

Transparente Fehlerdiagnose bei Weichenstörungen mittels Bayes'scher Netze

Transparent failure diagnostics for railway switches using Bayesian networks

Thorsten Neumann | Daniela Narezo Guzmán | Jörn Christoffer Groos

Die Anwendung moderner Verfahren der künstlichen Intelligenz (KI) zu Diagnosezwecken erfordert insbesondere bei sicherheitskritischen Anlagen eine sorgfältige Betrachtung der Verlässlichkeit der Ergebnisse. Bayes'sche Netze als etablierte KI-Methode weisen in dieser Hinsicht aufgrund ihrer Transparenz und eines hohen Maßes an Nachvollziehbarkeit der mit ihrer Hilfe algorithmisch realisierten, diagnostischen Schlussfolgerungen einige sehr positive Merkmale auf. Der vorliegende Beitrag diskutiert und demonstriert das theoretische und praktische Potenzial Bayes'scher Netze für die Fehlerdiagnose bei Weichenstörungen anhand konkreter numerischer Beispiele.

1 Einleitung

Digitalisierung und künstliche Intelligenz (KI) sind die großen technologischen Trends unserer Zeit und verändern zunehmend unser Leben [13]. Produktionsprozesse und Arbeitsabläufe wandeln sich und Algorithmen übernehmen immer häufiger wichtige Funktionen bei Entscheidungen. Damit verbunden ist der Wunsch nach mehr Effizienz sowie nach Vermeidung menschlicher Fehler. In bestimmten Bereichen wie der Objekt- oder Spracherkennung erzielen KI-Systeme bereits heute sehr hohe Genauigkeiten [6] oder übertreffen – z. B. bei komplexen Spielen wie Schach oder Go – sogar die menschliche Leistungsfähigkeit [15]. Gleichzeitig stellt sich in vielen Fällen die Frage nach der Verlässlichkeit von KI. Während z. B. bei der Platzierung von Online-Werbung oder bei Suchmaschinen, wo KI ebenfalls sehr erfolgreich eingesetzt wird, der erzielte Nutzen die negativen Wirkungen möglicher Fehlentscheidungen selbst bei Fehlerraten im zweistelligen Prozentbereich klar übersteigt, erfordern sicherheitskritische Anlagen und Prozesse nicht zuletzt aus ethischer Sicht [1] ein wesentlich höheres Maß an Verlässlichkeit, da hier bereits ein einzelner Fehler schwerwiegende Folgen für Mensch und Umwelt haben kann. Die Leit- und Sicherungstechnik im Schienenverkehr zählt zu diesen Anlagen und unterliegt daher seit jeher strengen Sicherheitsrichtlinien [5].

Ein notwendiges Augenmerk der KI-Forschung im jeweiligen Anwendungskontext liegt daher nicht zuletzt auf dem Nachweis der Sicherheit der eingesetzten Algorithmen. Vor allem „Black Box“-Verfahren (z. B. neuronale Netze bzw. Deep-Learning), bei denen die Entscheidungsprozesse im Einzelnen oft nicht transparent und nachvollziehbar sind, erfordern in diesem Zusammenhang eine erhöhte Aufmerksamkeit. Neben ausführlichen Studien im Labor sowie in geschützter realer Testfeldumgebung versucht man in der Forschung zunehmend auch Methoden des simulationsbasierten Testens zu nutzen, bei denen die KI in einer virtuellen, der Realität nachgebildeten Umgebung

The application of modern methods of artificial intelligence (AI) for diagnostic purposes requires careful consideration as to the reliability of the results, especially in the case of safety-critical systems. As an established AI method, Bayesian networks show some very positive characteristics in this regard due to their transparency and the high degree of traceability of the diagnostic conclusions algorithmically reached with their help. This paper discusses and demonstrates the theoretical and practical potential of Bayesian networks for fault diagnosis in the case of switch failures using concrete numerical examples.

1 Introduction

Digitalisation and artificial intelligence (AI) are the major technological trends of our time and they are increasingly changing our lives [13]. Production processes and workflows are changing and algorithms are increasingly assuming important functions in decision-making. This is associated with a desire for greater efficiency and the avoidance of human error. AI systems already achieve very high levels of accuracy in certain areas such as object or speech recognition [6] and they can even exceed human performance, i. e. in complex games such as chess or Go [15]. At the same time, however, the question of reliability arises in many cases. Clearly, the benefits of AI in fields like online advertising or search engines, for example, usually outrank the negative effects of possible wrong decisions, even if the error rates are in the two-digit range. However, safety-critical systems and processes require a considerably higher degree of reliability, not least from an ethical point of view [1], because even a single error can have serious consequences for humans and the environment. Railway control and rail infrastructures belong to this kind of system and have therefore always been subject to strict safety regulations [5].

It is therefore necessary for current AI research activities pertaining to such applications to focus not least on proving the safety of the used algorithms. „Black box“ procedures (e. g. neural networks or deep learning), where the individual decision-making processes are often not transparent and comprehensible, particularly require increased attention within this context. In addition to extensive studies in the laboratory and in protected real test field environments, research is increasingly attempting to use simulation-based testing methods in which the AI is confronted with different test scenarios. These are embedded in a virtual environment simulating reality based on a digital twin of the asset and the environment [4].

in Form eines digitalen Zwillings mit unterschiedlichen Testszenarien konfrontiert wird [4]. Dies erhöht zwar nicht unbedingt die Nachvollziehbarkeit der eingesetzten KI-Algorithmen, fördert aber das Vertrauen in die KI und erlaubt idealerweise eine statistisch fundierte Abschätzung der Sicherheit. Jedoch ist die Erstellung des hierfür erforderlichen digitalen Zwillings inklusive komplexer Umgebungen keineswegs trivial und meist mit einem sehr hohen Aufwand verbunden. Alternativ kann man versuchen, sich bezüglich KI solcher Ansätze zu bedienen, die anders als z.B. neuronale Netze von ihrer Struktur und Algorithmik her für den Menschen unmittelbar verständlich und nachvollziehbar sind. Beispiele hierfür sind klassische Fehlerbaum- oder andere regelbasierte Inferenzverfahren [16]. Aus diagnostischer Sicht, d.h. bei der modellgestützten Ermittlung von Fehlern und Fehlerursachen bei Ausfällen oder Störungen technischer Systeme haben sich zudem Bayes'sche Netze, welche sehr anschaulich menschliche Logiken des Schlussfolgerns unter Unsicherheit abbilden, in der Vergangenheit als ein erfolgversprechender Ansatz erwiesen [2]. Der vorliegende Beitrag beschäftigt sich daher am Beispiel von Eisenbahnweichen gezielt mit dem Einsatz und den Potenzialen Bayes'scher Netze zur transparenten Fehlerdiagnose.

2 Theoretisches Konzept

Bayes'sche Netze sind eine spezielle Art probabilistischer, graphischer Modelle [7], welche die anschauliche Darstellung und kompakte Codierung komplexer stochastischer Abhängigkeiten zwischen verschiedenen Zufallsvariablen mit jeweils prinzipiell beliebiger Anzahl an (diskreten) Zuständen ermöglichen. Die für das Problem relevanten Knoten (= Zufallsvariablen) werden dazu in Form eines gerichteten, azyklischen Graphen angeordnet (Bild 1), wobei Kanten den (in der Praxis üblicherweise kausalen) Einfluss eines Knotens auf seine jeweils unmittelbaren Nachfolger (= Kindknoten) repräsentieren. Die Abhängigkeitsstrukturen zwischen weiter entfernten Knoten folgen dann dem graphentheoretischen Prinzip der d-Separation bzw. d-Konnektivität [3].

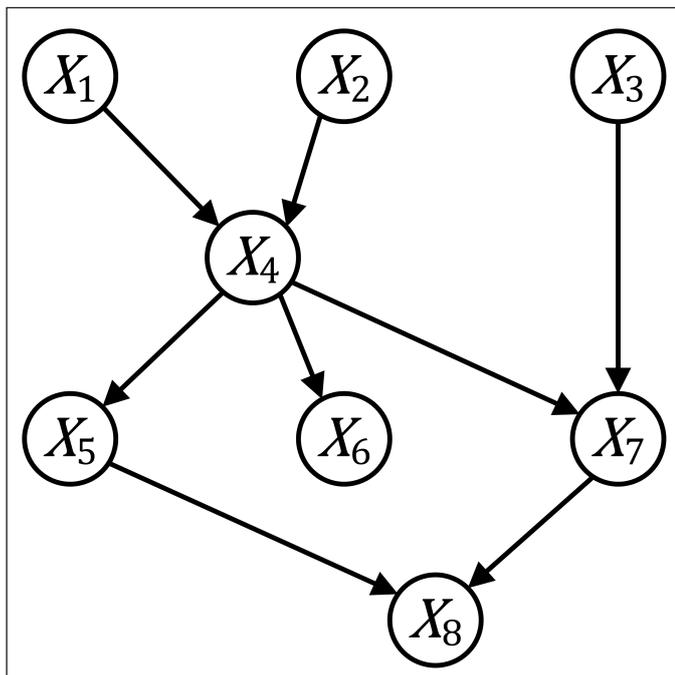


Bild 1: Bayes'sches Netz (Beispiel)

Fig. 1: Bayesian network (example)

Quelle / Source: DLR

Although this does not necessarily increase the traceability of the used AI algorithms, it does promote confidence in the AI solutions and ideally allows a statistically sound assessment of safety. However, creating the digital twin required for this as well as realistically simulating complex environments is by no means trivial and usually involves a great deal of effort.

Alternatively, one could try to use AI approaches which, unlike neural networks, for example, are directly interpretable by humans in terms of structure and algorithms. Typical examples include fault trees or other rule-based inference methods [16]. Moreover, Bayesian networks have proven to be a promising approach in the past from a diagnostic point of view, i.e. with regard to the model-supported identification of errors and error causes in the event of malfunctions in technical systems [2]. This is not least because of their highly descriptive imitation of human reasoning under uncertainty. This paper therefore deals with the use and potential of Bayesian networks in transparent fault diagnosis using railway switches as an example.

2 The theoretical concept

Bayesian networks are a special kind of probabilistic graphical model [7], which allow the visual representation and compact coding of complex stochastic dependencies between different random variables with any number of (discrete) states. The nodes relevant to the problem (= random variables) are arranged in the form of a directed, acyclic graph (fig. 1). And edges represent the (usually causal) influence of a node on its immediate successors (= child nodes). Moreover, the dependency structure between more distant nodes follows the graph-theoretical principle of d-separation or d-connectivity [3].

This enables complex forms of model-based reasoning in which knowledge about the state of individual nodes (= evidence) can be used to efficiently calculate the resulting (conditional) state probabilities of all the other nodes in the network. Causal reasoning occurs when knowledge about the state of a node X_i affects the state probabilities of one or more (not necessarily immediate) successors X_j . Conversely, diagnostic reasoning means that the evidence for any given node affects the probabilities of its parents or further upstream ancestor nodes. Finally, inter-causal reasoning is of particular interest when there are two or more possible causes for a given observed (direct or indirect) effect. If, for example, one of the causes (X_i) can be excluded as the reason for the observed effect, the probability of the other causes usually increases. Conversely, the probability of the other causes decreases if X_i (at least in part) can be identified as the actual trigger for the given effect. In the literature, this case is also referred to as "Explaining Away" [7].

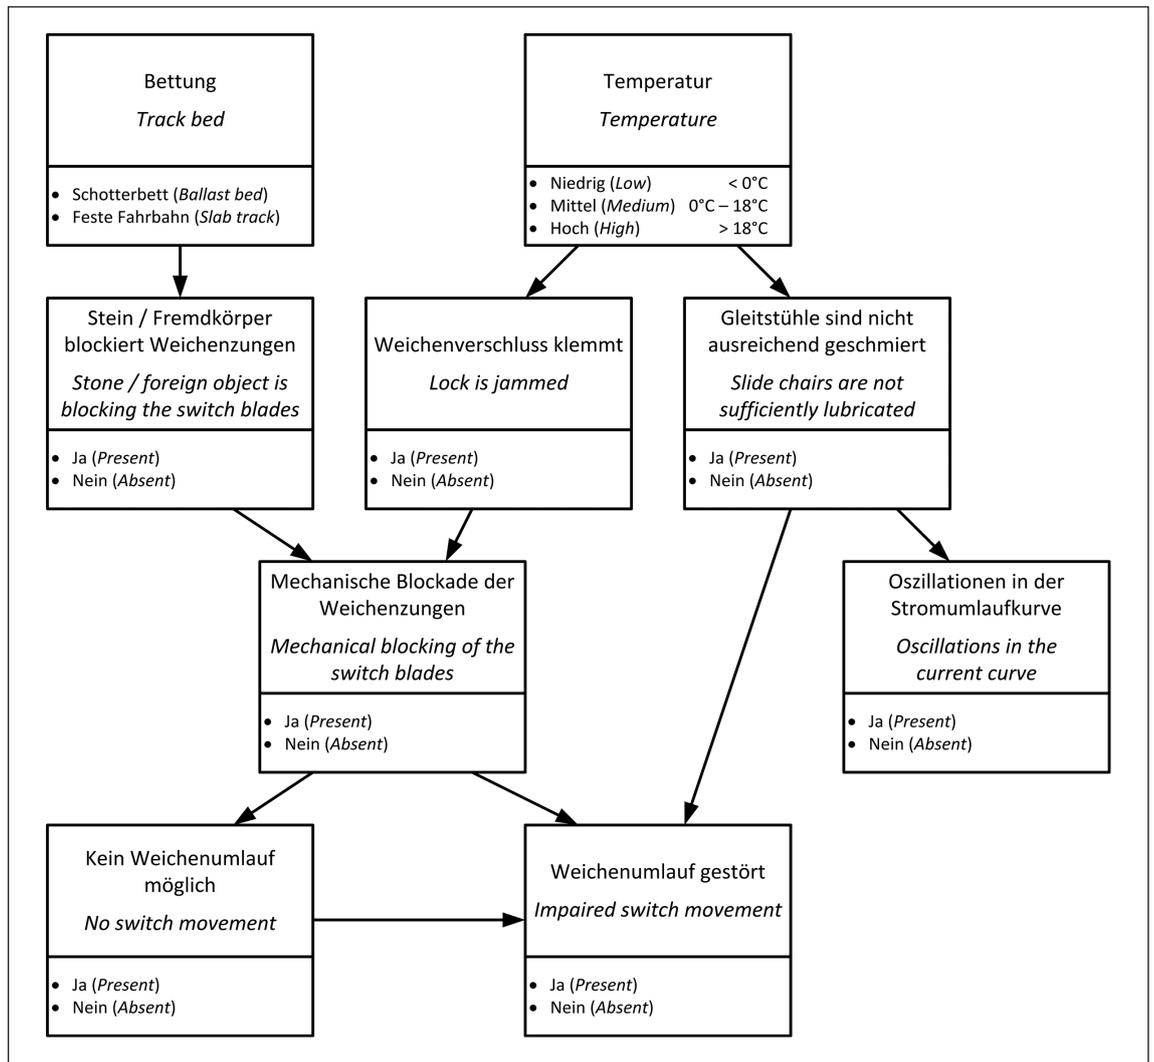
Besides the fundamental stochastic dependencies between the random variables of the Bayesian network, which are completely coded by the structure of the underlying graph with very few exceptions, the actual quantification of the mutual influences between the nodes of the network is achieved using the local conditional probability distributions of the form $P(X_i | Pa(X_i))$, where $Pa(X_i)$ is the set of parent nodes of the node X_i . The full definition of a Bayesian network thus requires the construction of the underlying graph and, in the second step, the determination of the local (conditional) probability distributions for each single node.

Given suitable training data, both tasks can principally be solved by machine learning approaches [11] with more or less

Bild 2: Diagnosemodell für Weichen (vereinfachtes Beispiel)

Fig. 2: Diagnostic model for railway switches (simplified example)

Quelle / Source: DLR



Dies ermöglicht komplexe Formen des modellbasierten Schlussfolgerns, bei dem das Wissen über den Zustand einzelner Netzknotten (= Evidenz) zur effizienten Berechnung der daraus resultierenden (bedingten) Zustandswahrscheinlichkeiten aller anderen Knoten im Netz verwendet werden kann. Kausales Schlussfolgern liegt vor, wenn sich Wissen über den Zustand eines Knotens X_i auf die Zustandswahrscheinlichkeiten eines oder mehrerer (nicht-notwendig unmittelbarer) Nachfolger X_j auswirkt. Umgekehrt bedeutet diagnostisches Schlussfolgern, dass Evidenzen einzelner Knoten die Wahrscheinlichkeiten der Eltern- oder auch weiter vorgelagerter Vorfahrenknoten beeinflussen. Besonders interessant ist ferner das interkausale Schlussfolgern, wenn zwei oder mehr mögliche Ursachen für einen bestimmten beobachteten (mittelbaren oder unmittelbaren) Effekt denkbar sind. Kann z.B. eine der Ursachen (X_i) als Grund für den beobachteten Effekt ausgeschlossen werden, so nimmt die Wahrscheinlichkeit der anderen Ursachen in der Regel zu. Umgekehrt nimmt die Wahrscheinlichkeit der anderen Ursachen ab, wenn X_i (mindestens zum Teil) als tatsächlicher Auslöser für den genannten Effekt identifiziert werden kann. In der Literatur spricht man in diesem Fall auch von „Explaining Away“ [7].

Neben den grundsätzlichen stochastischen Abhängigkeiten bzw. Unabhängigkeiten zwischen den Zufallsvariablen des Bayes'schen Netzes, welche bis auf wenige Ausnahmen komplett über die Struktur des zugrundeliegenden Graphen codiert sind, erfolgt die eigentliche Quantifizierung der wechselseitigen Einflüsse zwischen den Knoten des Netzes abschließend über lokale bedingte Wahrscheinlichkeitsverteilungen.

good success. However, depending on the specific application, it is also possible or even necessary to carry out one or both steps manually and have the required probabilities estimated by experts, for example. Especially in the case of the fault diagnosis of railway switches, it can be assumed that hybrid approaches, which include the knowledge of domain experts as well as the sensor data from existing switch monitoring systems, are currently the most effective with regard to the creation of a suitable model [10].

| Inhaltliche Bedeutung | Zugehörige Netzknotten |
|--|--|
| Externe Einflüsse / bauliche Eigenschaften | <ul style="list-style-type: none"> Bettung Temperatur |
| Potenzielle Fehlerursachen | <ul style="list-style-type: none"> Stein/Fremdkörper blockiert Weichenzungen Weichenverschluss klemmt Gleitstühle sind nicht ausreichend geschmiert |
| Messungen / abgeleitete Kenngrößen | <ul style="list-style-type: none"> Oszillationen in der Stromumlaufkurve |
| Aggregierte Fehlerzustände | <ul style="list-style-type: none"> Mechanische Blockade der Weichenzungen |
| Mögliche Hauptstörungen | <ul style="list-style-type: none"> Kein Weichenumlauf möglich Weichenumlauf gestört |

Tab. 1: Klassifizierung der Netzknotten des Modells aus Bild 2 nach inhaltlicher Bedeutung

Homepageveröffentlichung unbefristet genehmigt für DLR /
 Rechte für einzelne Downloads und Ausdrücke für Besucher der Seiten
 genehmigt von DW Media Group, 2019

| Meaning | Associated nodes |
|--|--|
| External factors / constructional attributes | <ul style="list-style-type: none"> Track bed Temperature |
| Potential causes of failure | <ul style="list-style-type: none"> Stone / foreign object is blocking the switch blades Lock is jammed Slide chairs are not sufficiently lubricated |
| Measurements / derived features | <ul style="list-style-type: none"> Oscillations in the current curve |
| Aggregated causes of failure | <ul style="list-style-type: none"> Mechanical blocking of the switch blades |
| Main effect / failure | <ul style="list-style-type: none"> No switch movement Impaired switch movement |

Tab. 1: Different types of meaning for the nodes of the model from fig. 2

lungen der Form $P(X_j | Pa(X_j))$, wobei $Pa(X_j)$ die Menge der Elternknoten des Knotens X_j bezeichnet. Die vollständige Definition eines Bayes'schen Netzes erfordert demnach die Konstruktion des Netzgraphen sowie in einem zweiten Schritt die Bestimmung der lokalen (bedingten) Wahrscheinlichkeitsverteilungen pro Netzknoten.

Für beide Aufgaben können je nach Verfügbarkeit an geeigneten Trainingsdaten verschiedene Methoden des maschinellen Lernens [11] genutzt werden. Es besteht aber auch die Möglichkeit, je nach Anwendungsfall einen oder beide Schritte manuell durchzuführen und die erforderlichen Wahrscheinlichkeiten z. B. durch Experten schätzen zu lassen. Gerade im Fall der nachfolgend betrachteten Fehlerdiagnose bei Eisenbahnweichen ist davon auszugehen, dass in Bezug auf die Erstellung eines passenden Modells hybride Ansätze, die sowohl das Wissen von Domänenexperten als auch Sensordaten der bestehenden Weichenüberwachung einbeziehen, derzeit am zielführendsten sind [10].

3 Anwendung in der Weichendiagnose

3.1 Modellierung

Im Kontext der modellbasierten Diagnose von Fehlerursachen bei Weichen sind aufgrund der Komplexität der Anlagen in der Regel diverse Faktoren zu berücksichtigen. Dies spiegelt sich nicht zuletzt darin wider, dass ein entsprechendes Bayes'sches Netz zwangsläufig Knoten mit inhaltlich sehr unterschiedlichen Bedeutungen aufweisen wird (vgl. Tab. 1). Bild 2 zeigt in diesem Zusammenhang ein vereinfachtes, auf wenige Fehler beschränktes Modell, an dem im Folgenden das Potenzial Bayes'scher Netze für den betrachteten Anwendungsfall demonstriert werden soll. Die hinterlegten lokalen (bedingten) Wahrscheinlichkeitsverteilungen der einzelnen Netzknoten, welche hier zum Zweck der besseren Verdeutlichung der Funktionsweise des Modells (mit Ausnahme der Knoten „Bettung“ und „Temperatur“) auf hypothetischen Annahmen mit möglicherweise überhöhten Fehlerwahrscheinlichkeiten beruhen, sind in Bild 3 dargestellt.

In plausibler Weise wird dabei abgebildet, dass beispielsweise die Temperatur als externer Faktor auf die Gleitfähigkeit der Schmierstoffe bei den Gleitstühlen wirkt und die Wahrscheinlichkeit einer unzureichenden Gleitfähigkeit etwa bei niedrigen Temperaturen zunimmt. Genauso besteht die Möglichkeit, dass Weichenverschlüsse bei niedrigen Temperaturen schwergängiger als bei hohen Temperaturen sind oder bei Frost sogar vereist sein können. Die Art des Gleisbetts hat ferner unmittelbar Auswirkungen auf die Wahrscheinlichkeit eines Fremdkörpers (insbesondere eines blockierenden Steins) im Bereich der Weichenzungen. Beides (d. h. sowohl ein Fremdkörper im Bereich der Weichenzungen als auch ein klemmender Weichenverschluss) kann in der Folge eine mehr oder weniger starke Blockade im Weichenumlauf verursachen.

3 An application for railway switch diagnostics

3.1 Modelling

Various factors usually have to be taken into account due to the complexity of the asset within the context of the model-based diagnosis of the causes of railway switch failures. This is reflected not least in the fact that a Bayesian network will inevitably have nodes with very different meanings in parallel (see tab. 1). In this regard, fig. 2 shows a simplified model limited to just a few possible faults, which demonstrates the potential of Bayesian networks for the considered application. The deposited local (conditional) probability distributions of the individual network nodes are shown in fig. 3. Note that all the distributions here, except for the “track bed” and “temperature” nodes, are based on hypothetical assumptions with possibly excessive fault probabilities in order to better illustrate the functioning of the model.

As such, the network plausibly represents the fact that temperature acts as an external factor on the gliding properties of the slide chair lubricants, for instance, and that the probability of insufficient lubrication increases at lower temperatures. There is also the possibility that switch locks may be stiffer at lower temperatures than at higher temperatures or may even become iced up during frost. Similarly, the type of track bed has a direct effect on the probability of the occurrence of a foreign object (especially a blocking stone) in the vicinity of the switch blades. Moreover, both a foreign object in the vicinity of the switch blades as well as a jamming switch lock can cause a more or less strong blockage during the switch movement in the further process.

The combined effect of an inadequate lubrication of the slide chairs on the one hand and a possible blockage of the switch blades on the other hand then leads to the probability that the switch movement will be impaired or even not at all possible. Within this context, the direct edge between the two main failure nodes (fig. 2), along with the local probability distribution of the “Impaired switch movement” node, ensures that these mutually exclusive main failures (i. e. “Impaired switch movement” or “No switch movement”) cannot occur simultaneously in the model.

Finally, the “Oscillations in the current curve” node is of particular interest as it establishes the connection to existing systems for switch condition monitoring. Here, the non-reactively measured current curves represent the temporal course of the power consumption at the switch drive during the movement. The current curves usually follow a characteristic pattern which correlates with the different phases of the switch movement, namely the start phase, unlocking, the movement of the switch blades and locking [9]. Fig. 4 shows such a typical pattern as well as an abnormal current curve with oscillations during the movement phase, which could, but of course do not necessarily have to be, an indicator of some unwanted mechanical resistance during the switch blade movement (e. g. due to the insufficient lubrication of the slide chairs, cf. fig. 2).

3.2 Examples

In order to demonstrate the model from fig. 2, tab. 2 shows the computational results for some diagnostic scenarios under the assumption that the switch movement has been impaired. For this purpose, concrete knowledge (evidence) of the actual state of the individual network nodes is used to probabilistically localise the cause of the failure as accurately as possible. The pre-

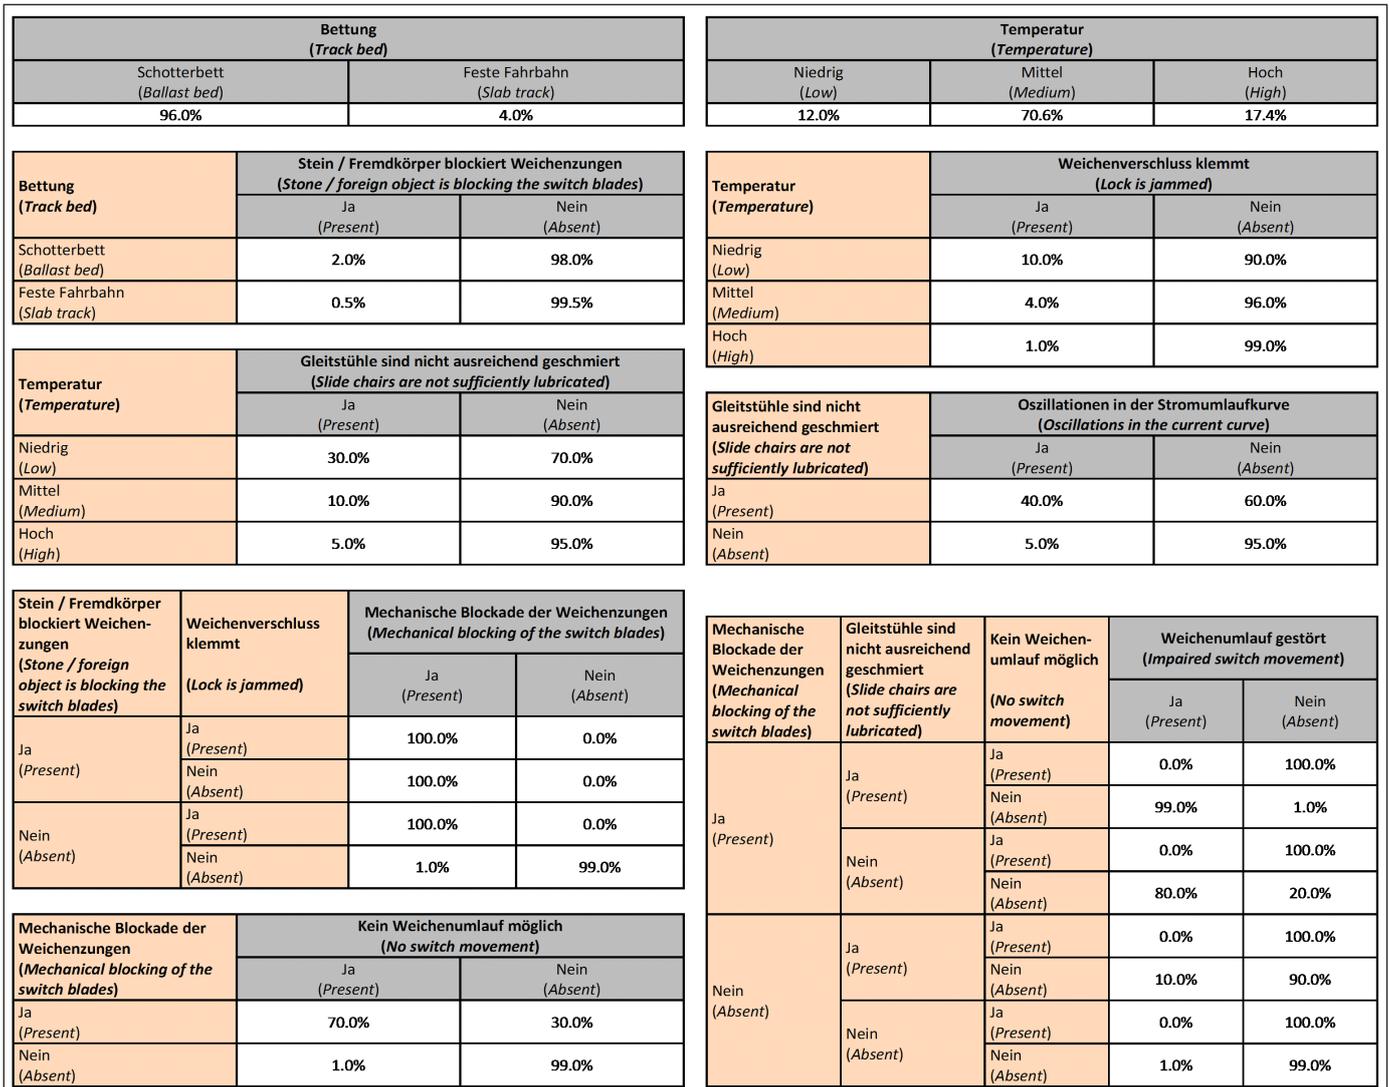


Bild 3: Lokale bedingte Wahrscheinlichkeitsverteilungen für das Modell aus Bild 2

Fig. 3: Local conditional probability distributions for the model from fig. 2

Quelle / Source: DLR

Aus dem Zusammenwirken einer ggf. unzureichenden Schmierung der Gleitstühle sowie einer möglichen Blockade der Weichenzungen ergeben sich dann die Wahrscheinlichkeiten dafür, dass der Weichenumlauf gestört oder unter Umständen gar nicht möglich ist. Die direkte Kante zwischen den beiden Hauptstörungsknoten (Bild 2) stellt dabei im Zusammenspiel mit der lokalen Wahrscheinlichkeitsverteilung des Knotens „Weichenumlauf gestört“ sicher, dass die sich im vorliegenden Beispiel per Definition gegenseitig ausschließenden Hauptstörungen (d.h. „Weichenumlauf gestört“ bzw. „Kein Weichenumlauf möglich“) auch im Modell nicht gleichzeitig auftreten können.

Von besonderem Interesse ist im Weiteren noch der Knoten „Oszillationen in der Stromumlaufkurve“, der gewissermaßen die Anbindung an bestehende Systeme der Weichenzustandsüberwachung herstellt. Die in Bezug auf die Sicherungstechnik rückwirkungsfrei gemessenen Stromumlaufkurven repräsentieren in diesem Zusammenhang den zeitlichen Verlauf der Stromaufnahme des Weichenantriebs während eines Umlaufs. Sie folgen dabei üblicherweise einem charakteristischen Verlauf, der unmittelbar mit den verschiedenen Phasen des Weichenumlaufs (d. h. Startphase, Entriegelung, Bewegung der Zungen, Verriegelung) korreliert [9]. Bild 4 zeigt einen solchen typischen Verlauf sowie eine anormale Umlaufkurve mit Os-

sented scenarios are consecutively based on each other, which is why the changes in the probabilities denoted in brackets (tab. 2) always refer to the given preceding scenario. Moreover, the reference scenario corresponds to the a priori case without any explicit knowledge of any actual states or failures. The percentages given in this case can therefore be understood to be a kind of basic probability.

It can be seen, as expected, that the knowledge (evidence) of the presence of an impaired switch movement (scenario 1.1) leads to significantly increased probabilities with regard to the possible causes of failure, especially those which are temperature-dependent. At the same time, if the actual temperature is not known, the probability of observing a low temperature increases over the course of diagnostic reasoning, since a jammed switch lock or the insufficient lubrication of the slide chairs occurs more frequently with decreasing temperatures according to the parameterisation of the model (fig. 3). For the same reason (but conversely), the probability of temperature-dependent causes of failure decreases again, if it is known that there is a high temperature at the time of observation (scenario 1.2). Moreover, as a result of inter-causal reasoning, the probability of a blocking stone or a foreign object in the vicinity of the switch blades then

| Knoten | Zustand | Szenario | | | |
|---|----------------|----------|------------------|------------------|------------------|
| | | Ref. | #1.1 | #1.2 | #1.3 |
| Bettung | Schotterbett | 96% | 96% (± 0 PP) | 97% (+ 1 PP) | 96% (- 1 PP) |
| | Feste Fahrbahn | 4% | 4% (± 0 PP) | 3% (- 1 PP) | 4% (+ 1 PP) |
| Temperatur | Niedrig | 12% | 22% (+ 10 PP) | 0% (- 22 PP) | 0% (± 0 PP) |
| | Mittel | 71% | 67% (- 4 PP) | 0% (- 67 PP) | 0% (± 0 PP) |
| | Hoch | 17% | 11% (- 6 PP) | 100% Evidenz | 100% Evidenz |
| Stein / Fremdkörper blockiert Weichenzungen * | Ja | 2% | 13% (+ 11 PP) | 20% (+ 7 PP) | 11% (- 9 PP) |
| Weichenverschluss klemmt * | Ja | 4% | 29% (+ 25 PP) | 10% (- 19 PP) | 6% (- 4 PP) |
| Gleitstühle sind nicht ausreichend geschmiert * | Ja | 12% | 37% (+ 25 PP) | 23% (- 14 PP) | 70% (+ 47 PP) |
| Oszillationen in der Stromumlaufkurve * | Ja | 9% | 18% (+ 9 PP) | 13% (- 5 PP) | 100% Evidenz |
| Mechanische Blockade der Weichenzungen * | Ja | 7% | 48% (+ 41 PP) | 41% (- 7 PP) | 22% (- 19 PP) |
| Kein Weichenumlauf möglich * | Ja | 6% | 0% (- 6 PP) | 0% (± 0 PP) | 0% (± 0 PP) |
| Weichenumlauf gestört * | Ja | 4% | 100% Evidenz | 100% Evidenz | 100% Evidenz |

* Beachte: P (X="ja") = 1-P(X="nein") / PP = Prozentpunkt

Tab. 2: Zustandswahrscheinlichkeiten bei gestörtem Weichenumlauf (Referenz = A-priori-Fall ohne Evidenzen)

zillationen während der Umstellphase, die neben anderen denkbaren Fehlerursachen auf zusätzliche mechanische Widerstände während der Zungenbewegung (z. B. eben wegen mangelnder Schmierung der Gleitstühle, vgl. Bild 2) hindeuten könnte.

3.2 Beispielrechnungen

Im Sinne einer Beispielrechnung basierend auf dem Modell aus Bild 2 zeigt Tab. 2 die Ergebnisse verschiedener Diagnoseszenarien für den Fall eines gestörten Weichenumlaufs, bei denen konkretes Wissen (Evidenz) über den tatsächlichen Zustand einzelner Netzknoten genutzt wird, um die Fehlerursache im probabilistischen Sinne bestmöglich einzugrenzen. Die dargestellten Szenarien bauen hierbei aufeinander auf, weshalb sich die in Klammern angegebenen Änderungen der Wahrscheinlichkeiten (Tab. 2) stets auf das jeweils vorangegangene Szenario beziehen. Das Referenzszenario entspricht überdies einer A-priori-Betrachtung ohne explizites Wissen über irgendwelche vorliegenden Zustände oder Störungen. Die in diesem Fall angegebenen Prozentwerte können demnach in gewisser Weise als Basiswahrscheinlichkeiten verstanden werden. Man erkennt, dass das Wissen (Evidenz) über das Vorliegen eines gestörten Weichenumlaufs (Szenario 1.1) wie erwartet zu einer deutlichen Erhöhung der Wahrscheinlichkeiten vor allem bei den temperaturabhängigen Fehlerursachen im Modell führt. Zugleich erhöht sich bei Unkenntnis der tatsächlichen Temperatur im Zuge diagnostischen Schlussfolgerns die Wahrscheinlichkeit einer niedrigen Temperatur, da ein klemmender Weichenverschluss oder eine mangelnde Schmierung der Gleitstühle gemäß Parametrierung des Modells (Bild 3) mit sinkenden Temperaturen häufiger auftreten. Mit der gleichen Begründung (nur in umgekehrter Richtung) nehmen die Wahrscheinlichkeiten der temperaturabhängigen Fehlerursachen übrigens wieder ab, wenn bekannt ist, dass zum Zeitpunkt der Betrachtung eine hohe Temperatur vorliegt (Szenario 1.2). Dabei erhöht sich infolge interkausalen Schluss-

| Node | State | Scenario | | | |
|--|-------------|----------|------------------|------------------|------------------|
| | | Ref. | #1.1 | #1.2 | #1.3 |
| Track bed | Ballast bed | 96% | 96% (± 0 PP) | 97% (+ 1 PP) | 96% (- 1 PP) |
| | Slab track | 4% | 4% (± 0 PP) | 3% (- 1 PP) | 4% (+ 1 PP) |
| Temperature | Low | 12% | 22% (+ 10 PP) | 0% (- 22 PP) | 0% (± 0 PP) |
| | Medium | 71% | 67% (- 4 PP) | 0% (- 67 PP) | 0% (± 0 PP) |
| | High | 17% | 11% (- 6 PP) | 100% Evidenz | 100% Evidenz |
| Stone / foreign object is blocking the switch blades * | Present | 2% | 13% (+ 11 PP) | 20% (+ 7 PP) | 11% (- 9 PP) |
| Lock is jammed * | Present | 4% | 29% (+ 25 PP) | 10% (- 19 PP) | 6% (- 4 PP) |
| Slide chairs are not sufficiently lubricated * | Present | 12% | 37% (+ 25 PP) | 23% (- 14 PP) | 70% (+ 47 PP) |
| Oscillations in the current curve * | Present | 9% | 18% (+ 9 PP) | 13% (- 5 PP) | 100% Evidenz |
| Mechanical blocking of the switch blades * | Present | 7% | 48% (+ 41 PP) | 41% (- 7 PP) | 22% (- 19 PP) |
| No switch movement * | Present | 6% | 0% (- 6 PP) | 0% (± 0 PP) | 0% (± 0 PP) |
| Impaired switch movement * | Present | 4% | 100% Evidenz | 100% Evidenz | 100% Evidenz |

* Note: P (X="present") = 1-P (X="absent") / PP = Percentage Point

Tab. 2: State probabilities in case of impaired switch movement (Reference = A-priori-case without evidences)

increases accordingly, as it may provide an alternative explanation for the impaired switch movement. In fact, foreign objects and a lack of lubrication of the slide chairs are then almost equally likely to be the true cause of failure with probabilities of 20% and 23% respectively. A distinct change in this probability ratio can be found if, for example, measurements or findings from sensor-based switch monitoring systems (in this case the observation of oscillations in the current curve) are taken into account (scenario 1.3). This means that the resulting probability of 70% for insufficiently lubricated slide chairs in this case is far above the probability of the other causes of failure in the model even under the assumption of high temperatures. Note that low temperatures together with observed oscillations in the current curve would imply an increase in the aforementioned probability of even up to 92%.

In the second example, consider that the switch movement is not possible at all instead of (simply) being impaired (tab. 3), which leads to somewhat different results. As such, the minor changes across the scenarios with regard to the probability of a lack of slide chair lubrication are primarily indirect effects of the probabilistically estimated temperature conditions. However, a detailed discussion of the results in tab. 3 should be dispensed with at this point in the interests of brevity. Nonetheless, it is worth pointing out that in the case of a slab track, even if a jammed switch lock is excluded as one of the possible reasons for the failure (scenario 2.3), the probabilities of the other two modelled causes of failure (i.e. a "Stone / foreign object blocking the switch blades" and "Slide chairs are not sufficiently lubricated") are comparatively low at 17% and 11% respectively. This could indicate that the observed failure (i.e. "No switch movement") has most likely been generated by a non-modelled cause of failure in the given situation (i.e. including

folgers die Wahrscheinlichkeit eines blockierenden Steins oder Fremdkörpers im Bereich der Weichenzungen als andere denkbare Fehlerursache für den gestörten Weichenumlauf entsprechend. Im betrachteten Modell liegen Fremdkörper und mangelnde Schmierung der Gleitstühle als tatsächliche Ursache dann mit 20% und 23% Wahrscheinlichkeit sogar nahezu gleichauf. Zu einer deutlichen Verschiebung dieses Verhältnisses kommt es, wenn man z. B. noch Erkenntnisse aus der sensorgestützten Weichenüberwachung (in diesem Fall die Beobachtung von Oszillationen in der Stromumlaufkurve) einbezieht (Szenario 1.3). Die resultierende Zustandswahrscheinlichkeit von 70% für nicht ausreichend geschmierte Gleitstühle (trotz hoher Temperatur) liegt in diesem Fall weit über den Wahrscheinlichkeiten der anderen modellierten Fehlerursachen. Bei niedrigen (anstatt hoher) Temperaturen und Oszillationen in der Stromumlaufkurve würde die genannte Wahrscheinlichkeit übrigens sogar 92% betragen.

Anders sieht es in einer zweiten Beispielrechnung aus, bei der anstelle eines gestörten Weichenumlaufs überhaupt kein Weichenumlauf möglich ist (Tab. 3). Die über die Szenarien hinweg lediglich geringen Änderungen der Wahrscheinlichkeit einer mangelnden Schmierung der Gleitstühle ergeben sich hier vor allem als indirekter Effekt über die Zustandswahrscheinlichkeiten der Temperatur. Auf eine ausführliche Diskussion der Ergebnisse aus Tab. 3 soll an dieser Stelle aber aus Platzgründen verzichtet werden. Es lohnt jedoch darauf hinzuweisen, dass im Fall einer Festen Fahrbahn trotz des Ausschlusses eines klemmenden Weichenverschlusses (Szenario 2.3) die Wahrscheinlichkeiten der beiden anderen Fehlerursachen (d.h. „Stein/Fremdkörper blockiert Weichenzungen“ und „Gleitstühle sind nicht ausreichend geschmiert“) mit 17% bzw. 11% vergleichsweise niedrig ausfallen. Dies könnte darauf hindeuten, dass der nicht mögliche Weichenumlauf bei der vorliegenden Evidenzsituation (einschließlich der Annahme einer Festen Fahrbahn) mit hoher Wahrscheinlichkeit von einer nicht modellierten Fehlerursache herrührt. Bei einem Schotterbett würde die Wahrscheinlichkeit eines blockierenden Steins oder Fremdkörpers bei ansonsten unveränderten Evidenzen allerdings auf 46% ansteigen.

4 Schlussfolgerungen und Ausblick

Insbesondere die Beispielrechnungen aus Abschnitt 3.2 zeigen, wie Bayes'sche Netze wegen ihrer intuitiv nachvollziehbaren Schlussfolgerungslogiken sehr gut zu einer transparenten Ursachendiagnose bei Weichenstörungen eingesetzt werden können. Darüber hinaus lassen sich wie im Referenzszenario aus Tab. 2 bzw. Tab. 3 auch (ggf. evidenzabhängige) Wahrscheinlichkeitsprognosen für einzelne Fehler oder Störungen ermitteln. Während etwa die A-priori-Wahrscheinlichkeit eines gestörten Weichenumlaufs laut Modell 4% beträgt (vgl. Tab. 2), würde dieser Wert infolge kausalen Schlussfolgerns unter Annahme einer niedrigen Temperatur (Evidenz) beispielsweise auf 6% anwachsen.

Die Transparenz des Modells fördert in diesem Zusammenhang die vor allem aus praktischer Sicht wichtige Plausibilisierung der Modellergebnisse [14] und vereinfacht zugleich die Lokalisierung und Behebung möglicher Modellfehler. Letzteres ist vor allem deshalb relevant, weil sowohl die Konstruktion des Netzes als auch die Parametrierung des Modells – wie auch bei anderen KI-Verfahren – keineswegs trivial sind. Dabei beschränkt sich die Anwendbarkeit der Theorie Bayes'scher Netze nicht zwingend auf kleine Modelle mit wenigen Netzknoten wie in Bild 2. Die verfügbaren Softwaretools und Algorithmen sind vielmehr auch für die Berechnung großer Netze geeignet. Dennoch kann es bei zunehmender Komplexität sinnvoll sein, im Sinne eines modularen bzw. objekt-orientierten Ansatzes [8] zunächst eigenständige Modelle für die einzelnen Teilkomponenten des betrachteten Systems zu konstruieren, bevor diese über

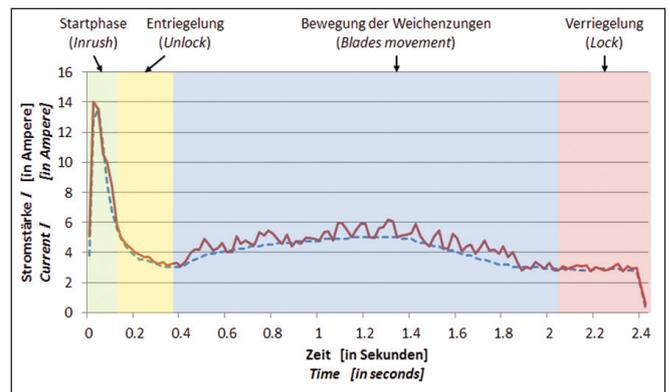


Bild 4: Schematische Darstellung einer typischen Stromumlaufkurve (gestrichelte Linie) und einer atypischen Stromumlaufkurve mit Oszillationen während der Umstellphase (durchgezogene Linie)

Fig. 4: Schematic illustration of a normal current curve (dotted line) and an abnormal current curve with oscillations during the movement phase (solid line)

Quelle / Source: DLR

the assumption of a slab track). In the case of a ballast bed, however, the probability of a blocking stone or foreign object would plausibly increase to 46% given otherwise unchanged evidence.

4 Conclusion and further outlook

The example calculations from Section 3.2 show how Bayesian networks can be very useful to transparent fault diagnosis in the case of switch failures due to their intuitively comprehensible logic of reasoning. In addition, probability forecasts for individual faults or malfunctions can also be derived (depending on the provided or non-provided evidence), as can be seen in the reference scenarios from tab. 2 or tab. 3. While, for example, the a priori probability of an impaired switch movement is 4% according to the model (cf. tab. 2), this value would increase to 6% as a result of causal reasoning assuming a low temperature (evidence).

In this context, the transparency of the Bayesian network promotes the plausibility check of the model results [14], which is particularly important from a practitioner's point of view. Moreover, this kind of interpretability simplifies the localisation and correction of possible modelling errors at the same time. The latter is particularly relevant because both the construction of the network and the parameterisation of the model – as with other AI methods – are by no means trivial. Importantly, the applicability of Bayesian networks is not necessarily limited to small models with few network nodes as in fig. 2, but the available software tools and algorithms are also well suited to the calculation of large networks. Nevertheless, increasing complexity means that it can be better to first construct independent models for the individual subcomponents of the considered system in terms of a modular or object-oriented approach [8] before connecting them to each other via previously defined interface nodes. The article in [12] describes the structural design of a corresponding switch diagnosis model considering numerous (sub)components and influencing factors.

The general procedure regarding the use of Bayesian networks for switch failure diagnostics is shown in fig. 5 in the form of a schematic flow chart. As can be seen, the diagram also contains conceptual extensions in the direction of a future

| Knoten | Zustand | Szenario | | | |
|---|----------------|----------|------------------|------------------|------------------|
| | | Ref. | #2.1 | #2.2 | #2.3 |
| Bettung | Schotterbett | 96% | 97% (+ 1 PP) | 0% (- 97 PP) | 0% (± 0 PP) |
| | Feste Fahrbahn | 4% | 3% (- 1 PP) | 100% Evidenz | 100% Evidenz |
| Temperatur | Niedrig | 12% | 20% (+ 8 PP) | 22% (+ 2 PP) | 11% (- 11 PP) |
| | Mittel | 71% | 69% (- 2 PP) | 69% (± 0 PP) | 71% (+ 2 PP) |
| | Hoch | 17% | 11% (- 6 PP) | 10% (- 1 PP) | 18% (+ 8 PP) |
| Stein / Fremdkörper blockiert Weichenzungen * | Ja | 2% | 23% (+ 21 PP) | 7% (- 16 PP) | 17% (+ 10 PP) |
| Weichenverschluss klemmt * | Ja | 4% | 50% (+ 46 PP) | 60% (+ 10 PP) | 0% Evidenz |
| Gleitstühle sind nicht ausreichend geschmiert * | Ja | 12% | 13% (+ 1 PP) | 14% (+ 1 PP) | 11% (- 3 PP) |
| Oszillationen in der Stromlaufkurve * | Ja | 9% | 10% (+ 1 PP) | 10% (± 0 PP) | 9% (- 1 PP) |
| Mechanische Blockade der Weichenzungen * | Ja | 7% | 84% (+ 77 PP) | 81% (- 3 PP) | 52% (- 29 PP) |
| Kein Weichenumlauf möglich * | Ja | 6% | 100% Evidenz | 100% Evidenz | 100% Evidenz |
| Weichenumlauf gestört * | Ja | 4% | 0% (- 4 PP) | 0% (± 0 PP) | 0% (± 0 PP) |

* Beachte: P (X="ja") = 1-P(X="nein") / PP = Prozentpunkt

Tab. 3: Zustandswahrscheinlichkeiten bei nicht möglichem Weichenumlauf (Referenz = A-priori-Fall ohne Evidenzen)

zuvor definierte Schnittstellenknoten miteinander verbunden werden. Der Artikel in [12] beschreibt den strukturellen Entwurf eines entsprechenden Weichendiagnosemodells unter Berücksichtigung zahlreicher Komponenten und Einflussfaktoren. Das allgemeine Vorgehen bezüglich des Einsatzes Bayes'scher Netze für die Fehlerursachendiagnose bei Weichenstörungen ist ferner in Bild 5 in Form eines schematischen Ablaufdiagramms dargestellt. Dabei sind auch konzeptionelle Erweiterungen in Richtung eines zukünftig selbstlernenden Systems enthalten. Zudem besteht die theoretische Möglichkeit, in Abhängigkeit von der gegebenen Evidenzlage mittels (automatisierter) Sensitivitätsanalysen jeweils diejenigen Netzknoten zu ermitteln, bei denen konkrete (ggf. kostengünstig zu generierende) Zusatzinformationen über deren Zustand einen maximalen Nutzen hinsichtlich der probabilistischen Eingrenzung der unbekanntes Fehlerursache(n) liefern. Somit lassen sich in dynamischer Weise (technisch und wirtschaftlich) optimale Diagnosestrategien

| Node | State | Scenario | | | |
|--|-------------|----------|------------------|------------------|------------------|
| | | Ref. | #2.1 | #2.2 | #2.3 |
| Track bed | Ballast bed | 96% | 97% (+ 1 PP) | 0% (- 97 PP) | 0% (± 0 PP) |
| | Slab track | 4% | 3% (- 1 PP) | 100% Evidenz | 100% Evidenz |
| Temperature | Low | 12% | 20% (+ 8 PP) | 22% (+ 2 PP) | 11% (- 11 PP) |
| | Medium | 71% | 69% (- 2 PP) | 69% (± 0 PP) | 71% (+ 2 PP) |
| | High | 17% | 11% (- 6 PP) | 10% (- 1 PP) | 18% (+ 8 PP) |
| Stone / foreign object is blocking the switch blades * | Present | 2% | 23% (+ 21 PP) | 7% (- 16 PP) | 17% (+ 10 PP) |
| Lock is jammed * | Present | 4% | 50% (+ 46 PP) | 60% (+ 10 PP) | 0% Evidenz |
| Slide chairs are not sufficiently lubricated * | Present | 12% | 13% (+ 1 PP) | 14% (+ 1 PP) | 11% (- 3 PP) |
| Oscillations in the current curve * | Present | 9% | 10% (+ 1 PP) | 10% (± 0 PP) | 9% (- 1 PP) |
| Mechanical blocking of the switch blades * | Present | 7% | 84% (+ 77 PP) | 81% (- 3 PP) | 52% (- 29 PP) |
| No switch movement * | Present | 6% | 100% Evidenz | 100% Evidenz | 100% Evidenz |
| Impaired switch movement * | Present | 4% | 0% (- 4 PP) | 0% (± 0 PP) | 0% (± 0 PP) |

* Note: P (X="present") = 1-P (X="absent") / PP = Percentage Point

Tab. 3: State probabilities in case of no switch movement (Reference = A-priori-case without evidences)

self-learning system. In addition, given the already found evidence, it is also theoretically possible to determine those network nodes where concrete (possibly simple or inexpensive to obtain) additional information about the actual states provides maximum benefit with regard to the probabilistic delimitation of the unknown cause(s) of failure using (automated) sensitivity analyses. Thus, optimal diagnostic strategies can be dynamically derived with regard to technical and / or economic constraints. This also includes practical recommendations which specifically minimise the effort of troubleshooting in the event of a failure. However, despite the promising concept, it must be conceded that there is still some research to be done with regard to designing and optimising a comprehensive Bayesian network model for railway switch diagnostics before a reasonable implementation under real-world conditions will become possible. ■

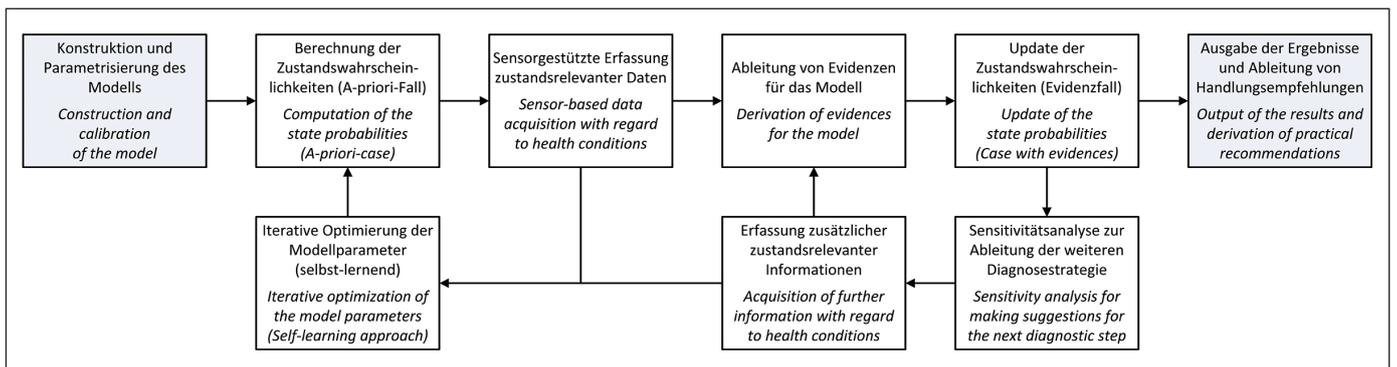


Bild 5: Erweitertes Ablaufschema der Fehlerdiagnose bei Weichen mittels Bayes'scher Netze

Fig. 5: Extended flowchart of railway switch diagnostics using Bayesian networks

Quelle / Source: DLR

einschließlich entsprechender Handlungsempfehlungen für die Praxis ableiten, die den Aufwand der Fehlersuche im Falle einer Störung gezielt minimieren. Dabei darf allerdings nicht verschwiegen werden, dass trotz des erfolgversprechenden Konzepts hinsichtlich der Konstruktion und Optimierung eines ausgereiften Bayes'schen Netzes als Diagnosemodell für Weichen sowie bezogen auf dessen prototypischen Einsatz im operativen Betrieb noch einige Forschungs- und Entwicklungsarbeit zu leisten ist. ■

LITERATUR | LITERATURE

- [1] Bostrom, N.; Yudkowsky, E.: The Ethics of Artificial Intelligence. In: Franks, K.; Ramsey, W. M. (Hg.): The Cambridge Handbook of Artificial Intelligence: Cambridge University Press, 2014, S. 316–334. Online verfügbar unter <http://faculty.smc.edu/acjamieson/s13/artificialintelligence.pdf>, zuletzt geprüft am 02.08.2019
- [2] Cai, B.; Huang, L.; Xie, M.: Bayesian Networks in Fault Diagnosis. In: IEEE Trans. Ind. Inf. 13 (5), 2017, S. 2227–2240
- [3] Charniak, E.: Bayesian Networks without Tears. In: AI Magazine (Winter 1991), S. 50–63
- [4] Dahmen, U.; Rossmann, J.: Experimentable Digital Twins for a Modeling and Simulation-based Engineering Approach. In: 2018 IEEE International Systems Engineering Symposium (ISSE). Rome, 01.-03.10.2018, 2018
- [5] European Union (30.04.2004): Railway Safety Directive, vom 29.04.2004. In: Official Journal of the European Union (L 164), S. 44–113. Online verfügbar unter <https://eur-lex.europa.eu/legal-content/EN/TXT/PDF/?uri=CELEX:32004L0049&qid=1565080317218&from=DE>
- [6] Hinton, G.; Deng, L.; Yu, D.; Dahl, G.; Mohamed, A.; Jaitly, N. et al.: Deep Neural Networks for Acoustic Modeling in Speech Recognition: The Shared Views of Four Research Groups. In: IEEE Signal Process. Mag. 29 (6), 2012, S. 82–97. DOI: 10.1109/MSP.2012.2205597
- [7] Koller, D.; Friedman, N.: Probabilistic graphical models. Principles and techniques. Cambridge, Mass.: MIT Press (Adaptive computation and machine learning), 2009
- [8] Koller, D.; Pfeffer, A.: Object-Oriented Bayesian Networks. In: Proceedings of the 13th Annual Conference on Uncertainty in Artificial Intelligence. Providence, Rhode Island, 1.-3.8.1997, 1997, S. 302–313
- [9] Narezo Guzmán, D.; Hadzic, E.; Schuil, R.; Baars, E.; Groos, J. C. (2018a): Data-driven condition now- and forecasting of railway switches for improvement in the quality of railway transportation. In: Kulkarni, Ch. S.; Tinga, T. (Hg.): Proceedings of the European Conference of the PHM Society. 4th European Conference of the PHM Society. Utrecht, The Netherlands, 03.-06.07.2018. PHM Society (Proceedings of the European Conference of the PHM Society, 4)
- [10] Narezo Guzmán, D.; Neumann, T.; Groos, J. C. (2018b): Kontinuierliche Überwachung der LST mit eingebetteten Sensoren. Automatische Anomalie-Erkennung für die Leit- und Sicherheitstechnik mit Verfahren der künstlichen Intelligenz: Aktuelle Forschungsschwerpunkte am Beispiel der Weiche. In: EI – DER EISENBAHNINGENIEUR 11/2018, S. 6–11
- [11] Neapolitan, R. E.: Learning Bayesian networks. Upper Saddle River, NJ: Pearson Prentice Hall (Prentice Hall series in architectural intelligence), 2004
- [12] Neumann, T.; Narezo Guzmán, D.: Bayesian network design for fault diagnostics of railway switches. In: Beer, M.; Zio, E. (Hg.): Proceedings of the 29th European Safety and Reliability Conference. ESREL 2019. Hannover, 22 - 26 September 2019. Singapore: Research Publishing, 2019
- [13] Russell, S.; Norvig, P.: Artificial Intelligence. 3rd ed.: Pearson Education UK, 2016
- [14] Silmon, J. A.; Roberts, C.: Improving railway switch system reliability with innovative condition monitoring algorithms. In: Proceedings of the Institution of Mechanical Engineers, Part F: Journal of Rail and Rapid Transit 224 (4), S. 293–302. DOI: 10.1243/09544097JRR313, 2010
- [15] Silver, D.; Hubert, T.; Schrittwieser, J.; Antonoglou, I.; Lai, M.; Guez, A. et al.: A general reinforcement learning algorithm that masters chess, shogi, and Go through self-play. In: Science (New York, N.Y.) 362 (6419), 2018, S. 1140–1144. DOI: 10.1126/science.aar6404
- [16] Zang, Y.; Shangguan, W.; Cai, B.; Wang, H.; Pecht, M. G.: Methods for fault diagnosis of high-speed railways: A review. In: Proceedings of the Institution of Mechanical Engineers, Part O: Journal of Risk and Reliability 10 (5), 2019, S. 1748006X1882393

AUTOREN | AUTHORS

Dr.-Ing. Thorsten Neumann

Wissenschaftlicher Mitarbeiter / *Researcher*
 Institut für Verkehrssystemtechnik,
 Arbeitsgruppe Anlagen- und Systemmonitoring
 Deutsches Zentrum für Luft- und Raumfahrt e.V. (DLR)
 Anschrift / *Address*: Rutherfordstr. 2, D-12489 Berlin
 Email: Thorsten.Neumann@dlr.de

Dr. Daniela Narezo Guzmán

Wissenschaftliche Mitarbeiterin / *Researcher*
 Institut für Verkehrssystemtechnik,
 Arbeitsgruppe Anlagen- und Systemmonitoring
 Deutsches Zentrum für Luft- und Raumfahrt e.V. (DLR)
 Anschrift / *Address*: Rutherfordstr. 2, D-12489 Berlin
 Email: Daniela.NarezoGuzman@dlr.de

Dr. rer. nat. Jörn Christoffer Groos

Gruppenleiter / *Group Leader*
 Institut für Verkehrssystemtechnik,
 Arbeitsgruppe Anlagen- und Systemmonitoring
 Deutsches Zentrum für Luft- und Raumfahrt e.V. (DLR)
 Anschrift / *Address*: Lilienthalplatz 7, D-38108 Braunschweig
 Email: Joern.Groos@dlr.de