

Zeitschrift: bulletin.ch / Electrosuisse
Herausgeber: Electrosuisse
Band: 110 (2019)
Heft: 9

Artikel: Künstliche Intelligenz auf Schienen = L'intelligence artificielle sur la bonne voie
Autor: Schmid, Philipp / Casutt, Joël / Zurkirchen, Marcel
DOI: <https://doi.org/10.5169/seals-855980>

Nutzungsbedingungen

Die ETH-Bibliothek ist die Anbieterin der digitalisierten Zeitschriften auf E-Periodica. Sie besitzt keine Urheberrechte an den Zeitschriften und ist nicht verantwortlich für deren Inhalte. Die Rechte liegen in der Regel bei den Herausgebern beziehungsweise den externen Rechteinhabern. Das Veröffentlichen von Bildern in Print- und Online-Publikationen sowie auf Social Media-Kanälen oder Webseiten ist nur mit vorheriger Genehmigung der Rechteinhaber erlaubt. [Mehr erfahren](#)

Conditions d'utilisation


L'ETH Library est le fournisseur des revues numérisées. Elle ne détient aucun droit d'auteur sur les revues et n'est pas responsable de leur contenu. En règle générale, les droits sont détenus par les éditeurs ou les détenteurs de droits externes. La reproduction d'images dans des publications imprimées ou en ligne ainsi que sur des canaux de médias sociaux ou des sites web n'est autorisée qu'avec l'accord préalable des détenteurs des droits. [En savoir plus](#)

Terms of use

The ETH Library is the provider of the digitised journals. It does not own any copyrights to the journals and is not responsible for their content. The rights usually lie with the publishers or the external rights holders. Publishing images in print and online publications, as well as on social media channels or websites, is only permitted with the prior consent of the rights holders. [Find out more](#)

Download PDF: 18.04.2026

ETH-Bibliothek Zürich, E-Periodica, <https://www.e-periodica.ch>



Künstliche Intelligenz auf Schienen

Deep Learning sorgt für Sicherheit | Um die Funktionsfähigkeit ihrer Infrastruktur sowie die Sicherheit der Fahrgäste und des Personals sicherzustellen, setzen die Schweizerischen Bundesbahnen (SBB) unter anderem spezielle Diagnosezüge ein. Mehrere Kameras auf diesen Zügen nehmen Bilder der Gleise auf. Um die Bilder optimal auswerten zu können, setzen die SBB auf künstliche Intelligenz und arbeiten eng mit dem CSEM zusammen.

PHILIPP SCHMID, JOËL CASUTT, MARCEL ZURKIRCHEN

Das Rückgrat der Eisenbahn sind die Schienen. Sie liegen jahrzehntelang im Gleisbett und werden jeden Tag arg strapaziert: nicht nur von Personenzügen in unterschiedlichen Grössen und mit unterschiedlichen Geschwindigkeiten, sondern auch von tonnenschweren Güterzügen. Die Division Infrastruktur der SBB betreibt in der Schweiz ein Streckennetz von rund 3000 km Länge mit teils mehrspurigen Gleisen.

Der Aufwand, um die Kunden sicher von A nach B zu bringen, ist enorm. Trotz dieser schwierigen Aufgabe

erreichen die SBB die beste Kundenpünktlichkeit im europäischen Vergleich von über 90%.

Täglich gehen Mitarbeiter der SBB den Gleisen entlang und überprüfen den Fahrweg visuell auf mögliche Abweichungen (Bild 1). Dadurch wird unter anderem der Zustand der Gleise überprüft und Defekte frühzeitig erkannt. Rund 50 Mitarbeiter sind für das komplette Schienennetz verantwortlich und inspizieren die Fahrweginfrastruktur auf über 250 mögliche Fehlerarten. Zusammen ergibt dies pro Jahr etwa 23000 bestätigte Auffälligkeiten, von

denen die meisten unkritisch sind. Diese werden anhand ihres Schweregrades klassifiziert, und entsprechende Massnahmen werden eingeleitet.

Für eine effiziente Beurteilung nutzen die Streckeninspektoren idealerweise Tageslicht. Da die Züge in einem immer höheren Takt fahren, wird die Inspektion für die Mitarbeiter besonders während der Stosszeiten immer anspruchsvoller. Auf Strecken mit erhöhter Geschwindigkeit, wie der Neubaustrecke sowie dem neuen Gotthardbasistunnel, ist die manuelle Streckeninspektion während dem laufenden Betrieb

nicht gestattet. Ausserdem braucht es sehr grosse Erfahrung, um die Auffälligkeiten korrekt beurteilen zu können. Aus diesen Gründen sowie zur Steigerung der Effizienz setzen die SBB seit einigen Jahren neben den menschlichen Streckeninspektoren spezielle Messzüge ein, sogenannte Diagnosefahrzeuge (DFZ), die vollgepackt mit neuester Kamera- und Messtechnologie sind.

Die Qualität der automatischen Auswertung ist hier noch nicht so weit ausgereift wie die Analyse durch einen menschlichen Experten, und bedarf heute noch der manuellen Nachprüfung der Daten. Wie bringt man nun die Erfahrung der Experten in eine robuste Software?

Diagnosefahrzeug-Typen

Die SBB betreiben aktuell zwei unterschiedliche Diagnosefahrzeuge (**Bild 2**): ein selbstfahrendes (DFZ) und ein gezogenes (gDFZ) mit je bis zu 18 Hochleistungskameras. Mit Geschwindigkeiten von bis zu 200 km/h fahren die Systeme über die Schienen und führen dabei Messungen an Schotterbett, Gleiskonstruktion, Fahrleitungen und Tunnelbauten aus. Alle Daten werden in vollem Tempo gespeichert und können bei Bedarf auch zur Prüfung live im Messzug dargestellt werden (**Bild 3**). So kommen etwa 10 GB Daten pro Kilometer zusammen. Diese Datenmenge entspricht etwa 5 Millionen Buchseiten Text – für jeden Kilometer. Die Speicherung und Verarbeitung solcher gewaltigen Datenmengen fällt unter «Big Data».

Daten

Bisher wurden diese Datenmengen mit klassischen Ansätzen ausgewertet. Diese liefern jedoch zu viele falsche




Bild 1 Die Erhöhung des Taktes der Züge erschwert die Arbeit der Gleisinspektoren zunehmend.

Befunde. Eine Herausforderung gegenüber der Qualitätskontrolle in der industriellen Produktion liegt in der enormen Variation. Die Schienen liegen in der freien Natur und sind damit allen Umwelteinflüssen ausgesetzt:

- Wetter: Regen, Schnee, Matsch, Vereisung
- Umgebung: Tunnel, Bahnhof, Stadt, Wald, Brücke
- Artefakte: Dreck, Tierkot, Pflanzen, weggeworfene Kaugummis oder Zigarettenstummel
- Typen: unterschiedliche Gleisgeometrien, Weichen, Profil.

Die Entwicklung eines klassischen Algorithmus zur Auswertung all dieser Variationen ist praktisch unmöglich. Solche Algorithmen können zwar leicht verstanden werden und sind sehr leistungsfähig im Umgang mit numerischen Daten. Jedoch gibt es im Fall von Defekten auf der Schienenoberfläche keine klaren numerischen Beschrei-

bungen, denn Form, Textur oder Schattierung der Defekte sind jedes Mal unterschiedlich. Ein menschlicher Experte kann damit noch sehr gut umgehen, er braucht kein mathematisches Modell, um einen Defekt zu erkennen. Er hat sich über viele Jahre die notwendige Erfahrung angeeignet, welche ihm hilft, die Klassifizierung sicher vorzunehmen. Genau hier kommt Deep Learning ins Spiel.

Deep Learning

Deep Learning ist eine Domäne der Artificial Intelligence (AI, Künstliche Intelligenz). Es werden grosse (tiefe) neuronale Netzwerke trainiert, die Lernmethoden imitieren dabei die Funktionsweise des menschlichen Gehirns. Deep Learning ermöglicht, das Wissen und die Erfahrung eines Experten in Software zu übertragen. Das erfordert grosse Mengen (100 bis 10 000 Bilder) von gekennzeichneten



Bild 2 a) Selbstfahrendes und b) gezogenes Diagnosefahrzeug.




Bild 3 Im Innern eines Diagnosefahrzeugs.

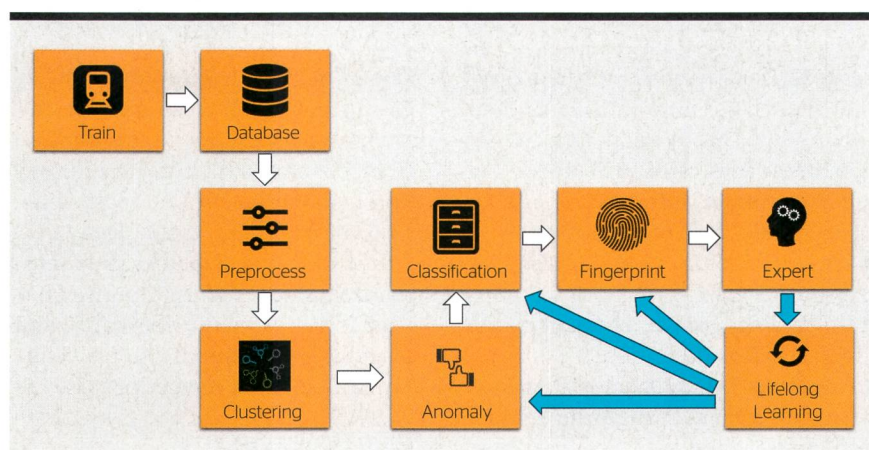


Bild 4 Schematische Darstellung der Datenverarbeitung.

Daten – das heisst von Experten beurteilte und markierte Bilder. Der grosse Vorteil ist, dass der Algorithmus selbst identifiziert, welches die wichtigen Merkmale sind und so das beste mathematische Modell automatisch festlegt: Der Algorithmus baut sich seine eigene Erfahrung auf.

Hierfür hat das CSEM, ein schweizerisches Forschungs- und Entwicklungs-Zentrum, für die SBB eine neue Software entwickelt, welche bezüglich der hohen Qualitätsanforderungen richtungsweisend ist. Diese besteht aus mehreren Modulen (**Bild 4**):

- Vorverarbeitung und Clustering
- Detektion von Auffälligkeiten
- Klassifikation
- Fingerprinting
- Kontinuierliche Verbesserungen durch Einbinden von Experten (Lifelong Learning)

Eine der grössten Herausforderungen besteht darin, dass nur relativ wenige

Trainingsdaten zur Verfügung stehen und es bei bestimmten Fehlerkategorien selbst für Experten sehr schwierig ist, eine eindeutige Klassifizierung vornehmen zu können. Um das Wissen und die Erfahrung der SBB-Experten möglichst einfach abbilden zu können, wurden spezielle Werkzeuge entwickelt. Diese erlaubten es in kurzer Zeit, die Datenbasis zu verzehnfachen und die Einschätzungen der Experten untereinander abzugleichen. Alle Grenzfälle wurden im Team besprochen und erst danach bewertet. Dieser wichtige Schritt zeigt, dass es auch bei der Anwendung neuester Technologien den Menschen als letzte Instanz braucht.

Vorverarbeitung und Clustering

Alle Messdaten werden vom Zug auf eine zentrale Datenbank der SBB übertragen und in ein spezifisches SBB-Dateiformat konvertiert. Die SBB können so verschiedene, von der Quelle unab-

hängige Daten parallel darstellen. So können neben den Daten von den Diagnosefahrzeugen auch Daten von Drohnen, Fotos von Experten oder Messdaten aus dem Labor miteinander kombiniert und weitere Datenkorrelationen ermöglicht werden. Liegen die Bilddaten auf dem Server, werden sie in einem ersten Schritt durch verschiedene Filter vorverarbeitet, normalisiert und in einzelne Klassen aufgeteilt (Clustering).

Detektion von Auffälligkeiten

In einem nächsten Schritt wird nach Auffälligkeiten (Anomalien) gesucht. Anomalien sind alles, was auch einem nicht geschulten Menschen auf einer Schiene beim Betrachten auffallen würde – Dreck, Blätter, Kaugummi, Defekte, Schweissnähte usw. Um sicherzustellen, dass kein Fehler übersehen wird, tendieren diese Algorithmen dazu, zu viele Auffälligkeiten zu detektieren. Sie können dafür mit einer nahezu unendlichen Variation umgehen und auch unbekannte Fehler zuverlässig erkennen. Um die Anzahl der Alarme tief zu halten, wird der folgende Schritt benötigt.

Klassifikation

Um echte Defekte von unkritischen Fahrbahnzuständen zu unterscheiden, ist eine exakte Klassifikation nötig. In dem Projekt werden sechs verschiedene Klassen unterschieden. Von «keine Gefahr» (Kaugummi, Vogel-dreck) zu den heikelsten Fehlern, den sogenannten Squats (**Bild 5**). Diese Defekte sind an der Oberfläche nur sehr schwer zu erkennen: Analog einem Zahn mit Karies entsteht im Inneren ein Hohlraum, der sich immer tiefer in die Schiene hineinfrisst. Der grosse Unterschied zu klassischen Algorithmen liegt in der Klassifizierung von Objekttypen mit hoher intrinsischer Varianz. Für gute Resultate wurde über Monate sehr eng mit den Experten der SBB zusammengearbeitet. Erst dank ihrem Wissen konnte ein neuronales Netzwerk für die Klassifizierung erfolgreich trainiert werden.

Fingerprinting

Der Algorithmus kann bereits sehr zuverlässig Schäden von Artefakten auf den Gleisen unterscheiden und klassifizieren. Das Gleisnetz ist sicherheitsrelevant und unterliegt strikten Vorschriften. Deshalb können sich die SBB




Bild 5 Fehlerklassen.




Bild 6 Zeitlicher Verlauf eines mit Fingerprinting gefundenen Fehlers.

nicht ausschliesslich auf einen Algorithmus verlassen. Die finale Entscheidung, ob und wann ein Defekt vor Ort geprüft und repariert werden soll, bleibt bei den Streckeninspektoren.

Je nach Streckenabschnitt kommen die Diagnosefahrzeuge alle 14 Tage zum Einsatz. Hierbei werden immer wieder die gleichen Auffälligkeiten gefunden – die dann erneut durch einen Experten bewertet werden müssten und Zusatzaufwand generieren. Viele Auffälligkeiten entwickeln sich nur sehr langsam über die Zeit zu Defekten, so dass von der Entdeckung bis hin zur Reparatur, bei Defekten mit geringer Kritikalität, bis zu sechs Monate vergehen können. Während dieser Zeit ist der Defekt bereits im Instandhaltungssystem registriert und sollte, bis zur gebündelten Behebung «optimierte Instandhaltung» mit anderen Defekten, nicht immer wieder als neuer Fehler bei der Auswertung auftauchen. Dazu wurde das Fingerprinting entwickelt. Das Ziel ist die Verfolgung von Defekten über die Zeit. Erkennt die AI einen Defekt, wird ein Fingerabdruck berechnet, der den Defekt eindeutig kennzeichnet. Fahren die Diagnosefahrzeuge später wieder über diesen Fehler, kann anhand des Fingerabdrucks der Defekt einem bereits bekannten Defekt eindeutig zugeordnet werden. Dadurch ergibt

sich für jeden Defekt ein zeitlicher Verlauf – die Historie des Defektes (Bild 6). Die Zuordnung funktioniert zudem ohne hochgenaue Lokalisierung des Fahrzeugs auf der Schiene (GPS funktioniert nicht im Tunnel) sowie bei lokal ändernden Umgebungsmerkmalen.

Besonders durch temperaturbedingte Ausdehnungen können sich das Gleisbett und die relative Position eines Fehlers zu dem umliegenden Gestein oder den Gleisklammern verändern (Bild 7). Dies wird durch Deep-Learning-Techniken ermöglicht.



Bild 7 Ob durch Erdbeben oder Ausdehnung unter Wärmeeinfluss, Schienen können manchmal spektakuläre Verformungen erfahren.




Bild 8 Diagnosefahrzeuge ermöglichen eine grosse Anzahl unterschiedlicher Messungen.

Life-Long Learning

Der Mensch lernt durch seine Sinne jeden Tag etwas Neues hinzu und erweitert damit kontinuierlich seinen Wissensschatz. Das gleiche Verhalten wünschen wir uns von künstlicher Intelligenz. Der Experte wird daher auch in Zukunft gebraucht: Er fungiert als Lehrer in dem kontinuierlichen Prozess, um die Sicherheit und Zuverlässigkeit auf der Schiene zu gewährleisten. Nur dank seiner Erfahrung kann die Software stetig dazulernen und auf neu auftretende Defekte reagieren. Es entsteht eine regelrechte Symbiose zwischen Mensch und Maschine. Die AI kann nicht nur Wissen aufbauen, sondern auch transferieren. So werden die entwickelten neuronalen Netzwerke bereits heute bei den SBB für die Ausbildung der jungen Streckeninspektoren verwendet, indem der Computer den Lernenden zeigt, was Defekte sind, und die Grenzfälle aufzeigt, wo sich selbst die Experten nicht ganz einig sind.

Resultate

Das Projekt läuft seit zwei Jahren und ist nun in der entscheidenden Evaluationsphase. Die Verifizierung und statis-

tische Auswertung der Algorithmen ist herausfordernd. Es wurde eine Teststrecke bestimmt, auf welcher durch mehrere Testfahrten mit den Diagnosefahrzeugen umfangreiche Daten aufgenommen wurden. Dieselbe Strecke wurde von mehreren Streckeninspektoren unabhängig beurteilt. Die neue Deep-Learning-Software musste gegen klassische Algorithmen antreten, die seit über zehn Jahren verfeinert werden und weltweit im Einsatz stehen. Die CSEM-Lösung verbessert die Erkennungsrate um den Faktor 10 und reduziert dabei die Fehlalarme (Falsch-Positives) um 50% im freien Gelände und um 95% in Tunnels. Diese ausgezeichneten Resultate wurden ohne Optimierung des neuronalen Netzwerks erreicht. Dies wird nun in der nächsten Phase mit vielen Daten direkt vom Feld nahezu automatisch verfeinert.

Ausblick

Dank den Diagnosefahrzeugen werden die vermessenen Streckenkilometer um ein Mehrfaches innert wenigen Jahren erhöht. Um diese Datenflut meistern zu können, braucht es Software wie die von CSEM. Heute ist die Gleis-

kontrolle traditionell reaktiv. Erst wenn ein Fehler erkannt wird, kann er auch repariert werden. Je nach Schwere des Defekts muss dazu eine Strecke kurzfristig gesperrt werden.

Die Hoffnung ist, dass die Wartung von schadhafte Stellen in Zukunft dank dem automatischen Erkennen und dem Fingerprinting bereits im Voraus geplant und damit das Systemverständnis hinsichtlich den Zusammenhängen der Infrastruktur und der Schadensentwicklung weiter gesteigert werden kann. Das ultimative Ziel wäre es, diese Software in einem Echtzeit-Bordüberwachungssystem in jedem Zug (On-Board Monitoring) zu betreiben.

Autoren

Philipp Schmid ist Head Robotics & Machine Learning am CSEM und entwickelt mit seinem Team moderne Lösungen für die Industrie.
→ CSEM, 6055 Alpnach
→ philipp.schmid@csem.ch

Joël Casutt ist Leiter Technologie und Entwicklung im Bereich Mess- und Diagnosetechnik bei den SBB.
→ SBB, 3018 Bern
→ joel.casutt@sbb.ch

Marcel Zurkirchen ist Leiter Mess- und Diagnosetechnik bei den SBB.
→ marcel.zurkirchen@sbb.ch



Anlagentagung 2019

25. September 2019 | EKZ Dietikon

www.electrosuisse.ch/anlagentagung

Sichern
Sie sich
Ihr Ticket!

Sicherer Umgang mit Netzanlagen – Fit für die Zukunft?

Freuen Sie sich unter anderem auf folgende Referenten:



Patrick Noth
Ingenieur Diagnostik,
BKW Energie AG
Erdungssysteme im Wandel



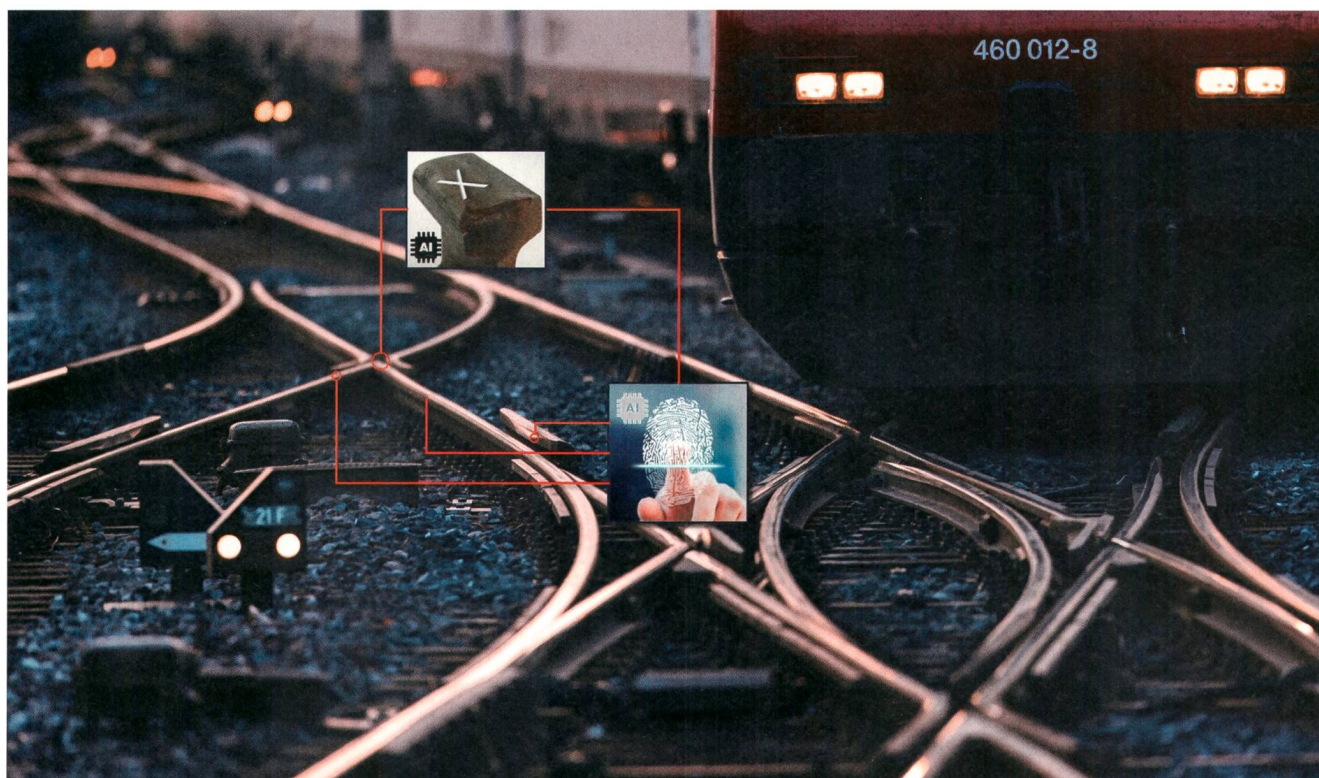
Michael Walter
Manager High Voltage Technology,
GE Grid (Switzerland) GmbH
UHF-Sensoren: Nutzen, Platzierung
und Umgang in der Praxis



Christoph Studer
Projektleiter Netzplanung,
Primeo Netz AG
«Bodenhaftung» von
Mittelspannungsnetzen



Sandro Dinsler
Head of Engineering Lines,
Swissgrid AG
380 kV-Leitung unterirdisch!
Ja. Ein Praxisbericht.



L'intelligence artificielle sur la bonne voie

Le deep learning au service de la sécurité ferroviaire | Les CFF utilisent, entre autres, des trains de diagnostic pour garantir le bon fonctionnement de leurs infrastructures ainsi que la sécurité des usagers et de leurs employés. À bord, des caméras photographient les voies ferrées à la recherche du moindre changement. Afin d'optimiser l'évaluation des images saisies, les CFF recourent à l'intelligence artificielle et travaillent en étroite collaboration avec le CSEM.

PHILIPP SCHMID, JOËL CASUTT, MARCEL ZURKIRCHEN

Les rails représentent l'épine dorsale du chemin de fer. Encastrés pendant des décennies dans le lit des voies, ils sont chaque jour soumis à rude épreuve, et ce, non seulement par un incessant ballet de trains de voyageurs de différentes tailles et circulant à des vitesses variables, mais aussi par des convois de marchandises d'un poids considérable. En Suisse, la division Infrastructure des Chemins de fer fédéraux suisses (CFF) exploite un réseau de 3000 km, composé parfois de lignes à plusieurs voies. L'effort requis pour acheminer les clients en toute

sécurité d'un point A à un point B est énorme. Malgré cette tâche difficile, les CFF affichent une ponctualité record en Europe, avec un taux de plus de 90 %.

Chaque jour, des inspecteurs des voies des CFF parcourent à pied l'infrastructure ferroviaire pour vérifier visuellement son état et rechercher d'éventuelles anomalies (figure 1). En charge de l'intégralité du réseau ferroviaire, ces quelque 50 collaborateurs sont à la recherche d'environ 250 types de défauts. Chaque année, près de 23 000 anomalies, souvent encore complètement inoffensives, sont confir-

mées. Celles-ci sont classées en fonction de leur gravité et des mesures appropriées sont mises en œuvre.

Pour se révéler efficaces, les inspecteurs des voies doivent disposer d'une grande expérience et, idéalement, pouvoir bénéficier de la lumière du jour. Les trains circulant à une cadence de plus en plus élevée, leur travail devient toujours plus difficile, en particulier aux heures de pointe; et ce, à tel point que ce contrôle manuel n'est plus autorisé par la loi sur les tronçons à grande vitesse, comme le nouveau tunnel du Saint-Gothard, durant les heures d'ex-

ploitation. C'est pourquoi depuis quelques années, les CFF utilisent également des trains de mesure spéciaux, appelés véhicules de diagnostic, dotés des technologies de caméras et des techniques de mesure les plus modernes. La qualité de cette évaluation automatique n'arrive toutefois pas à égaler celle d'un expert. Les CFF et le CSEM, un centre suisse de recherche et de développement, se sont donc associés pour « transposer » l'œil averti des inspecteurs des voies dans un logiciel robuste.

Les véhicules de diagnostic

Les CFF exploitent actuellement deux types de véhicules de diagnostic: un véhicule automoteur (figure 2a) et un véhicule tracté (figure 2b). Ces véhicules se déplacent sur les rails à des vitesses pouvant atteindre 200 km/h, procédant à des mesures sur le lit de ballast, les voies, les lignes de contact et les tunnels. Équipés de 18 caméras et de 20 écrans, ils peuvent accueillir jusqu'à quatre ingénieurs de mesure. Toutes les données sont stockées en temps réel, mais peuvent également être affichées en direct pour contrôle dans le train de mesure (figure 3). Chaque kilomètre livre ainsi environ 10 GB de données, soit l'équivalent d'un livre de 5 millions de pages. Pas de doute, le stockage et le traitement de cette masse d'informations relèvent du « big data ».

Les données

Jusqu'à présent, ces montagnes de données étaient traitées avec des méthodes traditionnelles, livrant trop de diagnostics erronés. Contrairement au contrôle de qualité dans un environnement industriel, ici les conditions d'observation varient, car les rails se trouvent à




Figure 1 L'augmentation de la cadence des trains rend le travail des inspecteurs des voies de plus en plus difficile.

l'air libre et sont ainsi exposés à toutes sortes d'influences environnementales:

- la météo: pluie, neige, boue, givre;
- les abords: tunnel, gare, ville, forêt, pont;
- les artefacts: saleté, excréments d'animaux, plantes, chewing-gums ou mégots de cigarettes;
- les types: différences dans la géométrie des voies, des aiguillages et des profils.

Développer un algorithme classique pour l'évaluation de toutes ces variations est pratiquement impossible. De tels algorithmes sont certes faciles à appréhender et très puissants dans le traitement des données numériques, mais confrontés à des descriptions floues, ils sont inefficaces. Et c'est justement le cas lors de défauts à la surface des rails. Leur forme, leur texture ou leur ombrage se révèlent toujours inédits. Un expert peut très bien s'en accommoder, puisqu'il n'a pas besoin d'un

modèle mathématique pour reconnaître un défaut. Il a en effet acquis beaucoup d'expérience au fil des années, ce qui l'aide à effectuer inconsciemment la classification. C'est dans ce type de situation que le deep learning (ou l'apprentissage profond) entre en scène.

Le deep learning

Le deep learning est un domaine de l'intelligence artificielle (AI ou artificial intelligence). De grands réseaux neuronaux (profonds) sont entraînés grâce à des méthodes d'apprentissage inspirées du fonctionnement du cerveau humain. Le deep learning permet de transférer les connaissances et l'expérience d'un expert dans un logiciel afin de former les algorithmes d'apprentissage. Pour ce faire, il faut de grandes quantités de données caractérisées, soit des images évaluées et étiquetées par des experts. Le grand avantage: l'algorithme identifie lui-même



Figure 2 Véhicule de diagnostic des CFF (a) et véhicule de diagnostic tracté (b).




Figure 3 À l'intérieur d'un véhicule de diagnostic.

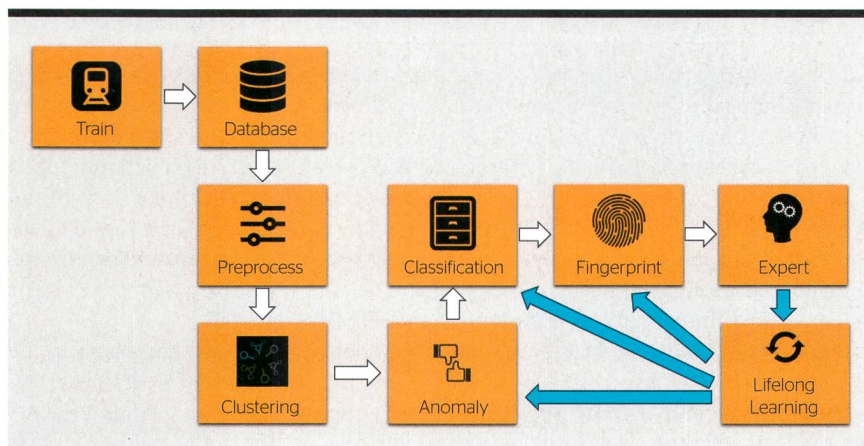


Figure 4 Vue schématique du traitement des données.

les caractéristiques importantes et détermine ainsi automatiquement le meilleur modèle mathématique; en bref, il développe sa propre expérience.

Pour livrer de meilleurs résultats, le nouveau logiciel du CSEM réalise un processus composé de plusieurs étapes (figure 4):

- prétraitement et clustering (partitionnement des données);
- détection d'anomalies;
- classification;
- fingerprinting: calcul des «empreintes digitales» des défauts ou anomalies;
- amélioration continue par l'implication d'experts (apprentissage continu).

L'un des principaux défis à relever réside dans le fait que les données étiquetées disponibles pour entraîner le système sont relativement peu nombreuses. Par ailleurs, pour certaines catégories de défauts, il est très difficile, même pour des experts, d'établir une

classification claire. C'est pourquoi des outils spéciaux ont été développés pour aider ces derniers à exploiter au mieux leurs connaissances et leur expérience. Ces outils ont rapidement permis de décupler la base de données et de faire des recoupements entre experts. Les cas limites ont été discutés au sein de l'équipe avant d'être définitivement évalués. Cette étape essentielle montre que ces nouvelles technologies ne peuvent pas se passer de l'expertise humaine.

Prétraitement et clustering

Toutes les données relevées dans le train rejoignent une base de données centralisée des CFF où elles sont converties dans un format propre à la compagnie. Les CFF peuvent ainsi afficher différentes données en parallèle, indépendamment de leurs sources. Ainsi, outre les données livrées par les véhicules de diagnostic, des données de drones, des

photos d'experts ou des données de mesure de laboratoire peuvent être combinées les unes avec les autres. Une fois sur le serveur, les données sont passées à travers différents filtres, standardisées et réparties dans différentes catégories (clustering). Les images prises dans un tunnel sont en effet traitées différemment de celles de rails prises à l'air libre ou dans une gare.

Détection d'anomalies

L'étape suivante consiste à rechercher les anomalies, à savoir tout ce qu'une personne non formée pourrait aussi remarquer en observant un rail: saleté, feuilles, chewing-gums, défauts, soudures, etc. Pour éviter qu'un défaut ne passe inaperçu, les algorithmes ont tendance à détecter trop d'anomalies. Ils peuvent gérer une variété de défauts quasi infinie et détecter de manière fiable des défauts inconnus. Pour maintenir le nombre d'alarmes à un bas niveau, l'étape suivante est primordiale.

Classification

Toutes les anomalies détectées ne présentent pas le même degré de dangerosité. Il est notamment crucial de distinguer les défauts les plus délicats: les «squats». Ces derniers sont très difficiles à détecter sur la surface des rails: de manière analogue à une carie dans une dent, une cavité apparaît à l'intérieur du rail et se développe toujours plus profondément. Si le «squat» est visible sur la surface, il doit être réparé relativement rapidement.

Afin de différencier les défauts réels des anomalies non critiques, une classification exacte est donc nécessaire (figure 5). Six classes différentes ont été répertoriées dans ce projet, allant de l'«absence de danger» (chewing-gum, fientes d'oiseaux) aux défauts plus importants («squats»). Cette étape représente la différence majeure avec les algorithmes classiques. Pour obtenir de bons résultats, le CSEM a travaillé pendant des mois en étroite collaboration avec les experts des CFF. C'est grâce aux connaissances de ces derniers qu'il a été possible d'entraîner un réseau neuronal à effectuer cette classification avec succès.

Fingerprinting

L'algorithme se révèle déjà très fiable pour identifier et classifier les défauts liés aux artefacts. Les CFF ne peuvent




Figure 5 Différents types de défauts.




Figure 6 Suivi temporel d'un défaut (fingerprinting).

toutefois pas encore s'appuyer exclusivement sur lui, car le réseau de voies ferrées est un élément essentiel en matière de sécurité et il est soumis à une réglementation fédérale stricte. En conséquence, la décision finale quant à savoir si et quand un défaut doit être contrôlé sur place ou réparé reste du ressort des inspecteurs des voies.

Les véhicules de diagnostic empruntent le même itinéraire une fois par mois. De ce fait, les mêmes anomalies et défauts sont constamment détectés et devraient donc également toujours être évalués par un expert. Beaucoup de défauts se développant très lentement, l'intervention ne doit pas forcément être immédiate et sera planifiée opportunément. Afin d'éviter que des défauts déjà enregistrés dans le système de maintenance ne réapparaissent systématiquement, un procédé de suivi dans le temps, le fingerprinting, a été mis au point: lorsque l'AI détecte un défaut, son « empreinte digitale » est calculée de manière à le caractériser formellement. Dès lors, quand le train repasse à cet endroit, il est clairement reconnu et classifié en tant que donnée connue, ce qui permet de disposer d'un suivi temporel, ou d'un historique, de chaque défaut (figure 6). Pour ce faire, il s'agit de surmonter les problèmes d'imprécision de localisation

du véhicule sur le rail (le GPS ne fonctionnant pas dans les tunnels) et d'évolution des caractéristiques environnementales locales; le lit de la voie et la position relative d'un défaut par rapport à la roche environnante ou aux colliers de serrage de la voie peuvent effective-

ment varier considérablement, et ce, particulièrement en cas de dilatation induite par la température (figure 7). Des techniques basées sur le deep learning sont donc également utilisées pour calculer l'empreinte digitale de manière fiable.




Figure 7 Que cela soit dû à des phénomènes sismiques ou à la dilatation sous l'effet de la chaleur, les rails peuvent subir des déformations parfois spectaculaires.




Figure 8 Les véhicules de diagnostic permettent d'effectuer un grand nombre de mesures différentes.

Apprentissage continu

Chaque jour, l'être humain apprend quelque chose de nouveau grâce à ses sens. Il élargit ainsi continuellement ses connaissances. Nous attendons la même chose de l'intelligence artificielle. En tant qu'enseignant dans un processus continu destiné à assurer sécurité et fiabilité sur les rails, l'expert restera indispensable. Ce n'est que grâce à son apport que le logiciel pourra constamment apprendre et réagir à de nouveaux défauts. Il en découle une véritable symbiose entre l'homme et la machine.

L'intelligence artificielle peut non seulement acquérir des connaissances, mais aussi les transférer. Les réseaux neuronaux développés sont en effet déjà utilisés par les CFF pour la formation des jeunes inspecteurs de voies. L'ordinateur leur montre ce que sont les défauts et quels sont les cas limites pour lesquels les experts eux-mêmes ne sont pas unanimes.

Résultats

Le projet a démarré il y a deux ans et se trouve maintenant dans la phase cruciale de l'évaluation. La vérification et l'appréciation statistique des algo-

rites ne sont pas faciles. Un tronçon d'essai a été défini, sur lequel de multiples trajets ont été réalisés avec différents véhicules de diagnostic pour relever de nombreuses données (figure 8). En parallèle, le même tracé a fait l'objet d'une évaluation indépendante par plusieurs inspecteurs des voies. Le nouveau logiciel de deep learning a été mis en concurrence avec les algorithmes classiques, perfectionnés depuis plus de 10 ans et utilisés dans le monde entier. La solution du CSEM améliore le taux de détection d'un facteur 10 et réduit en outre les fausses alertes de 50% en plein air et de 95% dans les tunnels. Qui plus est, ces excellents résultats ont été obtenus sans l'optimisation du réseau neuronal. Ce dernier va à présent être affiné quasi automatiquement dans la phase suivante du projet grâce à un grand nombre de données provenant directement du terrain.

Perspectives

En quelques années, les nouveaux véhicules de diagnostic permettront de multiplier par quatre les kilomètres de tronçons mesurés. Pour maîtriser ce flux de données, des logiciels tels que celui du CSEM sont requis. Aujourd'hui

le contrôle des voies est traditionnellement réactif. Un défaut ne peut être réparé qu'une fois détecté. Et selon sa gravité, l'intervention peut nécessiter à court terme la fermeture d'un tronçon.

En misant sur la détection automatique et le fingerprinting, on espère à l'avenir pouvoir anticiper et planifier la maintenance bien à l'avance. En comprenant mieux comment et où les défauts surgissent, en tirant des conclusions et en prenant les mesures nécessaires, on peut même aspirer à réduire fondamentalement le nombre de ces défauts. L'objectif ultime serait d'utiliser ce logiciel en temps réel, dans un système de surveillance embarqué à bord de chaque train.

Auteurs

Philipp Schmid dirige l'activité Robotique et Machine learning au CSEM et développe, avec son équipe, des solutions modernes pour l'industrie.
→ CSEM, 6055 Alpnach
→ philipp.schmid@csem.ch

Joël Casutt est responsable Technologie et développement chez les CFF, dans le domaine des techniques de mesure et de diagnostic pour les infrastructures.
→ CFF, 3018 Bern
→ joel.casutt@cff.ch

Marcel Zurkirchen est en charge des techniques de mesure et de diagnostic chez les CFF.
→ marcel.zurkirchen@cff.ch



Swiss Lighting Forum 2020 – Licht ≠ Licht

30. Januar 2020 | Congress Center Basel

Sichern
Sie sich
Ihr Ticket!

Blaulichtschädigung: Wird LED-Beleuchtung schlechtgeredet?

Photobiologische Sicherheit – Was ist zentral für die Praxis?



Christoph Schierz, TU Illmenau

Seit die LED die Glühlampe abgelöst hat und in Zukunft auch die Leuchtstofflampe ersetzen wird, steht sie in Verdacht, schädlich für das Auge zu sein. Erfahren Sie mehr über den aktuellen wissenschaftliche Hintergrund und die Grundlagen für eine Gefährdungsbeurteilung dieser sogenannten «Blaulichtschädigung».

swiss-lighting-forum.ch

#lichtspricht



Schweizer Licht Gesellschaft
Association Suisse pour l'éclairage
Associazione Svizzera per la luce
Associazion Svizra per la glistch

