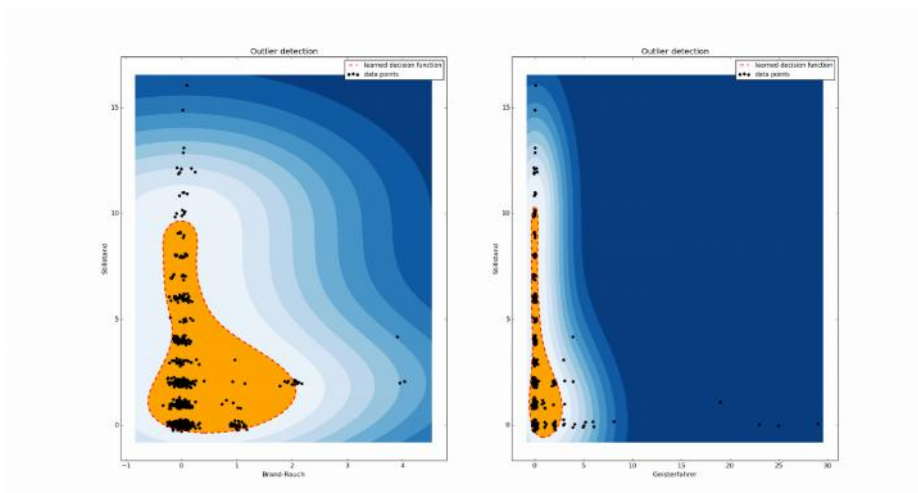


Abbildung 11: Beispieldiagramm Klassifikation Brandrauch

## 6 SCHNITTSTELLEN UND INTEGRATION

Das ursprüngliche Ziel dieses Arbeitspaketes, die Simulation der Schnittstelle zum Tunnelkopf in beide Richtungen, konnte im Laufe des Projektes nicht bearbeitet werden, da keine Lösung für den kontinuierlichen Export der Sensor- und Alarmdaten (Datenpunkte) aus dem Leitsystem gefunden wurde (M15).

Stattdessen wurden Datensätze manuell aus dem Datenbestand der ÜZ Bruck exportiert, detektierte Ereignisse klassifiziert (verifiziert oder falsifiziert) und die aufbereiteten Daten, dem Projektpartner Baselabs für die Fusion zur Verfügung gestellt. Die einzelnen Schritte werden im Folgenden erläutert.

An dieser Stelle sei angemerkt, dass die geplanten Aufwände des AP5 alleine durch die manuellen Exporte von TBT bei weitem überschritten wurden, auch ohne die Schnittstellenentwicklung.

### 6.1 Datenexport

Auf die Schnittstellenentwicklung auf Basis vom IEC 60870-5-104 musste in diesem Projekt aus den folgenden Gründen verzichtet werden:

- Schnittstelle zum Tunnelkopf und zur Leitebene nicht verfügbar
- Erweiterungsangebot von PKE für das zur Verfügung stellen einer neuen Schnittstelle wurde von ASFINAG nicht beauftragt
- Technisch konnte mit der gefundenen Lösung über den CSV Export das Projekt TSFu durchgeführt werden

Darum wurde in Übereinstimmung mit Hrn. DI Harbauer der ASFINAG von einer entsprechenden Schnittstellenentwicklung für den Demonstrator abgesehen.

Für die Bearbeitung der Datenfusion wurden stattdessen manuell Daten der Sensorik in comma-separated-files (CSV) extrahiert. An den Tagen 12.02.2015, 05.04.2015, 10.06.2015 und 17.08.2015 und konnten insgesamt über 2800 Megabyte an Datensätzen per Webinterface aus den Zeiträumen 1.12.2014 bis 28.02.2015, sowie vom 24.10.2010 exportiert werden. Darin enthalten sind 4622 Ereignismeldungen der Videodetektions- und

Audiodetektionsanlage, die weiter ausgewertet wurden. Zur manuellen Exportierung gab es leider keine Alternative. Der Zugriff und die Exportierung dieser Sensor- und Ereignisdaten hält einige Herausforderungen bereit:

- Daten des Tunnels „Kirchdorf“ können nicht in der ÜZ Wien exportiert werden. Stattdessen muss der Zugriff in der ÜZ Bruck erfolgen.
- Es sind viele manuelle Einzelschritte zur Exportierung einer Datensatzauswahl notwendig.
- Es kann pro Exportvorgang nur eine begrenzte Datenmenge exportiert werden. Werden zu viele Daten angefordert, bricht der Exportvorgang ohne Fehlermeldung ab. Dadurch muss nach jedem Exportversuch verifiziert werden ob Daten erfolgreich exportiert wurden oder nicht.
- Sensorrohdaten werden nicht für jeden Sensor und nicht über beliebige Zeiträume vorgehalten.

Zur Verifikation oder Falsifikation von Alarm- und Ereignismeldungen wurden diese manuell mit den aufgezeichneten Ereignisvideos abgeglichen. Dies musste aus Datenschutzgründen vor Ort in der ÜZ Bruck geschehen. Dabei wurde jedem von insgesamt detektierten 1136 Ereignissen zwischen dem 1.12.2014 und dem 27.02.2015 entweder der Zustand „Richtig-Positiv“ oder der Zustand „Falsch-Positiv“ zugeordnet. Diese Informationen werden zur Datenfusion im Sinne des „Supervised Machine Learning“ benötigt, wie in Abschnitt 5.2 beschrieben.

Zusammengefasst konnten insgesamt 686 positive Alarmmeldungen bestätigt werden: Etwa die Hälfte dieser positiven Alarme durch das Auftreten von Wartungsfahrzeugen, die langsam, entgegen der Fahrtrichtung, oder stehend agierten. Die andere Hälfte der positiven Alarme wurde durch tatsächliche Geisterfahrer, Langsamfahrer und Stehenbleiber ausgelöst. Dem gegenüber stehen 450 Alarme die falsifiziert werden mussten. Verschiedene Ursachen konnten als Fehlalarmursachen ausgemacht werden:

- Schatten, Lichtflecken oder Verschmutzung wurde als Objekte erkannt
- Lichtumschaltung im Tunnel
- Ausfall von Teilbeleuchtung
- Schlechte Beleuchtung

Zusätzlich stehen 1875 Alarmdatensätze zur Verfügung, die nicht auf Richtigkeit und Falschheit untersucht wurden. Diese können jedoch von der Fusionsmethode ausgewertet und klassifiziert werden, sodass eine nachträgliche, zielgerichtete Untersuchung möglich ist.

## 6.2 Schnittstellenintegration

Es fanden mehrere Gespräche und Diskussionen mit den Experten der ASFINAG zum Thema technischer Integration der Fusionsalgorithmen in die Leittechnik von ASFINAG Tunnelsystemen durchgeführt. Das Ergebnis daraus ist, dass die Einbettung des TSFu in bestehende und neu zu planende Tunnelanlagen zwischen Tunnelkopf und Leittechnik stattfinden muss.

Dabei müssen die, für die Sensorfusion verwendeten Rohdaten in gleicher Detaillierung vorliegen, wie sie für die Entwicklung der Fusionsalgorithmen verwendet wurden. Wie bereits beschrieben müssen dafür die Sensordaten in der gleichen Detailtiefe vorliegen, wie sie für die Untersuchung beim Tunnelkopf exportiert wurden.

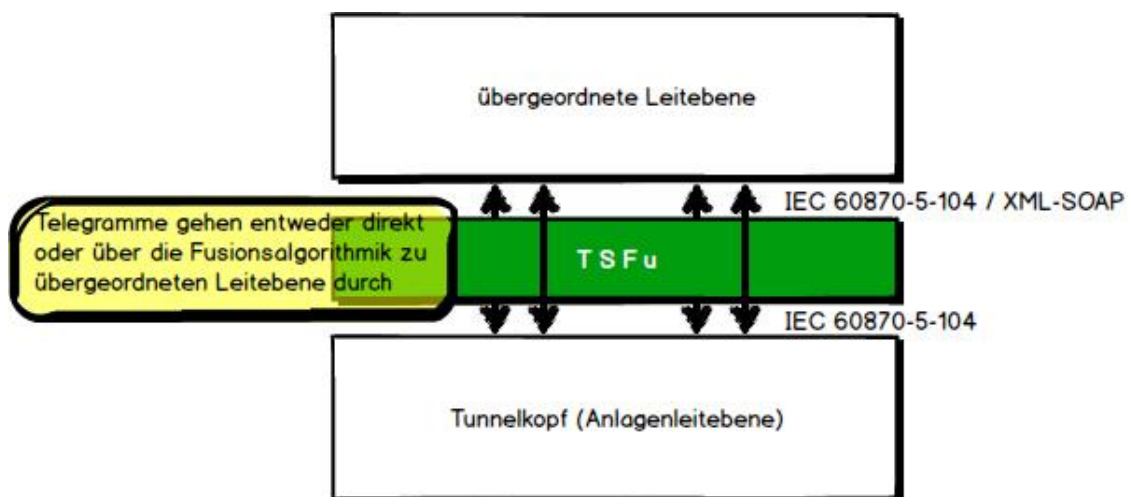


Abbildung 12: TSFu Integration in das Tunnelsystem

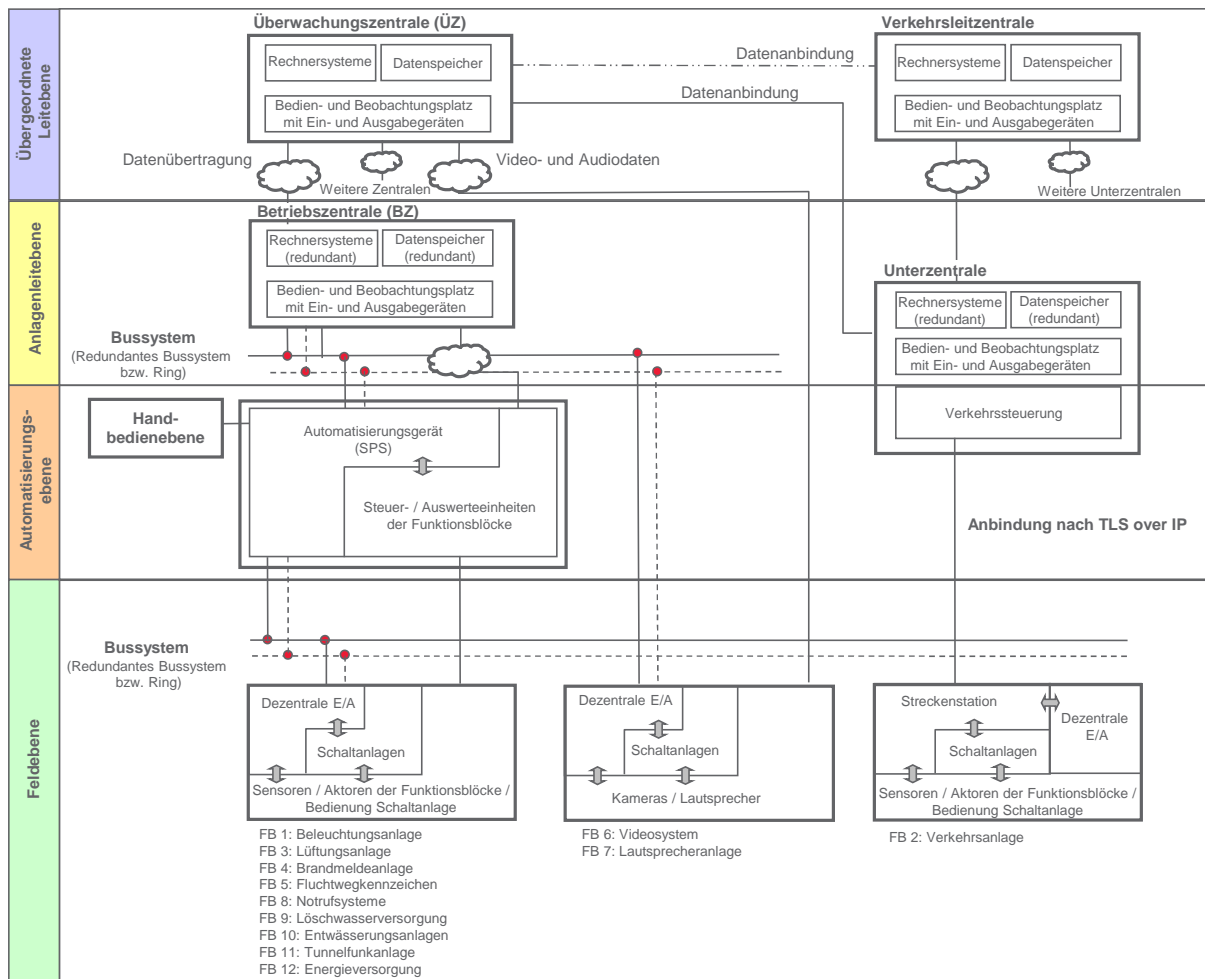


Abbildung 13: Schemenzeichnung Tunnelaufbau

In Abbildung 13 ersichtlich, wird ein Tunnelsystem aus einer Anlagenleitebene und einer übergeordneten Leitebene aufgebaut. Für eine Integration des TSFu in eine Tunnelanlage müsste also, wie in Abbildung 12 dargestellt, die Sensorfusion zwischen der Anlagenleitebene und der übergeordneten Leitebene angeordnet werden. Dabei könnten sowohl die ungefilterten Telegramme als auch dann die fusionierten Meldungen zur Leittechnik weitergereicht werden. Damit könnten in der Leittechnik, abhängig vom Betriebszustand des Tunnels, bewusst die Sensorfusionsmeldungen ignoriert werden. Dies kann z.B. für Subsystemtests aber auch bei Subsystemausfällen relevant sein.

## 7 DEMONSTRATOR

Um das untersuchte Datenfusionsverfahren auf Merkmalsebene in einen Tunnel zu integrieren, sind einige technische Voraussetzungen zu schaffen. Größte Herausforderung ist dabei das Anbinden an die Schnittstellen der Tunnelsensorik. Die im Abschnitt 5 vorgestellten Ergebnisse wurden ausschließlich offline, d.h. mit bereits aus einem Tunnelkopf exportierten Messdaten erstellt. Die Klassifikationsalgorithmen (sowohl für Einzelereignisse als auch die UED) sind prinzipiell onlinefähig, erfordern in diesem Modus allerdings das kontinuierliche Einspielen von aktuellen Messdaten um die Akkumulation für den Merkmalsvektor durchzuführen.

Um die prinzipielle Funktionsweise eines solchen Systems unter Echtzeitbedingungen zu demonstrieren wurde daher ein geeignetes Setup implementiert. Dies gliedert sich in drei Module:

1. Sensorinterface: Dieses Modul liest die exportierten Messdaten aus dem Tunnelkopf für einen gewählten Aufzeichnungszeitraum aus und spielt sie in Echtzeit ab. Die rohen Sensordaten werden dann über ein portables Interface an das Datenfusions-/Klassifikations-Module übergeben
2. Datenfusion/Klassifikation: Dieses Modul realisiert die Erkennung spezifischer Ereignisse bzw. abnormalen Verhaltens im Tunnel und ist analog zu Abschnitt 5.3 implementiert
3. Nutzerinterface: Um die Funktionsweise und den Vorteil der Datenfusion im Vergleich zu den Einzelsensoralarmen zu demonstrieren, wurde ein einfaches Nutzerinterface entwickelt, welche das Ergebnis der Klassifikation in Echtzeit visualisiert.

Alle drei Module wurden unabhängig voneinander implementiert um eine maximale Unabhängigkeit und hohe Portierbarkeit sowie Flexibilität zu erreichen. Die Module selbst sind über ein rechnerübergreifendes und plattformunabhängiges Interface miteinander verbunden. Dazu wurde ein Remote Procedure Call (RPC) Interface auf Basis von googles gRPC genutzt.



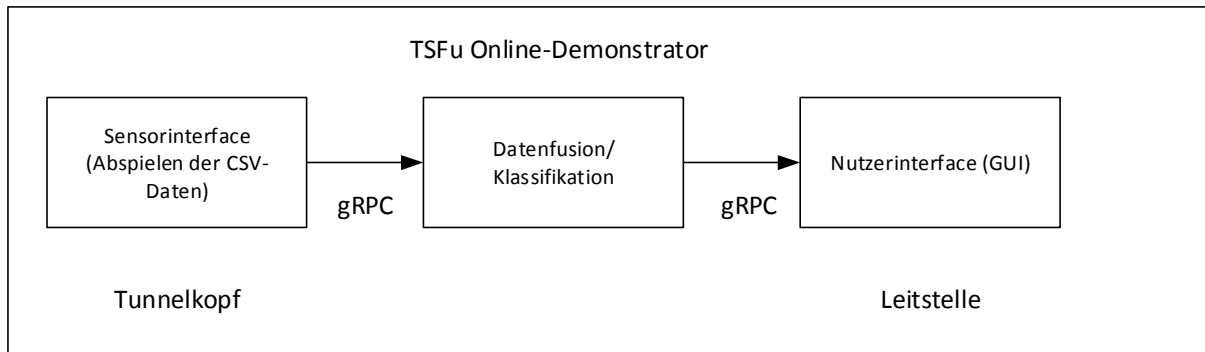


Abbildung 14: Schematische Darstellung des Online-Demonstrators.

In Abbildung 14 ist die Architektur des Online-Demonstrators schematisch dargestellt. Da alle drei Module über Netzwerkinterface miteinander kommunizieren, können sie an unterschiedlichen Stellen installiert werden. Die Datenfusion kann je nach Erfordernis entweder im Tunnelkopf oder aber der Leitstelle betrieben werden.

In Abbildung 15 wird ein schematischer Aufbau des Nutzerinterface dargestellt. Zu sehen sind einerseits Informationen zu Eingangsdaten aus den Sensor Rohdaten auf der linken Seite, als auch Informationen zu den verarbeiteten Eingangsdaten aus der Sensorfusion auf der rechten Seite. Mittig gibt es jeweils eine große Alarmleuchte, die den Zustand „grün“ (kein Alarm) oder rot (Alarm) annehmen kann. Dies geschieht, sobald mindestens einer der Alarme oder Klassifikatoren des zugehörigen Systems aktiv wird. Welcher Alarm/Klassifikator gerade aktiv ist, lässt sich aus der zugehörigen kleineren Alarmleuchte ablesen. Dabei werden die folgenden möglichen Alarme aus Rohdaten berücksichtigt: Aufprall/Platzer, Geisterfahrer, Langsamfahrer, Stillstand, Stau und Brand/Rauch als Tunnelereignisse, sowie Störung und Ausfall als Ereignisse die das Kamerasystem selbst betreffen.

Auf Seite der Fusion werden die folgenden Klassifikatoren berücksichtigt, wie in Kapitel 5: Unusual Event, Geisterfahrer, Langsamfahrer, Stillstand und Rauch als Tunnelereignisse. In Abbildung 15 ist zum Beispiel erkennbar, dass die Alarmleuchte der Rohdaten aktiv wurde, weil ein Stillstand detektiert wurde. Da die Klassifikatoren der Fusionsmethode jedoch nicht aktiv wurden, ist mit einem Fehlalarm zu rechnen. Zum Vergleich ist in Abbildung 16 ein Szenario aufgezeigt in dem der „Geisterfahrer“ Klassifikator die Informationen aus den Rohdaten als einen tatsächlichen Geisterfahrer ausgemacht hat, so dass auch die Alarmleuchte der Fusion aktiviert wurde.

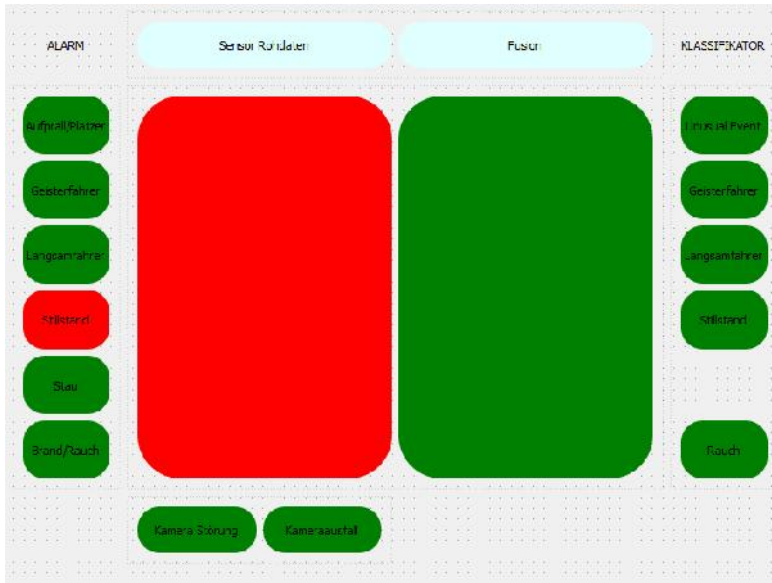


Abbildung 15: Schematischer Aufbau Nutzerinterface

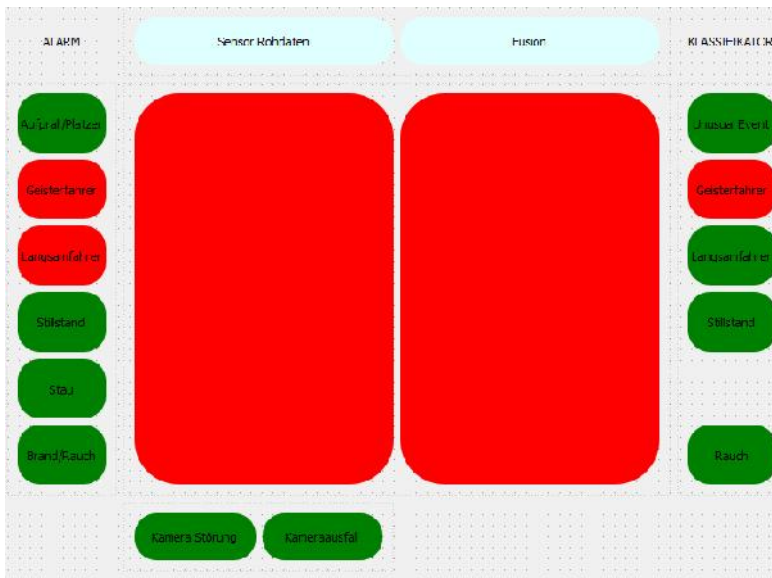


Abbildung 16: Beispielausgabe nach Fusion

## 8 ERGEBNISSE DATENFUSION

In diesem Abschnitt werden die mittels Datenfusion auf Merkmalsebenen erreichten Ergebnisse vorgestellt. Dabei wird sowohl auf die Leistungsfähigkeit und Erkennungsrate der dediziert angelernten *Klassifikatoren für spezifische Ereignisse*, als auch auf die *Unusual Event Detection* eingegangen.

### 8.1.1 Klassifikationsergebnisse

Im Rahmen des Vorhabens TSFu wurden verschiedene Klassifikatoren für spezifische Ereignisse, die typischerweise in einem Tunnelbetrieb auftreten können, entwickelt, implementiert und unter Aufsicht mittels gekennzeichnete Trainingsdaten angelernt. Es wurden alle gelabelten Ereignisse ausgewählt, die im betrachteten Zeitraum zur Verfügung standen. Anschließend wurden die angelernten Klassifikatoren auf unbekannte Echtdateien aus dem operativen Tunnelbetrieb angewendet, um deren Erkennungsleistung zu beurteilen. In diesem Abschnitt werden die erreichten Ergebnisse für die untersuchten Ereignisse genauer vorgestellt. Für jeden spezifischen Klassifikator wird mittels einer 2D-Darstellung gezeigt, wie sich der Einfluss der einzelnen relevanten Sensormessungen auf das gesamte Klassifikationsergebnis auswirkt. Anhand der Darstellung lässt sich leicht ableiten wie sich der Klassifikator in bestimmten Situationen verhalten wird. Desweiteren kann man an der Farbgebung erkennen, als wie „sicher“ ein Klassifikator sein Ergebnis bewertet.

Die folgenden Ergebnisse wurden aus 1547 Datenpunkten der Weströhre sowie 1441 Datenpunkten der Oströhre des Tunnels berechnet. Dabei konnte jeweils auf 636 bzw. 477 handgelabelte Daten zurückgegriffen werden. Für jeden spezifischen Klassifikator sind folgende Werte angegeben:

- Anzahl der gesamt verfügbaren handgelabelten Messdaten für dieses Ereignis inkl. positiver und negativer Stichproben
- Anzahl der für das Anlernen des Klassifikators genutzten gelabelten Messdaten (auch Trainingsset genannt) inkl. positiver und negativer Stichproben
- Anzahl der für das bestimmen der Klassifikationsgüte genutzten gelabelten Messdaten (auch Testset genannte) inkl. positiver und negativer Stichproben
- Erkennungsleistung/Güte des angelernten Klassifikators (Güte wird durch einen Wert zwischen 0,0 und 1,0 angegeben. Ein Wert von 1,0 bedeutet, dass der Klassifikator in

der Lage war, alle Stichproben aus dem Testset korrekt zu den entsprechenden handgelabelten Klasse zuzuordnen).

Außerdem wird für jedes Ereignis noch angegeben wie gut eine deterministische Heuristik auf Basis der Einzelalarme (d.h. es findet keine Datenfusion statt) das tatsächliche Ereignis erkannt hätte. Dazu wurde festgelegt, dass immer dann ein Ereignis gemeldet wird, wenn ein Einzelsensor mind. 2 mal hintereinander ausgelöst hat<sup>14</sup>. Löst also beispielsweise der Sensor, der Geisterfahrer direkt erkennen kann 2 oder mehr mal aus, wird das Ereignis *Geisterfahrer* gemeldet. Die dadurch ermittelte Erkennungsrate dient als Benchmark um die Robustheit gegen Falschalarme der Klassifikatoren zu bewerten. Auch wenn der Fokus bei dieser Evaluierung auf der Verringerung der Falschalarme liegt, sollte nicht unerwähnt bleiben, dass im Allgemeinen typischerweise sowohl die Falschalarmrate als auch die Anzahl der nicht detektierten echten Ereignisse relevant ist. Daher könnte eine alternative Beurteilung auch auf Basis der Genauigkeit (accuracy) stattfinden, wobei diese mit folgender Vorschrift bestimmt werden kann:

$$\text{accuracy} = \frac{\text{number of true positives} + \text{number of true negatives}}{\text{number of true positives} + \text{false positives} + \text{false negatives} + \text{true negatives}}$$

#### 8.1.1.1 Langsam fahrendes Fahrzeug (Slow Vehicle)

Die Anzahl der zur Verfügung stehenden und genutzten Stichproben für das Anlernen und Beurteilen des Klassifikators „langsam fahrendes Fahrzeug“ ist in Tabelle 12 zusammengefasst. Es ist hervorzuheben, dass in der gesamten zur Verfügung stehenden Messesequenz lediglich eine Stichprobe mit einem negativen Label vorhanden war.

In Abbildung 17/Abbildung 20 sind die Ergebnisse des Anlernvorgangs für einen Klassifikator zur Erkennung von Langsamfahr-Ereignissen im Tunnel grafisch dargestellt. Dabei wurde der Klassifikator nur mit den beiden Merkmalen „Stillstand“ und „Langsamfahrer“ trainiert. Beide Ereignisse liegen als separate Messungen der Tunnelsensorik vor. Blaue Kreise repräsentieren dabei positive Label, während rote Kreise ein negatives Label ausweisen. In der Darstellung ist zu sehen, wie die

---

<sup>14</sup> Durch Erhöhung des Schwellwertes auf 4 aufeinanderfolgende Ereignisse lässt sich die Falschalarmrate bereits um 50% senken. Allerdings steigt damit auch signifikant die Gefahr eine tatsächlichen Alarm zu verpassen und gar nicht zu melden.

verschiedenen Klassifikatoren die Einzelalarme Stillstand und Langsamfahrer nach der Fusion im Zusammenspiel bewerten. Im Diagramm für den Nearest Neighbor-Klassifikator ist gut zu erkennen, dass es zwei Bereiche gibt. Dabei werden Merkmalsvektoren, die in die blaue Fläche fallen als nicht zur Klasse *langsam fahrendes Fahrzeug*, erkannt während Merkmalsvektoren im roten Bereich als der Klasse zugehörig markiert werden. Aufgrund der Trainingsdaten, die ein Negativsample mit einem Merkmalsvektor für den Einzelalarm Langsamfahrer = 2 enthalten, bildet sich um diesen Bereich eine Fläche heraus, die der Klassifikator als nicht dieser Klasse zugehörig einstuft.

Der Klassifikator auf Basis einer linearen SVM teilt die Fläche vertikal ebenfalls auf Grund der Trainingsdaten. Allerdings liefert er nicht nur eine binäre Aussage sondern gibt über die Wahrscheinlichkeit ein Maß für die Sicherheit aus. Durch die lineare Trenngerade, kann der Klassifikator allerdings auch scheinbar belastbare Aussagen treffen, in Bereichen, in denen er niemals Testdaten gesehen hat. Beispielsweise würde er auch für ein Merkmalsvektor mit Langsamfahrer = 6 und Stillstand = 0.5 eine sehr hohe Klassenzugehörigkeit ausgeben. Erweitert man die SVM mittels eines RFB-Kernels ändert sich dieses Verhalten und der Klassifikator ist nun deutlich defensiver und damit konsistenter. Er liefert nun in Bereichen, in denen er kein Wissen anlernen konnte eine Klassenzugehörigkeit von ca. 0.5 was wahrscheinlichkeitstheoretisch dem *Nichtwissen* entspricht.

Der Decision Tree-Klassifikator markiert einen Bereich, der durch zwei horizontale Grenzen festgelegt ist und liefert in dieser Konfiguration auch nur eine binäre Aussage für die Klassenzugehörigkeit. Wird die Möglichkeit eines Random Forests genutzt, d.h. die Parallelschaltung mehrere Decision Trees, ergibt sich eine neue Fläche in der Merkmalsvektoren als nicht zur Klasse zugehörig (roter Bereich) erkannt werden.

Die erreichte Detektionsleistung der einzelnen Klassifikatoren für den Fall eines Langsamfahrerers im Tunnel unter Berücksichtigung des kompletten Merkmalsvektors ist in Tabelle 7Tabelle 13 zu sehen. Alle gelernten Klassifikatoren haben für Testdaten eine Erkennungsleistung von nahezu 100%. Ausschließlich der naive Bayes Klassifikator sowie die LDA erreichen diesen Wert nicht vollständig. Es ist auch zu erkennen, dass die

einfache Testheuristik nur eine Güte von ca. 3% erreicht, damit eine sehr hohe Falschalarmrate hat.

Set	Anzahl Labels	Positive Labels	Negative Labels
Gesamtset	344	343	1
Trainingsset	206	205	1
Testset	138	138	0

Tabelle 6 Statistik für die Labels für die Klasse langsam fahrendes Fahrzeug

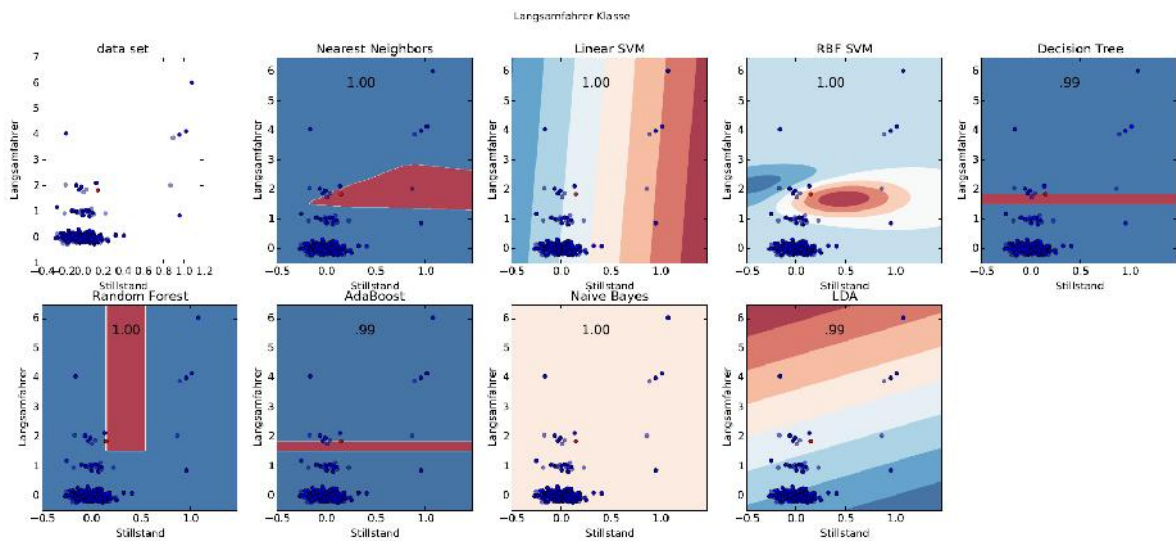


Abbildung 17 Trainingsergebnis für den Klassifikator „langsam fahrendes Fahrzeug“

Klassifikatortyp	Detektionsleistung (1.0 entspricht 100% korrekt)
Nearest Neighbors	1.0
Linear SVM	1.0
RBF SVM	1.0
Decision Tree	1.0
Random Forest	1.0
AdaBoost	1.0
Naive Bayes	0.978260869565
LDA	0.940170940171
Sensorrohdaten (Heuristik: Alarme > 1)	0.0289855072464

Tabelle 7: Ergebnisse des Klassifikators "langsam fahrendes Fahrzeug" auf dem Testset

#### 8.1.1.2 Rauch im Tunnel (Smoke)

Die Anzahl der zur Verfügung stehenden und genutzten Stichproben für das Anlernen und Beurteilen des Klassifikators „Rauch“ ist in Tabelle 8/Tabelle 12 zusammengefasst.

In Abbildung 18 sind die Ergebnisse des Anlernvorgangs für einen Klassifikator zur Erkennung von Rauch im Tunnel grafisch dargestellt. Dabei wurde der Klassifikator ausschließlich mit den Merkmalen „Brand/Rauch“ und „Langsamfahrer“ angelernt. Die Wahl der beiden Merkmale basiert auf der Annahme, dass es bei einer Rauchentwicklung im Tunnel mit hoher Wahrscheinlichkeit auch zu einem Stau durch langsam fahrende Fahrzeuge kommt. Beide Ereignisse liegen als separate Messungen der Tunnelsensoren vor.

Die erreichte Detektionsleistung der einzelnen Klassifikatoren für den Fall von Rauch im Tunnel unter Berücksichtigung des kompletten Merkmalsvektors ist in Tabelle 9 zu sehen.



Tabelle 8 Statistik zu den vorhandenen Labels für die Klasse „Rauch im Tunnel“

Set	Anzahl Labels	Positive Labels	Negative Labels
Gesamtset	72	48	24
Trainingsset	38	37	1
Testset	34	34	0

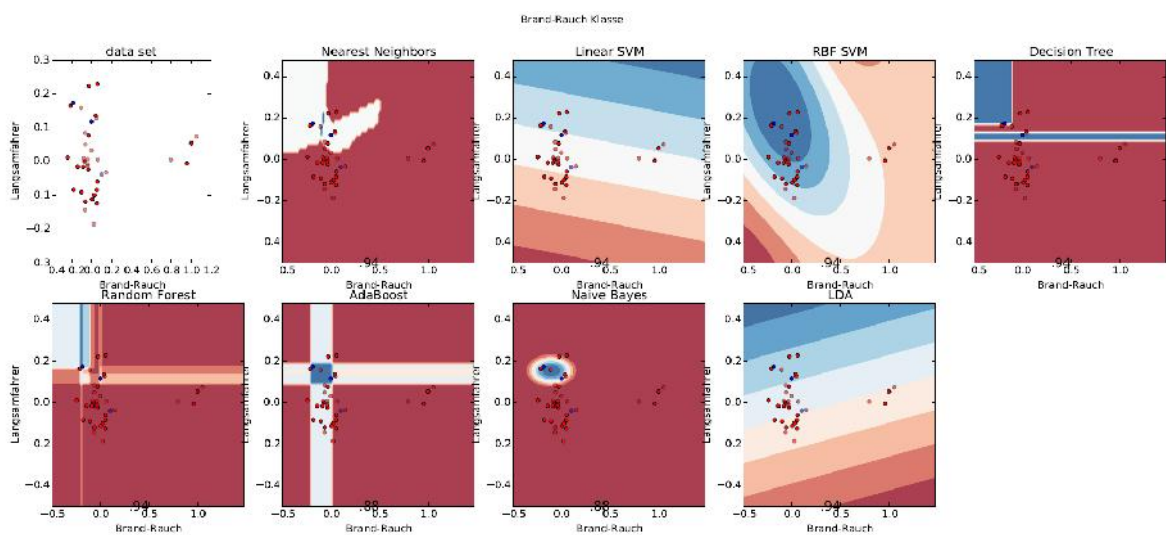


Abbildung 18 Trainingsergebnis für den Klassifikator „Rauch im Tunnel“



Klassifikator typ	Detektionsleistung (1.0 entspricht 100% korrekt)
Nearest Neighbors	0.9375
Linear SVM	0.9375
RBF SVM	0.9375
Decision Tree	0.9375
Random Forest	0.9375
AdaBoost	0.9375
Naive Bayes	0.125
LDA	0.9375
Sensorrohdaten (Heuristik: Alarme > 1)	0.9375

Tabelle 9: Ergebnisse des Klassifikators "Rauch im Tunnel" auf dem Testset

### 8.1.1.3 Stehendes Fahrzeug (Stopped Vehicle)

Die Anzahl der zur Verfügung stehenden und genutzten Stichproben für das Anlernen und Beurteilen des Klassifikators „Stehendes Fahrzeug“ ist in Tabelle 10 Statistik zu den vorhandenen Labels für die Klasse „stehendes Fahrzeug“ Tabelle 12 zusammengefasst. Hier ist hervorzuheben, dass für diesen Ereignisklassifikator erstmals ausreichend Testdaten sowohl in der Klasse der positiven als auch negativen Label zur Verfügung standen.

In Abbildung 19 Abbildung 20 sind die Ergebnisse des Anlernvorgangs für einen Klassifikator zur Erkennung von Stehend-Ereignissen im Tunnel grafisch dargestellt. Der Klassifikator wurde ausschließlich mit den beiden Merkmalen „Stillstand“ und „Langsamfahrer“ angelern. Beide Ereignisse liegen als separate Messungen der Tunnelsensorik vor. In der optischen Darstellung des Decision Trees erkennt man sehr gut die Korrelation zwischen den beiden Größen *Stillstand* und *Langsamfahrer*. Man sieht

auch, dass Merkmalsvektoren mit Langsamfahrer = 0 niemals auf eine Stehend-Ereignis hindeuten. Dies entspricht auch dem intuitiv erwarteten Verhalten.

Die erreichte Detektionsleistung der einzelnen Klassifikatoren für den Fall eines stehenden Fahrzeuges unter Berücksichtigung des kompletten Merkmalsvektors ist in Tabelle 11 Ergebnisse des Klassifikators "stehendes Fahrzeug" auf dem TestsetTabelle 13 zu sehen. Fast alle Klassifikatoren erreichen eine Erkennungsleistung von ca. 93% und sind somit der Einalarm-Heuristik, die ca. 30% Erkennungsleistung erreicht um den Faktor 3 überlegen. Das etwas schlechtere Ergebnis des naiven Bayes-Klassifikators mit nur 73% ist auf die explizite Nichtmodellierung der Korrelation zwischen den einzelnen Merkmalen zurückzuführen.

Set	Anzahl Labels	Positive Labels	Negative Labels
Gesamtset	585	174	411
Trainingsset	351	111	240
Testset	234	63	171

Tabelle 10 Statistik zu den vorhandenen Labels für die Klasse „stehendes Fahrzeug“

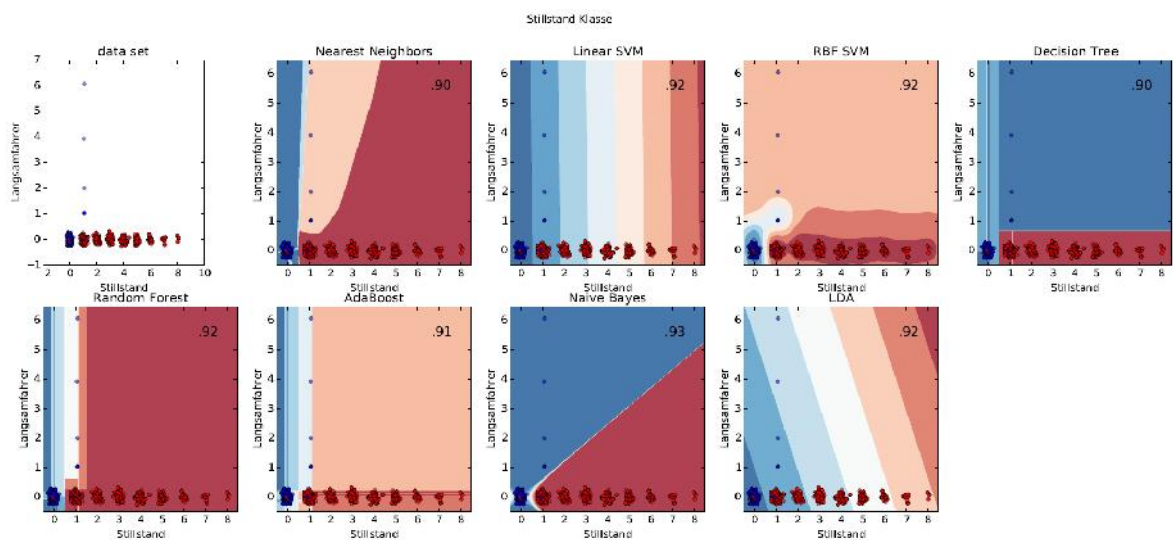


Abbildung 19 Trainingsergebnis für den Klassifikator „stehendes Fahrzeug“

Klassifikatortyp	Detektionsleistung (1.0 entspricht 100% korrekt)
Nearest Neighbors	0.935897435897
Linear SVM	0.935897435897
RBF SVM	0.935897435897
Decision Tree	0.935897435897
Random Forest	0.935897435897
AdaBoost	0.935897435897
Naive Bayes	0.735042735043
LDA	0.940170940171
Sensorrohdaten (Heuristik: Alarme > 1)	0.290598290598

Tabelle 11 Ergebnisse des Klassifikators "stehendes Fahrzeug" auf dem Testset

#### 8.1.1.4 Geisterfahrer (Wrong Way Driver)

Die Anzahl der zur Verfügung stehenden und genutzten Stichproben für das Anlernen und Beurteilen des Klassifikators „Geisterfahrer“ ist in Tabelle 12 zusammengefasst. Es ist hervorzuheben, dass für dieses Ereignis kaum gelabelte Negativbeispiele zur Verfügung standen.

In Abbildung 20 sind die Ergebnisse des Anlernvorgangs für einen Klassifikator zur Erkennung von Geisterfahrer-Ereignissen im Tunnel grafisch dargestellt. Der Klassifikator wurde ausschließlich mit den beiden Merkmalen „Geisterfahrer“ und „Langsamfahrer“ angelernnt. Beide Ereignisse liegen als separate Messungen der Tunnelsensorik vor.

Die erreichte Detektionsleistung der einzelnen Klassifikatoren für den Fall des Geisterfahrers unter Berücksichtigung des kompletten Merkmalsvektors ist in Tabelle 13 zu sehen.

Set	Anzahl Labels	Positive Labels	Negative Labels
Gesamtset	169	166	3
Trainingsset	101	99	2
Testset	68	67	1

Tabelle 12 Statistik zu den vorhandenen Labels für die Klasse „Geisterfahrer“

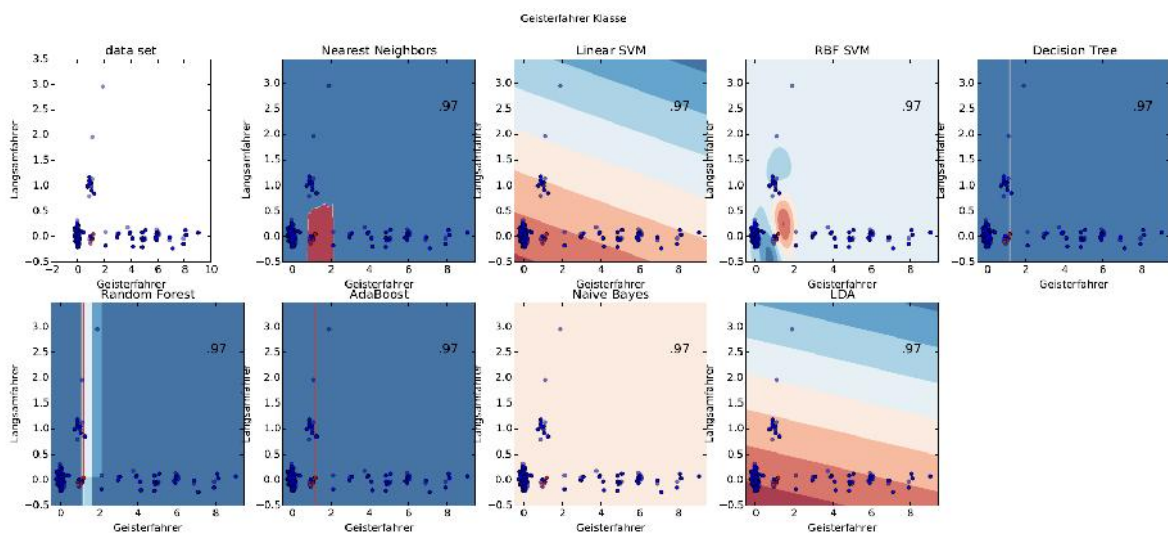


Abbildung 20 Trainingsergebnis für den Klassifikator „Geisterfahrer“

Klassifikatortyp	Detektionsleistung (1.0 entspricht 100% korrekt)
Nearest Neighbors	0.985294117647
Linear SVM	0.985294117647
RBF SVM	0.985294117647
Decision Tree	0.970588235294
Random Forest	0.970588235294
AdaBoost	0.985294117647
Naive Bayes	0.970588235294
LDA	0.985294117647
Sensorrohdaten (Heuristik: Alarme > 1)	0.220588235294

Tabelle 13 Ergebnisse des Klassifikators "Geisterfahrer" auf dem Testset

### 8.1.2 Erkennung ungewöhnlicher Situationen (Unusual Event Detection)

Während die im vorherigen Abschnitt evaluierten Klassifikatoren ausschließlich „entscheiden“ können, ob die aktuellen Messdaten einem spezifischen Ereignis (wie z.B. einem Geisterfahrer im Tunnel) ähneln, ist es mit Unusual Event Detection möglich prinzipiell vom Normalbetrieb abweichendes Verhalten im Tunnel zu detektieren und somit die Aufmerksamkeit des Personals gezielt auf diese Ereignisse zur weiteren Prüfung zu richten. Ähnlich wie im vorherigen Abschnitt wird zur besseren Verständlichkeit mit einer 2D-Visualisierung gearbeitet die jeweils zeigt, wie und mit welchem Gewicht die einzelnen Sensordetektionen in das resultierende Klassifikationsergebnis (usual bzw. unusual Event) eingehen.

In Tabelle 14 sind exemplarisch einige Ergebnisse der Unusual Event Detection auf den Sensordaten des Tunnels für den Zeitraum von Anfang Dezember 2014 bis Ende Januar

2015 gezeigt. Man kann gut erkennen, dass das Auslösen der UED im Falle von Unusual Events  $\geq 2$  offensichtlich auf ungewöhnliches Verhalten im Tunnel hindeutet. Beispielsweise hat die UED am 22.1.2015 95 ungewöhnliche Events im Tunnel registriert. Beim manuellen Einsehen der Messdaten zur Prüfung der Situation im Tunnel konnte festgestellt werden, dass zu dieser Zeit aufgrund von Bauarbeiten tatsächlich „Geisterfahrer“ in Form von Wartungsfahrzeugen im Tunnel unterwegs waren. Ähnlich, wenn auch nicht ganz so signifikant verhält es sich mit dem 02.12.2014. Hier gab es im Tunnel einen Brand der durch die UED als ungewöhnliches Verhalten durch 3 Events detektiert wurde.

Tabelle 14 Ergebnis der Unusual Event detections

Zeitraum	Usual Events	Unusual Events	Kommentar
2014-12-01	23	1	Niederschlag siehe Abbildung 21
2014-12-02	482	3	Brand im Tunnel
2014-12-21	61	2	Stau im Tunnel
2014-12-30	17	1	Kein tatsächliches Ereignis
2015-01-22	73	95	Geisterfahrer im Tunnel



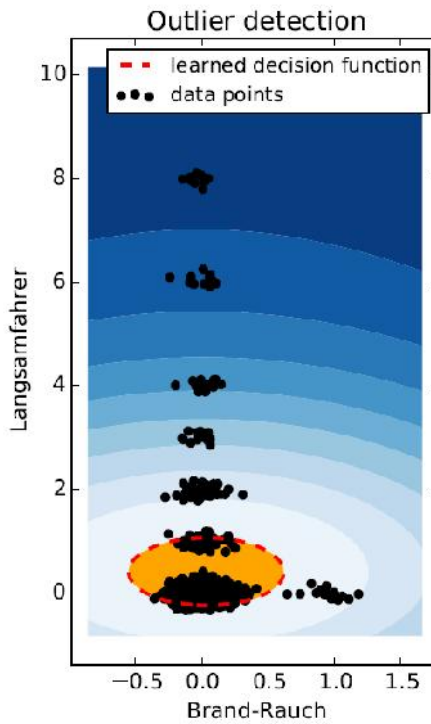


Abbildung 21: Niederschlag über dem Tagesverlauf

### 8.1.2.1 Langsamfahrer vs. stehendes Fahrzeug

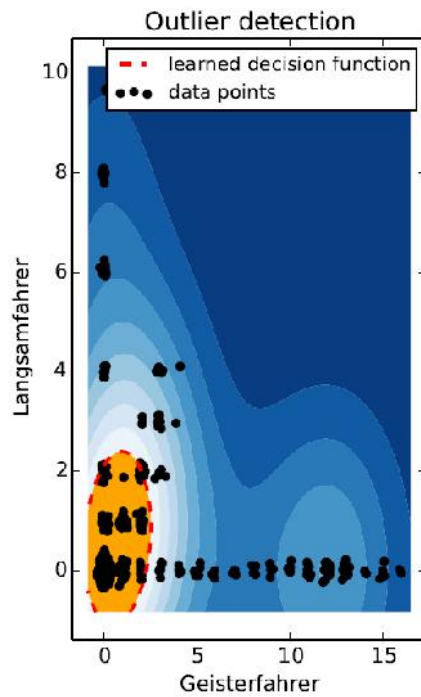


### 8.1.2.2 Rauch vs. Langsam fahrendes Fahrzeug

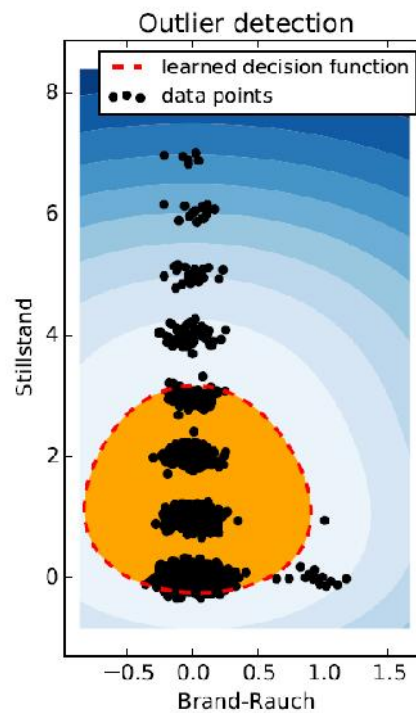




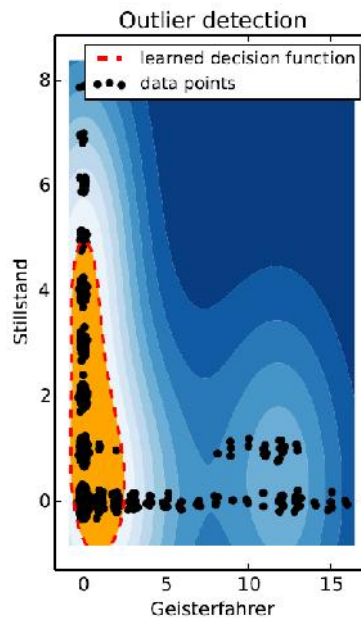
### 8.1.2.3 Geisterfahrer vs. Langsam fahrendes Fahrzeug



### 8.1.2.4 Rauch vs. stehendes Fahrzeug



### 8.1.2.5 Geisterfahrer vs. stehendes Fahrzeug



## 8.2 Beispielereignisse

Folgende Ereignisse konnten darüber hinaus in Bezug auf die zeitliche Fusion der Ereignisse näher untersucht werden. In Abbildung 22 und Abbildung 23 werden für den Monat Dezember 2014 die Alarme von AKUT und VBTC wiedergegeben. Man kann gut erkennen, dass an die Tage an denen es zu einer Alarmhäufung kommt, auch tatsächlich ein Großteil der Alarme gekoppelt ist. Interessant ist dabei, dass die Geisterfahrer am 1. 2. und 3. welche von dem Wartungsfahrzeugen während der Tunnelwartung erzeugt wurden nur durch das Videodetektionssystem erkannt wurden.




Abbildung 22: Alarmübersicht gesamt 12/2014




Abbildung 23: Alarmübersicht „richtig positiv“, für die Videodetektionsalarme




Abbildung 24: Betrachtung 22. Jänner 2015

Am 22. Jänner 2015 fand erneut eine Wartung bzw. Sperre statt. Die Aufprall/Platzer Meldungen entstanden an dem Tag um 11:39 und die Wartung bzw. der Kleintransporter, der als Geisterfahrer durch den Tunnel fährt fand um 22:50 statt. Zu diesem Zeitpunkt hat es keine AKUT Alarme gegeben. Wie man erkennen kann traten in Summe 95 Geisterfahrerauslösungen durch die Videodetektion auf.

Am 18.2. trat ein Unfall auf, der durch einen PKW der gegen die Tunnelwand gefahren ist verursacht wurde. Das Ereignis fand im Blickfeld der Kamera OR.5618 statt. Bei diesem Fall ging dem Unfall eine „Raserdetektion“ durch das Induktionsschleifensystem voraus.

KDTU OR.5614 VE -BG06.. Raser..... ALARM	2015.02.18 16:11:17,170	1
KDTU OR.5614 VE -BG06.. Raser..... ALARM	2015.02.18 16:11:49,670	0
2015 02 18 16 11 27 OR 5618 AM BX31.1 Aufprall/Platzer.... ALARM	#NV #NV	#NV
2015 02 18 16 11 29 OR 5618 AM BX31.1 Aufprall/Platzer.... ALARM	#NV #NV	#NV
2015 02 18 16 11 51 OR 5619 TV BX33.. Langsamfahrer..... AUSLÖ	1 0 PKW steht quer, Stau entsteht	
2015 02 18 16 11 51 OR 5619 TV BX33.. Langsamfahrer..... AUSLÖ	1 0 PKW steht quer, Stau entsteht	
2015 02 18 16 11 56 OR 5619 TV BX33.. Langsamfahrer..... AUSLÖ	1 0 PKW steht quer, Stau entsteht	
2015 02 18 16 12 05 OR 5619 TV BX33.. Stillstand..... AUSLÖ	1 0 rechte Spur blockiert, stockender Verkehr	
2015 02 18 16 12 23 OR 5619 TV BX33.. Stillstand..... AUSLÖ	1 0 rechte Spur blockiert, stockender Verkehr	
2015 02 18 16 12 30 OR 5619 TV BX33.. Langsamfahrer..... AUSLÖ	1 0 rechte Spur blockiert, stockender Verkehr	

Im Detail war also der chronologisch Ablauf wie in Tabelle 15 dargestellt.

Zeitpunkt	Baugruppe	Ereignis	Bemerkung
2015.02.18 16:11:17	OR.5614 BG06 Schleife	Raser	
2015.02.18 16:11:29	OR.5618 BX31.1 AKUT	Aufprall	
2015.02.18 16:11:51	OR 5619 BX33 VBTC	Langsamfahrer	Fzg. Schleudert durch das Bild
2015.02.18 16:11:56	OR 5619 BX33 VBTC	Langsamfahrer	PKW rollt, nachkommendes Fzg.
2015.02.18 16:12:05	OR 5619 BX33 VBTC	Stillstand	PKW steht um 16:12:01

Tabelle 15: Unfall am 18.2.2015 Chronologie

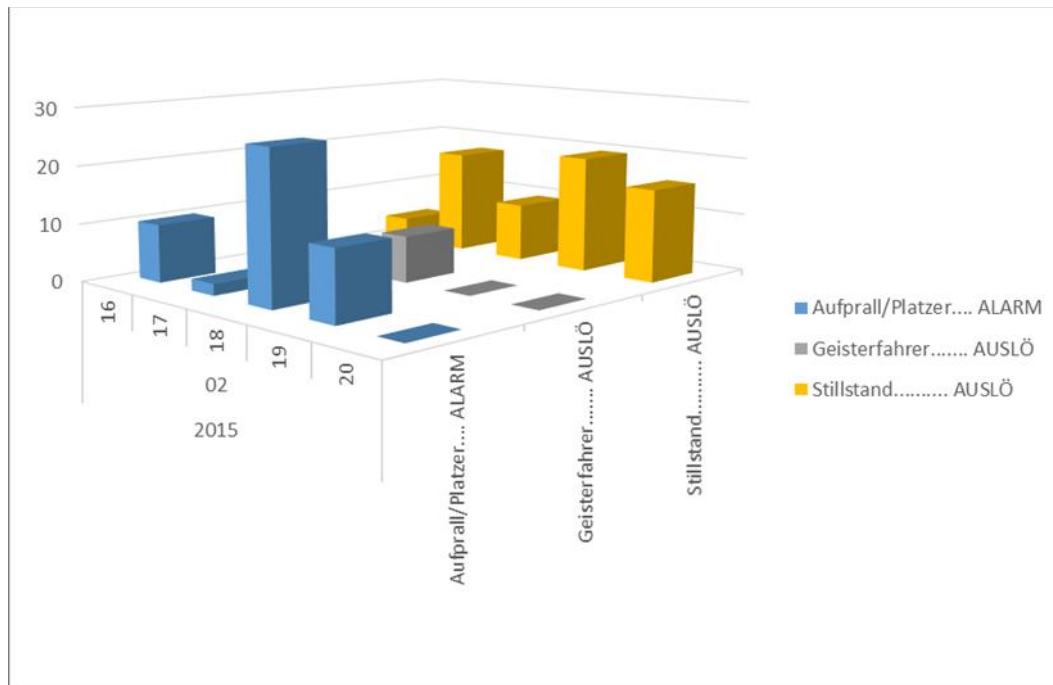


Abbildung 25: Detailansicht 18. Februar 2015 mit dem Unfall

Ein weiteres Interessantes Ereignis war eine „Verrauchung“ durch ein Fahrzeug, das offensichtlich eine staubige Ladung durch den Tunnel geführt hat und damit die Sicht eingetrübt hat.

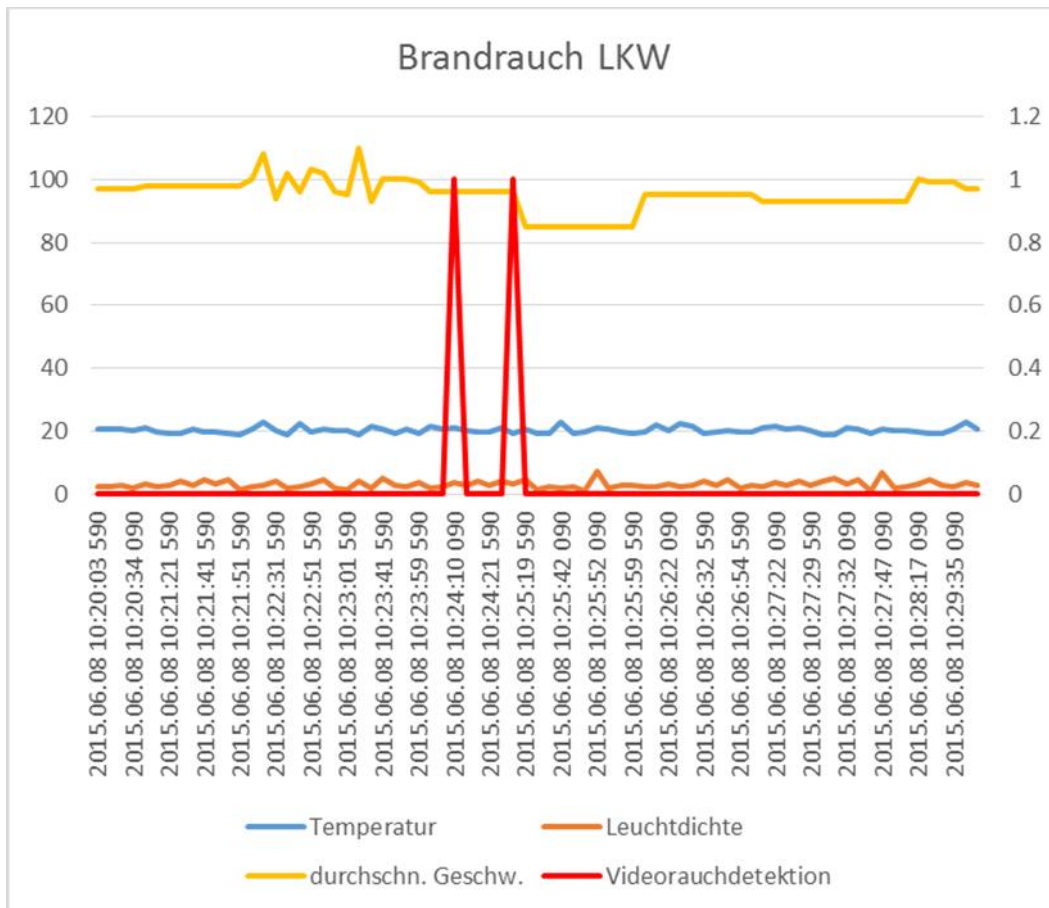


Abbildung 26: Darstellung zeitlicher Verlauf Verrauchung 8. Juni 2015

Dieses Ereignis zeigt, dass mittels des Fusionsansatzes und der Einstufung des Zustandes als nicht auffällig korrekt ist, d.h. es kommt zu keinen Reaktionen der anderen Verkehrsteilnehmer und dadurch zu der Klassifikation eines Fehlalarms.

## LITERATUR

- [1] Schubert, R., Richter, E., Mattern, N., & Lobel, H. (2012). Rapid Prototyping of ADAS and ITS applications on the example of a vision-based vehicle tracking system. In *19th ITS World Congress*
- [2] Ristic, B., Arulampalam, S., & Gordon, N. J. (2004). *Beyond the Kalman filter: Particle filters for tracking applications*. Artech house.
- [3] Schubert, R., Adam, C., Obst, M., Mattern, N., Leonhardt, V., & Wanielik, G. (2011, June). Empirical evaluation of vehicular models for ego motion estimation. In *Intelligent Vehicles Symposium (IV), 2011 IEEE* (pp. 534-539). IEEE.
- [4] Obst, M. (2014). Bayesian Approach for Reliable GNSS-based Vehicle Localization in Urban Areas. Dissertation, Technische Universität Chemnitz, 2014
- [5] Winner, H., Hakuli, S., & Wolf, G. (2009). *Handbuch Fahrerassistenzsysteme* (pp. 522-542). Springer Fachmedien.
- [6] PLaNT 170.020.2000 Videobasierte Detektionssysteme Technische Spezifikation
- [7] PLaPB 800.551.2000 (VBA)
- [8] PLaPB 800.562.2000 (BEL)
- [9] PLaPB 800.563.200\_Tunnel (BuS)
- [10] PLaPB 800.566.1600 (SLT)
- [11] RVS 09.02.22\_Tunnelausrüstung
- [12] Altman, N. S. (1992). An introduction to kernel and nearest-neighbor nonparametric regression. *The American Statistician*, 46(3), 175-185.
- [13] Vert, J. P., Tsuda, K., & Schölkopf, B. (2004). A primer on kernel methods. *Kernel Methods in Computational Biology*, 35-70.
- [14] Michalski, R. S., Carbonell, J. G., & Mitchell, T. M. (Eds.). (2013). *Machine learning: An artificial intelligence approach*. Springer Science & Business Media.
- [15] Zhang, H. (2004). The optimality of naive Bayes. *AA*, 1(2), 3.
- [16] Caruana, R., & Niculescu-Mizil, A. (2006, June). An empirical comparison of supervised learning algorithms. In *Proceedings of the 23rd international conference on Machine learning* (pp. 161-168). ACM.
- [17] Julier, S. J., & Uhlmann, J. K. (2004). Unscented filtering and nonlinear estimation. *Proceedings of the IEEE*, 92(3), 401-422.

