

Miroslav Pejic¹, Bilal Üyümez¹, Marko Pavlic², Robert Arndt² und Andreas Oetting¹

¹ Institut für Bahnsysteme und Bahntechnik, TU Darmstadt, Otto-Berndt-Straße 2 64287 Darmstadt

² M2C ExpertControl GmbH, Industriestr 12, 82194 Gröbenzell

1 Einleitung

Die Erforschung der Einsatzmöglichkeiten KI-basierter Systeme ist ein fortlaufender Prozess. Systeme, die große Datenmengen in kurzer Zeit auswerten müssen, kommen ohne KI nicht mehr aus. Ein System, das eine KI-basierte Komponente integriert, ist das FOS-System. Dieses streckenseitige System nutzt faseroptische Sensoren, um akustische Daten zu erfassen und die daraus entstehenden Muster auszuwerten. FOS-System hat vielfältige Anwendungsbereiche, die von nicht sicherheitskritischen Bereichen wie Fahrgastinformationen bis hin zu sicherheitskritischen Anwendungen im Bahnverkehr, wie Zuglokalisierung, reichen.

Im Rahmen des FoSSIL 4.0-Projekts haben die Kooperationspartner DB Netz, AP Sensing und die TU Darmstadt mit Unterstützung von INCYDE und M2C den Einsatz vom FOS-System mittels DAS (Distributed Acoustic Sensing) in sicherheitskritischen Anwendungen im Bahnverkehr untersucht. Der Schwerpunkt lag dabei auf der Zuglokalisierung und der Zugvollständigkeitskontrolle. Das Projekt lieferte wichtige Erkenntnisse darüber, wie potenzielle Störungen im FOS-System (insbesondere Fehler in der ML-basierten Komponente) und ihre Auswirkungen, bewältigt werden können. Im vorliegenden Paper werden von M2C und TU Darmstadt die ausgewählten Erkenntnisse des FoSSIL 4.0-Projekts zusammengefasst, indem es nicht nur die Möglichkeiten, sondern auch die Herausforderungen und Risiken aufgezeigt, die mit der Verwendung von FOS-System verbunden sind. Dabei werden auch Lösungen und Strategien diskutiert, die dazu beitragen können, die Zuverlässigkeit, Verfügbarkeit, Wartbarkeit und Sicherheit dieses Systems zu verbessern.

Zu Beginn wird in Kapitel 2 ein Vergleich zwischen den verfügbaren Technologien, die Glasfasern als Sensoren verwenden, angestellt. Kapitel 3 bietet dem Leser einen Überblick über den RAMS-Prozess. In Kapitel 4 wird das Systemdesign von deterministischen und KI-basierten Ansätzen behandelt. Kapitel 5 beleuchtet die konventionellen und zukünftigen Zugortungssysteme. In Kapitel 6 werden die Testfahrten der ML-basierten Zugortung sowie die Möglichkeit virtueller Testfahrten vorgestellt. Anschließend wird ein anwendungsfallbasierter Lösungsvorschlag zur Zulassung des ML-basierten FOS-Systems beschrieben. In Kapitel 7 wird das Potenzial des FOS-Systems für nicht sicherheitskritische Anwendungen dargelegt.

Korrespondierende Autoren:

¹ Miroslav Pejic: pejic@verkehr.tu-darmstadt.de

¹ Bilal Üyümez: ueyuemez@verkehr.tu-darmstadt.de

² Robert Arndt: robert.arndt@m2cec.com

² Marko Pavlic: marko.pavlic@m2cec.com

2 DAS- und weitere FOS-Systeme im Vergleich

Faseroptische Sensorik, im weiteren Text als FOS bezeichnet, wird in verschiedenen Anwendungsgebieten eingesetzt. FOS umfasst eine Reihe von Technologien, die Glasfasern als Sensoren verwenden, um unterschiedliche physikalische Parameter entlang der Faser zu messen. Abhängig von den zu messenden physikalischen Parametern kommen dabei unterschiedliche Technologien zum Einsatz:

- Fiber optic Linear Heat Detection (LHD) – LHD-System ist darauf ausgelegt, Temperaturveränderungen entlang eines Sensorkabels zu überwachen und zu erkennen. Ein faseroptisches LHD verwendet Standard-Glasfasersensorkabel, die typischerweise über mehrere Kilometer verlaufen und als lineare Temperatursensoren fungieren. Diese Systeme sind vollständig verteilt, das heißt, sie reagieren gleichmäßig auf Hitze an jedem Punkt entlang des Kabels. Das Ergebnis der Messung ist ein kontinuierliches Temperaturprofil entlang der gesamten Länge des Sensorkabels.
- Distributed Temperature Sensing (DTS) – DTS-System nutzt herkömmliche Glasfasern, die typischerweise über mehrere Kilometer verlaufen, als lineare Temperatursensoren. Diese Methode liefert ein räumlich hochaufgelöstes Temperaturprofil entlang der gesamten Länge des Sensorkabels. DTS basiert entweder auf der Raman- oder Brillouin-Streuung, um präzise Temperaturdaten zu erhalten. Ein Laserimpuls wird periodisch in die Faser gesendet und erzeugt schwach rückgestreutes Licht, das zum Auswertegerät zurückkehrt und kontinuierlich analysiert wird.
- Distributed Acoustic/Vibration Sensing (DAS/DVS) - Distributed Acoustic/Vibrational Sensing-Systeme erfassen Vibrationen und akustische Energie entlang von Glasfasern. Bestehende Glasfasernetze entlang der Anlagen werden genutzt und in verteilte akustische Sensoren umgewandelt, die Echtzeitdaten erfassen. [1]

Im vorliegenden Papier wird das DAS-System weiter untersucht. Das Messprinzip des DAS-Systems basiert darauf, dass Lichtpulse durch die Faser gesendet und das zurückgestreute Licht detektiert werden. Bewegungen auf oder in der Nähe der Gleise, die Erschütterungen verursachen, führen zu Veränderungen des zurückgestreuten Lichts. Abhängig von der Intensität der Bewegungen können verschiedene Muster im Gleis erkannt werden. Diese Bewegungen können in Echtzeit lokalisiert und die entstandenen Muster entsprechend klassifiziert werden. Dadurch eröffnet sich die Möglichkeit, dieses infrastrukturbasierte Sensorsystem als Quelle für kontinuierliche Daten zu nutzen. Diese Daten können für verschiedene Anwendungen verwendet werden, die von nicht-sicherheitskritischen bis hin zu sicherheitskritischen Anwendungen mit unterschiedlichen Sicherheitsanforderungen reichen. Dieses Paper konzentriert sich auf sicherheitsrelevante Bahnanwendungen, beleuchtet jedoch auch das Potenzial des DAS-Systems für nicht-sicherheitskritische Anwendungen. Da die Systeme, die in sicherheitskritischen Bahnanwendungen verwendet werden, klar definierte Anforderungen erfüllen müssen, wird die normkonforme Entwicklung dieser Systeme im nächsten Kapitel kurz erläutert.

3 Sicherheit und Verfügbarkeit von Systemen im Bahnbetrieb – ein Überblick über den RAMS-Prozess

Die CENELEC (Comité Européen de Normalisation Électrotechnique) Normen spielen eine wesentliche Rolle für die Sicherheit im Bahnbetrieb, insbesondere im Bereich der elektrischen und elektronischen Systeme. Diese Normen stellen sicher, dass die Systeme und Komponenten, die im Bahnbetrieb verwendet werden, sicher, zuverlässig und interoperabel sind. Hierbei ist die EN 50126 [2] wohl die wichtigste aller Normen und legt die Anforderungen und Verfahren zur Sicherstellung der Zuverlässigkeit, Verfügbarkeit, Instandhaltbarkeit und Sicherheit (RAMS) von Bahnsystemen fest. Sie behandelt den gesamten Lebenszyklus eines Bahnsystems von der Konzeption bis hin zur Außerbetriebnahme. Dieser sogenannte RAMS-Lebenszyklus, der in Abb. 1 dargestellt ist, wird in insgesamt 12 Phasen unterteilt wobei der Fokus dieser Arbeit auf den Phasen ein bis sechs liegt.

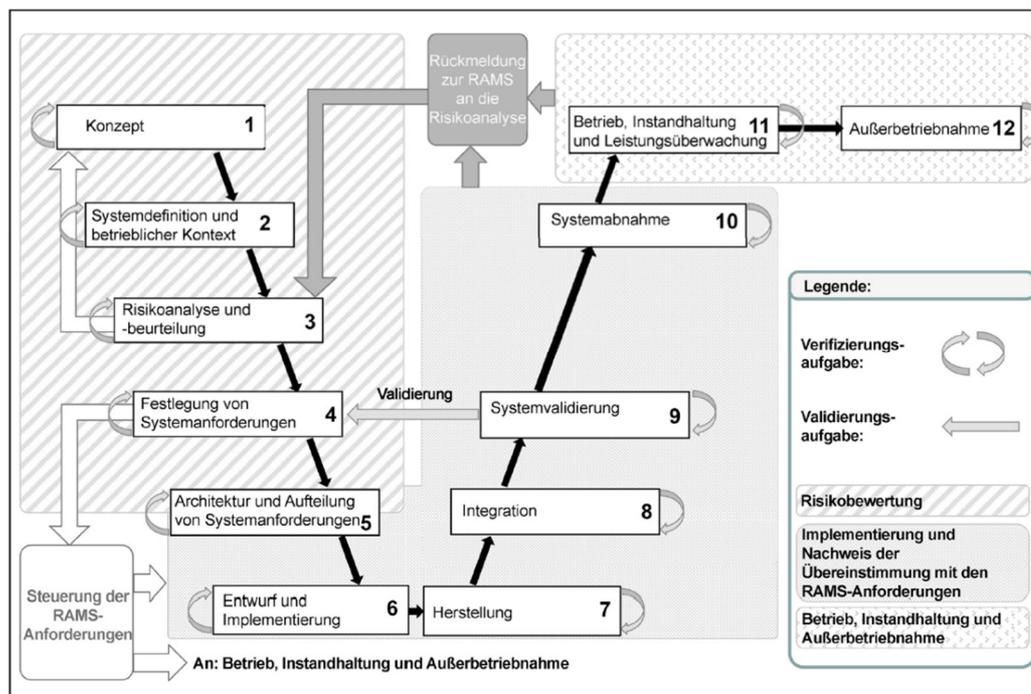


Abb. 1 RAMS Lebenszyklus nach EN 50126

Quelle: [2].

In der Phase 1 (Konzept) gilt es die Aufgabenstellung des Projektes auszuarbeiten. In der Phase 2 (Systemdefinition und Betrieblicher Kontext) werden die wesentlichen Eigenschaften und Funktionen des Systems beschrieben, die Grenzen des Systems definiert und deren Auswirkung auf andere Systeme analysiert. Weiters wird der Umfang der Gefahrenanalyse und die RAMS-Politik festgelegt. In Phase 3 (Risikoanalyse und -beurteilung) werden die mit dem System verbundenen Gefahren identifiziert und bewertet und legt spezifische RAMS-Anforderungen fest.

Anschließend wird in Phase 4 (Festlegung von Systemanforderungen) ein detaillierter Anforderungskatalog für das System erstellt. In der Phase 5 (Architektur und Aufteilung von Systemanforderungen) wird die Systemarchitektur entwickelt und gesamten RAMS-Anforderungen auf die einzelnen Teilsysteme beziehungsweise Komponenten aufgeteilt. Phase 6 (Entwurf und Implementierung) dreht sich um die Entwicklung und Integration der Systemkomponenten und die Durchführung von Tests zur Sicherstellung, dass das System den spezifizierten Anforderungen entspricht.

Bei der Dekomposition des Systems in Phase 5 erfolgt die Zuordnung der Anforderungen an die Teilsysteme und/oder Komponenten des Gesamtsystems. Der Prozess der Aufteilung der sicherheitsbezogenen Anforderungen wird als „Gefährdungsbeherrschung“ definiert [3]. Gefährdungen müssen in einem gewissen Maß toleriert werden und so gibt es eine Abhängigkeit zwischen diesem tolerierbaren Maß und der Sicherheitsintegritäts-Einstufung (SIL-Einstufung). In der nachstehenden SIL-Tabelle ist, basierend auf der tolerierbaren funktionalen Ausfallrate (TFFR, en: Tolerable Functional Failure Rate) für eine sicherheitsbezogene elektronische Funktion, der geforderte SIL festgelegt:

Tab. 1 SIL Einstufung in Abhängigkeit von TFFR

TFFR [h ⁻¹]	SIL Zuordnung	Erlaubte Gefährdungen
$10^{-9} \leq \text{TFFR} < 10^{-8}$	4	1 in 10 000 Jahren
$10^{-8} \leq \text{TFFR} < 10^{-7}$	3	1 in 1 000 Jahren
$10^{-7} \leq \text{TFFR} < 10^{-6}$	2	1 in 100 Jahren
$10^{-6} \leq \text{TFFR} < 10^{-5}$	1	1 in 10 Jahren
$10^{-5} \leq \text{TFFR}$	Basic SIL	

Bei der Dekomposition des Systems erfolgt die Zuordnung einer Sicherheitsintegritätsstufe für jedes Teilsystem, so dass das Gesamtsystem die gewünschte SIL-Einstufung erreicht. Letztendlich führt dies zu den erforderlichen Software-Integritätsstufen im Fall von Softwareentwicklung.

Die Anforderungen und Verfahren zur Entwicklung sicherer und zuverlässiger Software für Bahnsteuerungs- und Schutzsysteme werden in der Norm **DIN EN 50716** [4] beschrieben. Im Zuge dieser Arbeit muss hier speziell auf die Richtlinien zur Wahl der Softwarearchitektur in Tabelle A.3 der EN 50716 verwiesen werden, in der KI-Methoden für alle SIL-Level als „nicht empfohlen“ eingestuft werden. Dies wird mit den folgenden vier Herausforderungen die KI-Methoden mit sich bringen begründet:

1. Sicherstellung, dass die Trainingsdaten ausreichend vollständig und genau sind, so dass es hinreichend unwahrscheinlich ist, dass eine Situation, die nicht in den Trainingsdaten enthalten ist, in der Praxis tatsächlich auftritt.
2. Softwareverifikation ist nicht möglich da die trainierte Software nicht einsehbar ist.
3. Validierung der angenäherten Funktionalität.
4. Angriffe von außen und fehlende Kausalität.

Diese Herausforderungen müssen überwunden werden, wenn KI-Techniken als praktikable Techniken für die Softwareentwicklung in die EN 50716 aufgenommen werden sollen. Im nächsten Kapitel wird die Revolution im Systemdesign betrachtet, indem KI-basierte Ansätze mit deterministischen Systemen verglichen werden.

4 Revolution im Systemdesign: KI-basierte vs. deterministische Systeme

Entsprechend des vorigen Kapitels müssen die Entscheidungen von technischen Systemen für den Nachweis der Sicherheit auf klar definierte Regeln basieren. Wenn technische Systeme Ausgaben auf Basis von Eingaben generieren, so müssen diese Ausgaben vorhersehbar sein und mit deterministischen Übergangsregeln erfolgen. Derartige deterministische Systeme werden seit Jahrzehnten in vielen sicherheitsrelevanten Bahnanwendungen – z.B. als elektrische, elektronische, programmierbare elektronische Systeme (E/E/PE-System) – eingesetzt.

Während einer Risikoanalyse wird ein solches System als Black-Box behandelt. Da Systeme mit deterministischem Verhalten nach festen Regeln und Algorithmen funktionieren und daher vorhersehbare und konsistente Ausgaben – ohne Zufallseinflüsse – liefern, können sie nach den in Kapitel 3 erläuterten Sicherheitsnachweismethoden zugelassen werden.

Nach (Braband und Schäbe, 2022) gibt es für KI-basierte Systeme in sicherheitsrelevanten Bahnanwendungen bisher keine veröffentlichte vollständige Sicherheitsnachweismethode. [5] Es gibt viele Forschungsprojekte zu Sicherheitsbegründungen für KI, wie z.B. die Norm UL 4600, die einen Sicherheitsansatz für autonome Fahrzeuge fordert, die KI-Algorithmen nutzen können. [6]

Im Vergleich zu Systemen mit deterministischem Verhalten zeichnen sich KI-basierte Systeme dadurch aus, dass sie Ausgaben auf Basis von Wahrscheinlichkeiten und Zufallsvariablen erzeugen. Dadurch ist es möglich, mehr Daten in kurzer Zeit zu verarbeiten und Entscheidungen zu treffen, die nicht auf explizite Regeln basieren (z.B. Mustererkennung und Vorhersage). Anders als bei deterministischen Systemen mit klarer Vorhersage der Ausgaben, können die Ausgaben von KI-basierten Systemen nur mit Wahrscheinlichkeitsverteilungen beschrieben werden.

Bei einer Risikoanalyse ist dieses probabilistische Verhalten insofern problematisch, da die Ausgaben immer mit Unsicherheiten verbunden sind. Wie bereits oben erwähnt, gibt es zwar vereinzelt Forschungsansätze zu Sicherheitsbegründungen für KI, diese sind jedoch noch nicht ausreichend, um KI-basierte sicherheitsrelevante Bahnanwendungen zuzulassen.

Unter der Annahme, dass jedes beliebige System ein Teilsystem eines größeren Gesamtsystems sein kann, müssen diese Teilsysteme in einer geeigneten Beziehung zueinanderstehen und miteinander Informationen austauschen. Ausgehend von diesem Hierarchie-Prinzip der Systeme sind KI-basierte Systeme hauptsächlich Softwareanwendungen, die auf mindestens einer Hardwareplattform laufen. KI-basierte Systeme können auch Teile von einer Softwareanwendung sein, die auch ein deterministisches Verhalten aufweist. Die Zuweisung der Sicherheitsintegritätsstufe (SIL) erfolgt daher für das jeweilige Teilsystem (z.B. KI-Algorithmus, Softwareanwendung und Hardwareplattform) entsprechend der sogenannten Tolerable Functional Failure Rate (TFFR). [5]

5 Neue Wege der Zugortung – aktuelle Referenzsysteme und KI-basierte Ansätze im Vergleich

Für eine sichere Abstandshaltung zwischen den Zügen ist der momentane Ort der jeweiligen Züge notwendig. Im Bahnsystem werden Zugortungssysteme mit unterschiedlichen Wirkprinzipien eingesetzt. Zur Gleisfreimeldung bzw. Belegtmeldung werden heute im Bahnsystem häufig punktförmige Ortungssensoren eingesetzt. Bei punktförmigen Ortungssensoren werden die Züge an diskreten Punkten entlang der Infrastruktur detektiert. Konkrete Ausprägung von punktförmigen Ortungssensoren sind Achszähler und Balisen. Kontinuierliche Zugortungssensoren kommen hauptsächlich auf den Fahrzeugen in Form von Radodometrien vor. Daneben gibt es jüngst Forschungen mit Faseroptischen Sensoren zur kontinuierlichen Zugortung. Ein weiteres aktuell noch nicht zugelassenes aber sehr vielversprechendes System basierend auf Kameras wird ebenfalls vorgestellt. Dieses wurde zur Erstellung der Referenzdaten für die in Kapitel 6.1 präsentierten Ergebnisse verwendet.

Die Funktionsweise dieser Ortungssensoren wird im Folgenden kurz erläutert.

5.1 Achszähler

Achszähler bestimmen den Belegungszustand eines Freimeldeabschnittes über die Zählung der ein- und ausgefahrenen Achsen. Bei einer Differenz von Null wird ein freier Abschnitt angenommen.

Die Zählung der Achsen erfolgt über den Schienenkontakt, ein auf Räder reagierender punktförmiger Detektor im Gleis. Eine Richtungserkennung wird durch Doppelung des Sensors realisiert [7].

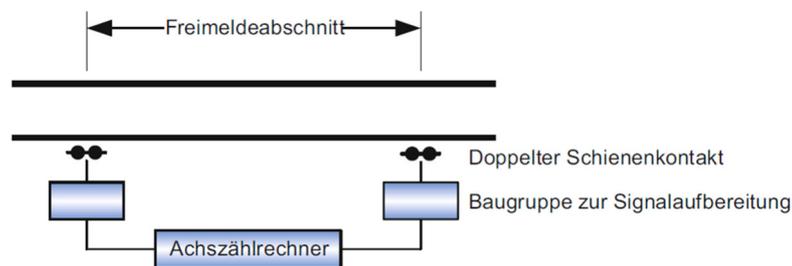


Abb. 2 Aufbau eines Achszählkreises.

Quelle: [7]

Zu falschen Besetztmeldungen kommt es durch Zählfehler, welche typischerweise Mehrfachzählungen, Nichterkennung oder Zählung von nicht vorhandenen Achsen sind. Fehlerhafte Freimeldungen, die zur Gefahr werden können, kommen erst durch das Zusammentreffen mehrerer Fehler in bestimmter Kombination zu Stande. Die Wahrscheinlichkeit dafür ist jedoch so gering, dass es praktisch ausgeschlossen wird. Fehlerhaft besetzt gemeldete Abschnitte müssen manuell auf Freizustand geprüft werden.

5.2 Balise und Odometrie

Mit der Einführung des ETCS-Systems melden Züge, die mit ETCS ausgestattet sind, ihre Position auch zugleich an die ETCS-Zentrale. Die Positionsmeldung erfolgt in bestimmten Zeit- und Wegintervall (vgl. Trinckauf et al. 2020). Die Intervalle sind in den Variablen `D_CYCLOC` und `T_CYCLOC` definiert. Für die Erfassung der Zugposition wird die zurückgelegte Entfernung mit der fahrzeugseitigen Odometrie (meist Wegimpulsgeber und Doppler-Radar oder Wirbelstromsensor) ermittelt. Da die Züge jedoch ihren Fahrweg nur linear kennen, ist zur absoluten Ortung jeweils Referenzpunkte erforderlich. In ETCS

ist die Referenzierung von Positionsinformationen in einem Balisen-Koordinatensystem abgebildet. Die Balise ist ein Transponder zwischen den Schienen einer Eisenbahn, der an einen darüberfahrenden Zug die aktuelle Position sendet (siehe Abb. 4). Balisen sind unregelmäßig im Schienennetz verteilt. In städtischen Gebieten ist die Aktualisierungsrate in der Regel höher als in ländlichen Gebieten. Sämtliche Entfernungs-/Positionsdaten werden einem Bezugspunkt zugeordnet, der über die Position der letzten befahrenen Balisengruppe abgebildet wird (Last Relevant Balise Group – LRBG) (vgl. Trinckauf et al. 2020).. Zwischen jeder Balisengruppe wird der zurückgelegte Weg mittels Odometrie erfasst, welche die Umdrehungen der Räder misst und somit die relative Position bestimmt. [8]



Abb. 3 Balisensystem. Die Zugposition wird bei Überfahrt der Balise an den Zug übertragen
Quelle: [9].

Die Position enthält dabei Messfehler aufgrund von Schlupf und Verringerung des Radumfangs durch Abnutzung. Diese Messfehler werden dann durch Befahren von LRBGs korrigiert. Abb.4 zeigt den Verlauf des Vertrauensintervalls bei einer ETCS-Level 2 Ortung mittels Odometrie.

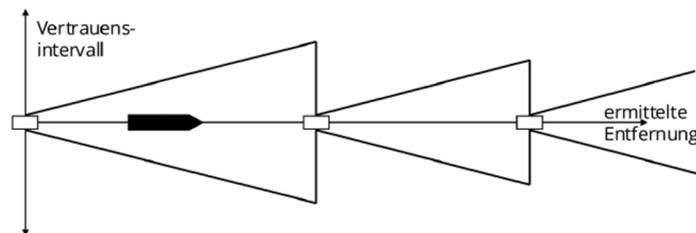


Abb. 4 Verlauf des Vertrauensintervalls zwischen LRBGs bei ETCS Level 2
Quelle: [8]S. 86

5.3 Kamera

Eine auf das Gleis gerichtete Kamera im Zug liefert Bilder die zur Bestimmung der Zugbewegung und zur Identifizierung von Gleisobjekten wie Weichen oder Haltestellenschildern verwendet werden können. Der Prozess zur Bestimmung der Zugbewegung aus der aufgenommenen Bildsequenz wird auch visuelle Odometrie (Visual Odometry VO) genannt. Dies liefert lediglich eine relative Zugposition die durch Akkumulation von systematischen Unsicherheiten zu einer Drift der Position neigt. Dies wird dadurch kompensiert, dass feste Objekte im Gleis wie Weichen, Balisen oder Achszähler detektiert werden und eine absolute Position liefern. (Siehe Abb. 5)



Abb. 5 Auf das Gleis gerichtetes Kamerasystem zur Zuglokalisierung
Quelle: eigene Darstellung – M2C

5.4 Zugortung mit KI-basiertem FOS-System

Für die Erhöhung der Kapazität des existierenden Bahnnetzes ist die sichere Verdichtung der Zugfolge unabdingbar. Die Grundlage für die Verdichtung der Zugfolge ist daher eine kontinuierliche Zugortung. Wie zu Beginn dieses Kapitels erwähnt, gibt es seit einiger Zeit Forschungen mit faseroptischen Sensoren (FOS) zur kontinuierlichen Zugortung.

Zur kontinuierlichen Zugortung mittels FOS werden handelsübliche Glasfaser – wie sie an den meisten deutschen Bahnstrecken bereits zur internen Kommunikation verlegt ist – in eine Kette von akustischen Sensoren verwandelt. Mit einem Lichtimpuls aus einem Sender (Interrogator) werden die rückgestreuten Lichtimpulse (Rayleigh-Rückstreuung) ausgewertet (vgl. Wilhelm et al. 2022). Akustische Schwingungen auf die Glasfaser – zum Beispiel durch vorbeifahrende Züge verursacht – können dabei die gemessene Rückstreuung verändern. Diese Veränderungen in rückgestreuten Lichtpulse werden in Echtzeit erfasst und mit den Methoden der Mustererkennung klassifiziert. Zur Mustererkennung müssen zunächst die in Echtzeit erfassten Lichtimpulse mittels Fourier-Transformation vorverarbeitet. Die Fourier-Transformation wandelt die empfangenen Lichtimpulse in den Frequenzbereich.

Die Ortungsdarstellung ergibt sich dann aus der akustischen Energie im Frequenzbereich durch die dreidimensionale Struktur mit den Dimensionen Zeit, Raum und Frequenzbereich. Zur Zugortung wird dann die 3D-Struktur mit den Algorithmen der maschinellen Bildverarbeitung (zum Beispiel Deep Learning) verarbeitet.[10].

Die Abbildung 6 zeigt die rückgestreuten Lichtimpulse (links) und die akustische Energie im Frequenzband (rechts).

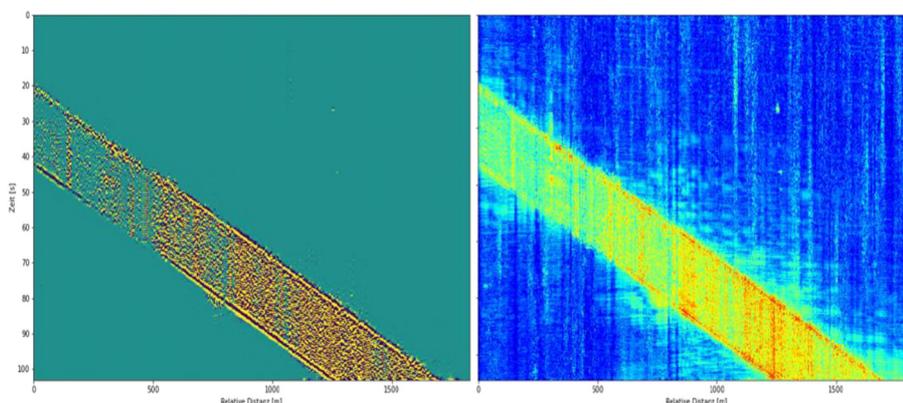


Abb. 6 Rayleigh-Rückstreuung (links) und transformiertes Signal im Frequenzband 20 Hz - 50 Hz (rechts)
Quelle: [10]

6 KI-basierte Zugortung – Testfahrten, Simulationsergebnisse und deren Relevanz für die Zulassung

Wie in Kapitel 5 beschrieben, kann die kontinuierliche Zugortung mithilfe des FOS-Systems gewährleistet werden. Um eine solche Zugortung realisieren zu können, müssen große Datenmengen in kurzer Zeit ausgewertet werden, was den Einsatz von KI erfordert. Aufgrund des Einsatzbereichs des FOS-Systems wurde die KI-Technik Convolutional Neural Network (CNN) verwendet, die sich gut für die Bilderkennung eignet. Im weiteren Text wird daher der Begriff ML-basiertes FOS-System verwendet. In diesem Kapitel werden die Ergebnisse der Testfahrten mit dem ML-basierten FOS-System vorgestellt. Anschließend werden die Möglichkeiten virtueller Testfahrten beschrieben und ein anwendungsfallbasierter Ansatz für die Zulassung des ML-basierten FOS-Systems vorgestellt.

6.1 Ergebnisse aus praktischen Testfahrten am Beispiel Annaberg-Buchholz

Um die Lokalisation von Zügen mittels des in dieser Arbeit vorgestellten ML-basierten FOS-System bewerten zu können wurden am 14 und 15 Juni 2022 Testfahrten auf der Strecke von Schlettau nach Markersbach (Sachsen, Deutschland) durchgeführt. Während dieser Testfahrt wurden Daten in Form von Kamera-Bildern aus dem Zug (siehe **Fehler! Verweisquelle konnte nicht gefunden werden.**) als auch Daten eines FOS-Systems aufgezeichnet.

Auf die Kamera-Bilder wurde ein interner Algorithmus (M2C) zur Bestimmung der Geschwindigkeit sowie zur Detektion von absoluten Referenzpunkten angewandt. Diese Ergebnisse dienen als Referenz für die Auswertung des ML-basierten FOS-Systems.

Fehler! Verweisquelle konnte nicht gefunden werden. links zeigt die geschätzte Geschwindigkeit der beiden Systeme für die erste Testfahrt, wobei das ML-basierte FOS-System (rot) nicht über die komplette Strecke verlegt war. Um eine quantitative Schätzung für den Vergleich zu erhalten, wird ein Anpassungsverfahren mit der Annahme einer konstanten Funktion auf die Differenz zwischen der Referenzgeschwindigkeit (Video) und der Messung (FOS) durchgeführt (**Fehler! Verweisquelle konnte nicht gefunden werden.** rechts). Dabei ergibt sich für diese Testfahrt eine Genauigkeit von -0.3km/h und einer Präzision von 1.2km/h .

Dasselbe Verfahren wurde auf alle Testfahrten im Testzeitraum angewandt und es ergab sich eine Genauigkeit von -0.4km/h und eine Präzision von 1.6km/h .

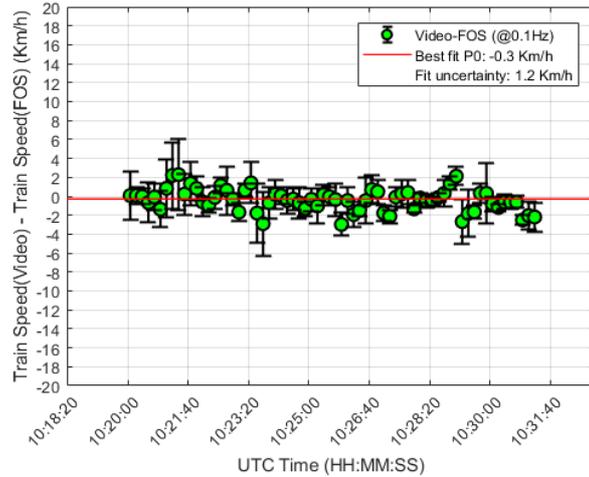
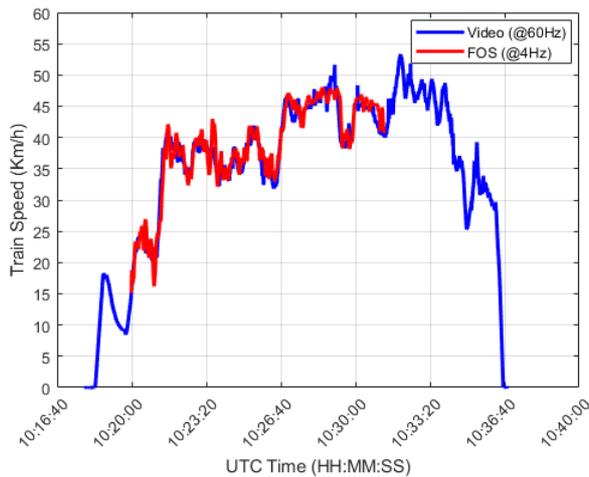


Abb. 7 (Links) Die durch Video (blau) berechnete Geschwindigkeit wird mit der durch FOS (rot) berechneten Geschwindigkeit für eine der Testfahrten von Markersbach nach Schlettau verglichen. Das eingesetzte ML-basierte FOS-System deckte nur einen Teil der gefahrenen Strecke ab, wodurch sich der kürzere Zeitverlauf ergibt. (Rechts) Zeigt die Differenz zwischen Video- und FOS-System, sowie in Rot die berechnete konstante Anpassungsfunktion mit einer Genauigkeit von -0.3 km/h und einer Präzision von 1.2 km/h .

Quelle: eigene Darstellung – M2C

Im niedrigen Geschwindigkeitsbereich von $0\text{--}6\text{ km/h}$, dargestellt in **Fehler! Verweisquelle konnte nicht gefunden werden.**, zeigt sich, dass das ML-basierte FOS-System hier seine Schwierigkeiten hat. Beim Anfahren (linkes Bild) kann eine bislang noch unerklärliche Verzögerung der Messung beobachtet werden. Bei konstanter niedriger Geschwindigkeit (rechtes Bild) ist eine starke Varianz zu beobachten, die auf ein geringes Rohsignal zurückzuführen ist.

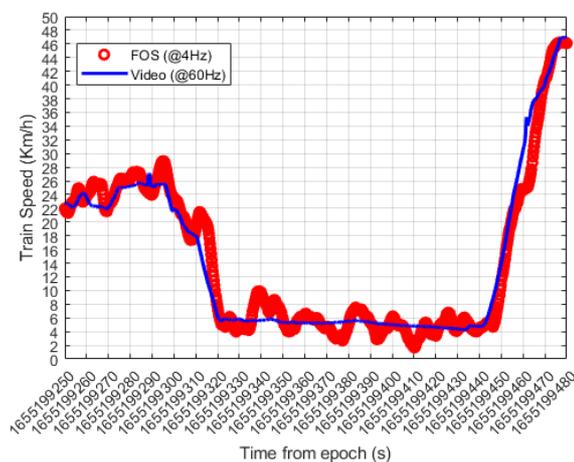
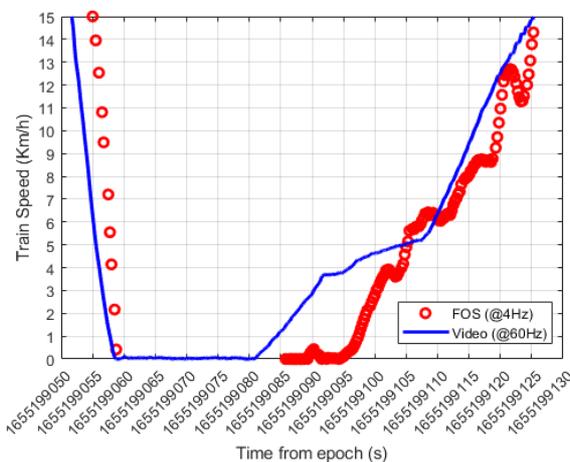


Abb. 8 (Links) Die Zuggeschwindigkeit wird zwischen Video (blaue Linie) und FOS (rote Kreise) im sehr niedrigen Geschwindigkeitsbereich $[0\text{--}4]\text{ km/h}$ verglichen. Es wird eine Verzögerung von 12 Sekunden bei der steigenden Flanke der Zuggeschwindigkeit beobachtet. (Rechts) Vergleich der Zuggeschwindigkeit zwischen Video (blaue Linie) und FOS (rote Kreise) im niedrigen Geschwindigkeitsbereich $[4\text{--}6]\text{ km/h}$.

Quelle: Eigendarstellung – M2C

Entlang der Messstrecke konnten über die Kameradaten Referenzpunkte detektiert werden, deren Position bekannt ist. Das Kamerasystem lieferte den dazugehörigen Referenzzeitpunkt bei Überfahrt. Die Ergebnisse der Auswertung sind in **Fehler! Verweisquelle konnte nicht gefunden werden.** dargestellt. Das linke Bild zeigt ein Histogramm der Positionsdivergenz bei Auswertung vom ML-

basierten FOS-System zu den Referenzzeitpunkten und es ergibt sich ein mittlerer Fehler von 2.9m mit einer Standardabweichung von 1.1m.

Zusätzlich wurde die Zeitdifferenz bei Auswertung der Referenzposition bestimmt (rechtes Bild) und es ergab sich ein mittlerer Fehler von -0.1s mit einer Standardabweichung von 0.4s.

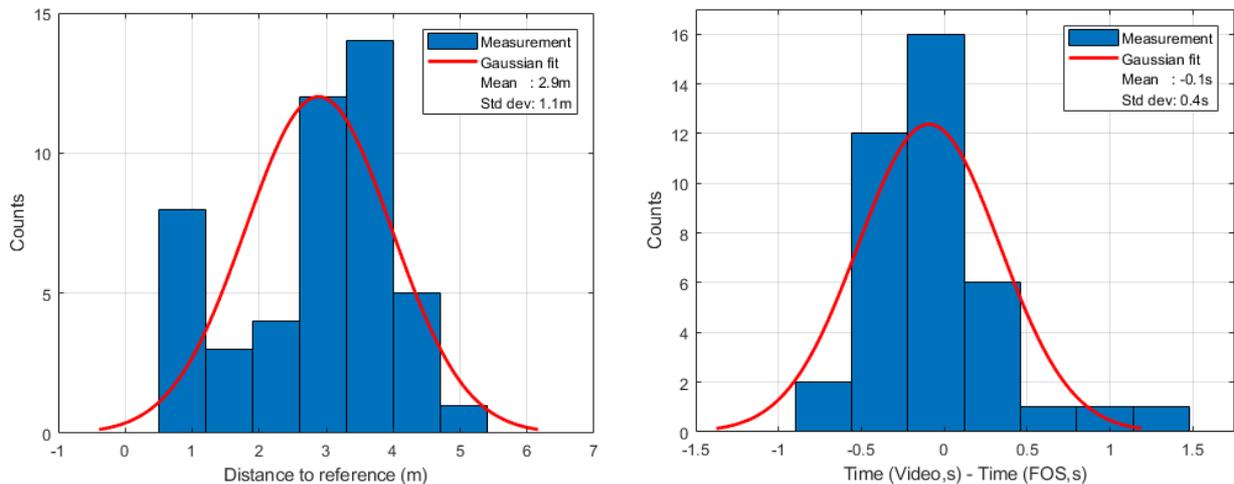


Abb. 9 (Links) Histogramm der von FOS gemessenen Entfernung zum Referenzpunkt. Die in Rot dargestellte Gaußsche Kurvenanpassung der Verteilung ergibt einen Mittelwert von 2,9 m mit einer Standardabweichung von 1,1 m. (Rechts) Histogramm der Zeitdifferenz zwischen FOS und Video beim Passieren der Referenzpunkte. Die in Rot dargestellte Gaußsche Kurvenanpassung der Verteilung ergibt einen Mittelwert von -0,1 s mit einer Standardabweichung von 0,4 s.

Quelle: eigene Darstellung – M2C

6.2 Virtuelle Testfahrten

Um die Erfüllung der Anforderungen an das System überprüfen zu können werden statistisch relevante Ergebnisse benötigt die speziell im Bahnbereich Schwierigkeiten mit sich ziehen, da Testfahrten mit einem enormen organisatorischen Aufwand verbunden sind. Hier bietet sich die Verwendung von Simulationsumgebungen an [11]. Für beliebige Strecken und Zugkompositionen kann in der Simulation eine virtuelle Referenzfahrt generiert werden, welche als Input für detaillierte Sensormodelle dient. Bereits vorhandene Messfahrten werden verwendet um diese Sensormodelle zu entwickeln und diese sind somit in der Lage realitätsnahe Ausgangswerte zu liefern. Damit lassen sich neue Sensortechnologien, Sensorkombinationen oder Fusionsalgorithmen völlig flexibel und jederzeit testen und evaluieren. Zusätzlich besteht die Möglichkeit beliebige Störeinflüsse einzustreuen. Für sicherheitskritische Anwendungen könnten diese Simulationsergebnisse somit als essentieller Baustein für die vorgeschriebenen Nachweise dienen.



Abb. 10 Für beliebige Strecken und Zugkompositionen werden virtuelle Referenzfahrten generiert, die als Eingang für detaillierte Sensormodelle dienen. Simulationsergebnisse können als essentieller Bestandteil zum Nachweis der funktionalen Sicherheit dienen[11].

Quelle: eigene Darstellung – M2C

6.3 Ein use-case basierter Lösungsvorschlag zur Zulassung des ML-basierten FOS Systems

Wie in Kapitel 4 dargelegt, sind die auf maschinellem Lernen basierenden Entscheidungen mit Wahrscheinlichkeiten verknüpft, was dazu führt, dass Systeme, die solche Modelle enthalten, gemäß den bestehenden Normen nicht zugelassen werden können. Die DIN-Norm 50128 verbietet den Einsatz von Künstlicher Intelligenz nicht, bezeichnet die entsprechenden Inhalte jedoch als „informativ“. Sie erläutert lediglich kurz, wofür KI eingesetzt werden könnte, ohne dabei konkrete Anforderungen an diese Systeme in sicherheitskritischen Anwendungen im Bahnbereich zu formulieren.

Es gibt verschiedene Ansätze, um zuverlässige KI-basierte Systeme zu entwickeln. Eine umfassende Untersuchung wurde in [13] durchgeführt, in der eine Systematische Literaturübersicht erstellt wurde. Diese Übersicht umfasst 5090 begutachtete Referenzen, die sich mit der Sicherheit im Zusammenhang mit KI befassen. Besonderes Augenmerk wurde auf einen Teilbestand von 329 Referenzen gelegt, die speziell die Zuverlässigkeit von KI-basierten Systemen behandeln. Aus dieser Analyse wurden fünf wesentliche Ansätze identifiziert:

- i. Durchführung umfangreicher **Black-Box-Tests** von KI;
- ii. Nutzung von **Sicherheitsgrenzen**, um die Reaktion der KI auf einen sicheren Bildersatz zu begrenzen – **Safety Envelope**;
- iii. Entwicklung von **Fail-Safe** KI-Systemen;
- iv. Kombination von **erklärbarer KI** mit **White-Box-Analysen**, um ein tiefes Verständnis der zugrundeliegenden KI-Modelle zu ermöglichen;
- v. Konzeption von **systemischen Methoden und Prozessen auf Systemebene**, um die Zuverlässigkeit von KI zu systematisieren.

Das **Black-Box-Testen** ist eine Methode, die es ermöglicht, Testfälle in simulierten oder realen Szenarien zu erstellen, um die unterschiedlichen Verhaltensweisen von KI-basierten Systemen zu erfassen. Aufgrund ihrer komplexen Natur wird KI dabei als Black Box betrachtet. Eine Herausforderung dieser Methode besteht jedoch darin, die Testvollständigkeit zu gewährleisten. Es ist nicht möglich, sicherzustellen, dass alle möglichen Szenarien abgedeckt werden. Beispielsweise könnten im realen Betrieb Zugfahrten vom ML-basierten FOS-System erfasst werden, die im Trainingsprozess nicht berücksichtigt wurden. Zur Lösung dieses Problems ist die Definition eines klaren Anwendungsbereichs erforderlich.

Ein weiterer möglicher Ansatz ist die Nutzung von **Sicherheitsgrenzen (Safety Envelope)**. Wenn die festgelegten Anwendungsbereiche überschritten werden, sollte ein Schutz- oder Reaktionsmechanismus aktiviert werden. In diesem Zusammenhang wurde der Einsatz von **Fail-Safe-KI** in Betracht gezogen. Die Implementierung einer Fail-Safe-KI erfordert jedoch die Schaffung formaler Sicherheitsumgebungen für dieselben Anwendungen, was keine einfache Aufgabe ist. Beide dieser Ansätze werden durch entsprechende zusätzliche Prozesse im use-case basierten Lösungsvorschlag zur Zulassung des KI-basierten Systems berücksichtigt.

Es ist wichtig hervorzuheben, dass **erklärbare KI** allein nicht ausreicht, um Sicherheit zu gewährleisten, da dieses Gebiet noch in den Anfängen der Forschung steht. Erklärbare KI zielt darauf ab, KI-Systeme so zu gestalten und zu trainieren, dass ihre Entscheidungen und Funktionsweisen für Menschen verständlich und nachvollziehbar sind. Trotz der Fortschritte in der Erklärbarkeit sind zusätzliche Sicherheitsmaßnahmen und weitere Forschungsanstrengungen erforderlich, um die Zuverlässigkeit und Sicherheit von KI-Systemen sicherzustellen. Insbesondere im Kontext des ML-basierten FOS-Systems, das auf komplexen CNN basiert, ist es schwierig zu verstehen, warum das ML-Modell bestimmte Entscheidungen trifft.

Unter Berücksichtigung der beschriebenen Ansätze wurde in diesem Paper der unter Punkt v. genannte Ansatz auf den use-case "Zuglokalisierung" angepasst und ein entsprechender Lösungsvorschlag erarbeitet. Dieser Lösungsvorschlag sollte nicht als Ersatz für die bestehenden CENELEC-Normen verstanden werden, sondern vielmehr als wertvolle Ergänzung dazu. Der Lösungsvorschlag basiert auf vier Schritten, die in Abb. 11 dargestellt sind.

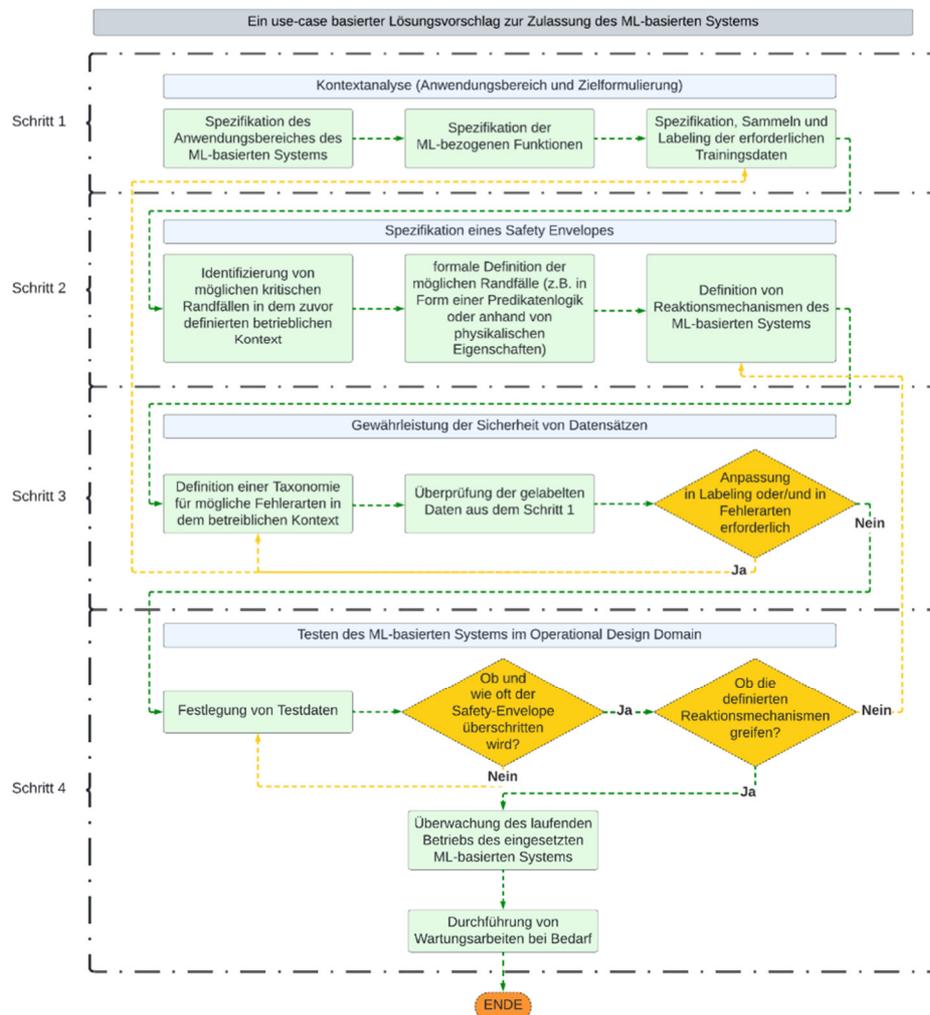


Abb. 11 Use-case basierter Lösungsvorschlag zur Zulassung des ML-basierten FOS-Systems

Quelle: eigene Darstellung – TU Darmstadt

Im ersten Schritt der Kontextanalyse wird der Anwendungsbereich für das ML-basierte FOS System definiert. Ein Beispiel hierfür ist die „Zugortung auf einer ein- oder zweigleisigen freien Strecke“ mit einer festgelegten Länge des zu überwachenden Abschnitts. In diesem Rahmen wird die Funktion des ML-basierten Systems spezifiziert, wie beispielsweise die Ableitung der Position von Zugspitze und Zugende basierend auf der Glasfaserlänge. Anhand der spezifizierten Funktionen werden die notwendigen Trainingsdaten festgelegt, gesammelt und annotiert. Dazu werden Aufzeichnungen von Zugfahrten auf den definierten Strecken mit verschiedenen Geschwindigkeiten genutzt. Die daraus abgeleiteten Muster werden in Abhängigkeit von der Geschwindigkeit markiert.

Im Anschluss an die Kontextanalyse wird im zweiten Schritt ein Safety Envelope spezifiziert. Unter Berücksichtigung von zuvor definierten Anwendungsbereich für das ML-basierte FOS-System werden die kritischen Randfälle identifiziert. Hierbei werden die Grenzen für den annotierten Datensatz gesetzt,

wie z. B. kein Zug auf dem festgelegten Anwendungsbereich kann schneller als 230 km/h oder langsamer als 5 km/h sein oder/und kein Zug kann länger als 750 m oder kürzer als 10 m sein. Hierbei erfolgt die formale Definition der möglichen Randbedingungen, die als Input für das ML-basierte FOS-System gelten. Der Output umfasst die Ergebnisse binärer Klassifikation wie False Positive, False Negative, True Positive und True Negative. In diesem Kontext erfolgt die Definition der Reaktionsmechanismen, die beschreiben, wie das ML-basierte FOS-System reagiert, wenn eine Überschreitung des Safety Envelopes auftritt, wie z. B. ein Güterzug mit einer Länge von 1000 m wurde detektiert – erfolgt die „Warnung“ (gelber Bereich) oder ein Güterzug mit einer Länge von 7 m wurde erfasst – erfolgt „Fail-Safe“ (roter Bereich). Bei „Warnung“ handelt es sich um die Ereignisse, die betriebliche Auswirkungen - wie z. B. der Gleisabschnitt unnötig länger als tatsächlich belegt gemeldet, während beim „Fail-Safe“ eine Gefährdung entsteht, die unter Umständen zu unerwünschtem Ereignis führen kann. Im Konkreten Beispiel, wenn die kürzere als tatsächliche Zuglänge ermittelt wurde, führt es dazu, dass der vom Zug belegte Streckenabschnitt als frei gemeldet wird. Da dadurch der sichere Bahnbetrieb gefährdet wird, muss die entsprechende Fail-Safe-Reaktion eingeleitet werden (siehe Abb. 12).

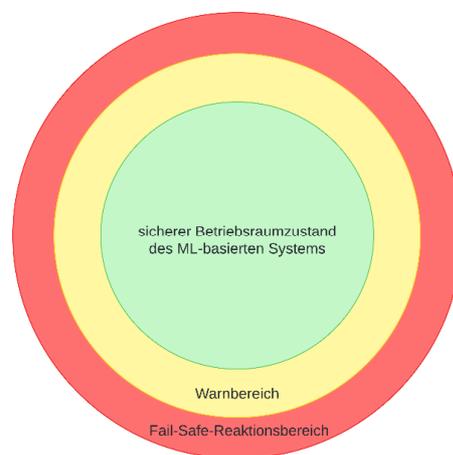


Abb. 12 Sicherheitsreaktion
Quelle: eigene Darstellung – TU Darmstadt

Im dritten Schritt müssen sichere Datensätze gewährleistet werden. Dazu wird eine Taxonomie definiert, die aufzeigt, welche Fehlerarten im ML-basierten System im festgelegten Anwendungsbereich auftreten können und ob sie nach bestimmten Kriterien klassifiziert, das heißt in Kategorien oder Klassen eingeordnet werden können. Ein unausgewogener Datensatz kann dazu führen, dass bestimmte Daten, wie zum Beispiel ein Zug mit einer Länge von 100 Metern und einer Geschwindigkeit von 80 km/h, überproportional häufig verwendet werden. Fehler in Datensätzen werden anhand von Randfällen und dem Anwendungsbereich definiert. Um die annotierten Daten überprüfen zu können, ist eine Bewertung des ML-basierten FOS-Systems erforderlich, bei der die geschätzte Zugposition in der Glasfaser berücksichtigt wird. Dabei werden sicherheitsrelevante Vorhersagen (False Negative, No Prediction Positive oder No Prediction Negative) einbezogen. Da jede dieser Vorhersagen potenziell zu einer Gefährdung führen kann, sind sie in einer logischen ODER-Verknüpfung in Abbildung 13 dargestellt.

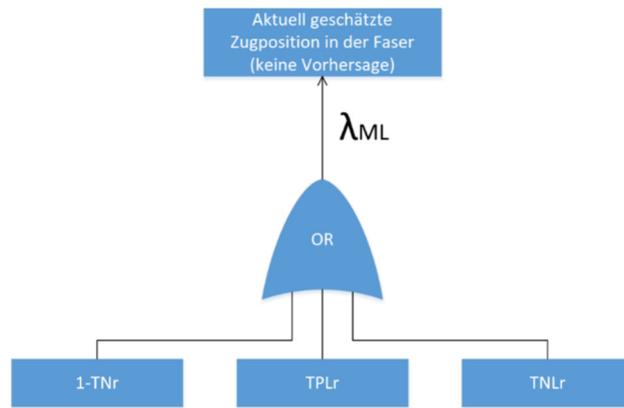


Abb. 13 Taxonomie für Fehlerarten
Quelle: eigene Darstellung – TU Darmstadt

Die Ausfallrate des ML-basierten FOS-Systems kann anhand der Abbildung 13 folgenderweise abgeleitet werden:

$$\lambda_{ML} = (1 - TN_r + TPL_r + TNL_r) - ((1 - TN_r) * TPL_r + (1 - TN_r) * TNL_r + TPL_r * TNL_r) + ((1 - TN_r) * TPL_r * TNL_r)$$

Die in der Formel enthaltenen Variablen sind folgenderweise definiert:

- TN_r ist der Prozentsatz der tatsächlichen Negativwerte, die garantiert korrekt sind, im Verhältnis zur Gesamtanzahl der realen Negativwerte;
- TPL_r (Verlustrate) ist der Prozentsatz der "Keinen Positiven-Vorhersagen", im Verhältnis zur Gesamtanzahl der realen Positiven;
- TNL_r (Verlustrate) ist der Prozentsatz der "Keinen Negativen-Vorhersagen" im Verhältnis zur Gesamtanzahl der realen Negativwerte.

Bei der Überprüfung von annotierten Daten wird auf die folgenden drei Aspekte geachtet:

- **Vollständigkeit** – ob sämtliche von den definierten potenziellen Fehlerarten im annotierten Trainingsatz vorhanden sind;
- **Unstimmigkeit** - ob in den annotierten Trainingsdaten neue Fehlerarten existieren, die nicht berücksichtigt wurden und
- **Plausibilität** – ob die annotierten Daten realistischen und erwartbaren Mustern entsprechen.

Falls Anpassungen in Annotation oder in den Fehlerarten erforderlich sind, erfolgt eine Anpassung entweder in Annotation innerhalb der Kontextanalyse oder in den Fehlerarten der Datensätze. Wenn jedoch keine Anpassungen erforderlich sind, werden die Testdaten festgelegt.

Die Festlegung von Testdaten erfolgt somit im vierten Schritt, in dem das ML-basierte FOS-System im operativen Betrieb getestet wird. An dieser Stelle wird eine statistische Auswertung durchgeführt, um zu prüfen, ob und wie häufig der definierte Safety Envelope überschritten wird (wie oft kommen die Fehlertypen TN_r , TPL_r und TNL_r vor), um die mittlere Dauer zwischen zwei Fehlern des ML-basierten FOS-Systems (MTBF) bestimmen zu können.

Wenn der Safety-Envelope überschritten wird, muss zusätzlich sichergestellt werden, dass die entsprechenden Reaktionsmechanismen aktiviert werden. Greifen die definierten Reaktionsmechanismen wie vorgesehen, wird das ML-basierte FOS-System während des laufenden Betriebs überwacht, und bei Bedarf werden Wartungsarbeiten durchgeführt.

Dieser mehrstufige, anwendungsfallbasierte Lösungsvorschlag umfasst zusätzliche erforderliche Aktivitäten, die gemäß den bestehenden Normen die Zuverlässigkeit des ML-basierten FOS-Systems

nachweisen können. Das ML-basierte FOS-System übernimmt als Teilsystem spezifische Aufgaben, die im gesamten FOS-System für die ausgewählte sicherheitskritische Anwendung eingesetzt werden. Darüber hinaus könnte das FOS-System auch in Anwendungen verwendet werden, die keinen Bezug zur Sicherheit haben. Im nächsten Kapitel wird das Potenzial des FOS-Systems in diesen Anwendungen näher untersucht.

7 KI-basiertes FOS-System in nicht sicherheitskritischen Anwendungen

Wie in Kapitel 2 beschrieben, können durch das ML-basierte FOS-System verschiedene Ereignisse identifiziert werden, die entsprechende Erschütterungen verursachen. Dies bedeutet, dass nicht nur die Bewegungen von Schienenfahrzeugen erfasst werden können, sondern auch die von Personen oder Tieren. Darüber hinaus können Ereignisse wie Kurzschlüsse in der Oberleitung oder Radflachstellen bei Schienenfahrzeugen erkannt sowie Weichen und andere bewegliche Infrastrukturelemente überwacht werden. In diesem Zusammenhang ergeben sich zwei weitere Anwendungsbereiche: smarte Instandhaltung und Schutz kritischer Infrastruktur.

Die Gewährleistung der Sicherheit in der Eisenbahninfrastruktur ist von grundlegender Bedeutung, da mögliche Bedrohungen nicht nur den reibungslosen Betrieb des Zugverkehrs beeinträchtigen, sondern auch potenziell schwerwiegende Folgen für die Gesellschaft insgesamt haben könnten. In diesem Zusammenhang hat der Schutz kritischer Infrastrukturen im Bahnverkehr höchste Priorität erlangt. Dies erfordert nicht nur technologische Innovationen, sondern auch eine sorgfältig ausgearbeitete Sicherheitsstrategie, um Risiken zu minimieren und die Widerstandsfähigkeit dieses essenziellen Systems zu gewährleisten.

Eine Infrastrukturüberwachung mittels ML-basiertem FOS-System ermöglicht eine schnelle Erkennung von Bedrohungen an der kritischen Infrastruktur. Dadurch können Bedrohungen präzise lokalisiert und entsprechend schnell darauf reagiert werden. In Kombination mit technologischen Innovationen und einer durchdachten Sicherheitsstrategie trägt die Anwendung des ML-basierten FOS-Systems dazu bei, die Effizienz der Schutzmaßnahmen zu erhöhen und die Resilienz des Schienenverkehrsnetzes weiter zu stärken.

Bezüglich der von DB InfraGO AG zur Verfügung gestellten Daten wurden im Zeitraum vom 01.08.2020 bis 31.08.2023 bundesweit 276.612 Störungsmeldedaten erfasst. Diese Störungen können unter Umständen zu Verspätungen oder Zugausfällen führen. Eine nicht maßstäbliche Darstellung der Störbestehenszeit ist in der Abbildung 14 veranschaulicht. Die Störbestehenszeit setzt sich aus der Summe der folgenden Zeitanteile zusammen:

- **Fehleroffenbahrungszeit** – die Dauer zwischen dem Auftreten einer Störung bis zu dessen Erkennung
- **Meldezeitverzögerung** – diese entsteht beim Melden von Störung durch Fahrdienstleiter der zur Entstörung verantwortlichen zuständigen Stelle (EVZS)
- **Verständigungszeit** – nachdem die EVZS über die Störung informiert wurde, beginnt die Verständigungszeit, die von der Erreichbarkeit der Entstörer abhängig ist;
- **Arbeitsbeginnverzögerung** – diese entsteht durch die Wege- und Wartezeit des Entstörers;
- **Entsörzeit** – Arbeitsbeginn vor Ort bis zur betrieblichen Freigabe – Endet mit dem Austrag der Störung oder dem Eintrag betrieblichen Folgemaßnahmen;

Abschließend wurde ein anwendungsfallbasierter Lösungsvorschlag für die Zulassung des ML-basierten FOS-Systems sowie dessen Potenzial für eine schnelle Inbetriebnahme in nicht sicherheitskritischen Anwendungen vorgestellt. Eine zeitnahe Anwendung des ML-basierten FOS-Systems kann zur schnellen Erkennung und Lokalisierung von Kabeldiebstählen beitragen.

Für die generische Zulassung des ML-basierten FOS-Systems in sicherheitskritischen Bahnanwendungen sind im Rahmen der weiteren Forschung zusätzliche Lösungsvorschläge erforderlich. Darüber hinaus sollte die Forschung Wege zur Zulassung entsprechender KI-Techniken in sicherheitskritischen Bahnanwendungen in Betracht ziehen.

Literaturverzeichnis:

- [1] <https://www.apsensing.com/technology/> (abgerufen am 27.06.2024)
 - [2] DIN/VDE Norm, „DIN EN 50126-1:2018-10 - Spezifikation und Nachweis von Zuverlässigkeit, Verfügbarkeit, Instandhaltbarkeit und Sicherheit (RAMS) - Teil 1: Generischer RAMS Prozess,“ 2018.
 - [3] DIN/VDE Norm, DIN EN 50126-2:2018-10 - Spezifikation und Nachweis von Zuverlässigkeit, Verfügbarkeit, Instandhaltbarkeit und Sicherheit (RAMS) - Teil 2: Systembezogene Sicherheitsmethodik, 2018.
 - [4] DIN/VDE Norm, DIN EN 50716:2023 Bahnanwendungen - Anforderungen für die Softwareentwicklung, 2023.
 - [5] Schäbe, H. und Braband, J.: Anwendung Künstlicher Intelligenz in der Bahntechnik für sicherheitsrelevante Anwendungen – Chancen und Probleme, SIGNALLING + DATACOMMUNICATION (114) 5 / 2022
 - [6] UL 4600: Standard for Safety for the Evaluation of Autonomous Products, April 2020
 - [7] U. Maschek, Sicherung des Schienenverkehrs, Springer Vieweg, 2022.
 - [8] Trinckauf, J. et al.: „ETCS in Deutschland, Dresden, Juni 2020.
 - [9] Rail System Net, „Rail System Net,“ 2015. [Online]. Available: <https://railsystem.net/balise/>.
 - [10] Wilhelm, R.; Luong, H. und Drapp, B.: Faseroptische Sensorik zur sicheren Zugortung: Fortschritte und Herausforderungen, Scientific Railway Signalling Symposium, Darmstadt 2022
 - [11] M2C ExpertControl GmbH, „Innovative Sensorsysteme Und Algorithmen,“ Trend Mobility No1 - Cooperative Intelligent Transport Systems, April 2021.
 - [12] VDE, DIN VDE V 0831-103:2020-09 Elektrische Bahn-Signalanlagen, 2020.
 - [13] Silva Neto, A.; Camargo JR., J.; Almeida JR., J. and Cugnasca, P.: Safety Assurance of Artificial Intelligence-Based Systems: A Systematic Literature Review on the State of the Art and Guidelines for Future Work, São Paulo 05508-010, Brazil, December 2022,
-