

# Erkennung streckenspezifischer Charakteristika zur Ortung im spurgebundenen Verkehr

## Detection of Track-specific Characteristics for Location in Railbound Traffic

Thomas Engelberg und Fernando Puente León\*

*Herrn Prof. em. Dr.-Ing. Franz Mesch zum 70. Geburtstag gewidmet*

Manuskripteingang: 07. Juli 2002; zur Veröffentlichung angenommen: 14. August 2002.

Die charakteristische Anordnung von Streckenbauteilen eröffnet den Weg zu einer bordautonomen Ortung im spurgebundenen Verkehr. Hierbei zeichnen am Fahrzeug angebrachte Sensoren Signale der Strecke auf, die mit Hilfe von Korrelationsverfahren mit den Daten eines Streckenatlases verglichen werden. Bei der Messung können unerwünschte Verzerrungen der Signale auftreten, die zu niedrigen Korrelationswerten führen. Der Aufsatz behandelt eine Erweiterung der Korrelationsmethodik, welche diese Verzerrungen berücksichtigt und somit deutlich bessere Ergebnisse liefert. Zur Erkennung von nichtlinear amplitudenverzerrten Signalen werden zwei Ansätze entwickelt, die auf Histogrammtransformationen basieren. Abszissenverzerrungen werden zusätzlich mittels einer Korrekturfunktion berücksichtigt, die sich über Energieminimierungsmethoden bestimmen lässt. Die vorgestellten Verfahren können bei der Ortung von Schienenfahrzeugen eingesetzt werden, aber auch in anderen Bereichen der Mustererkennung.

The characteristic arrangement of track components enables a train-based location in railbound traffic. Sensors mounted on the vehicle record signals of the rail track, and these are compared with the data of a digital rail map by means of correlation techniques. However, during measurement unwanted distortions of the signals may occur, yielding poor correlation results. The paper discusses an extension of the correlation methodology in which these distortions are considered, leading thus to notably better results. To detect signals with nonlinearly distorted amplitudes, two approaches based on a histogram transform are developed. Distortions of the abscissa are taken into account by means of a correction function that can be determined with energy minimization methods. The proposed strategies can be applied to the location of railbound vehicles as well as to other fields of pattern recognition.

**Schlagwörter:** Korrelationsverfahren, Mustererkennung, nichtlineare Ähnlichkeiten, bordautonome Ortung, Weichenerkennung

**Keywords:** Cross correlation, pattern recognition, nonlinear similarities, train-borne location, detection of rail switches

## 1 Einleitung

Die effiziente Nutzung der vorhandenen Fahrwege im spurgebundenen Verkehr erfordert eine leistungsfähige Fahrzeugortung [11]. Eine kontinuierliche Positionsbe-

stimmung der Fahrzeuge kann jedoch nicht allein mit satellitengestützten Navigationssystemen wie z. B. dem US-amerikanischen GPS (Global Positioning System) oder dem europäischen System Galileo realisiert werden [1]. Grundsätzliche Probleme bereiten unter anderem die Abschattung (z. B. in Tunnels) und die Mehrwegausbreitung der Satellitensignale. Deshalb sind zusätzliche Systeme zur Bestimmung der Fahrzeugposition erforderlich. Aufgrund

\* Die Arbeit entstand am Institut für Mess- und Regelungstechnik (Prof. Dr.-Ing. C. Stiller) der Universität Karlsruhe (TH) unter der Leitung von Prof. Dr.-Ing. F. Mesch.

technischer und wirtschaftlicher Überlegungen sind jedoch nur solche Verfahren interessant, die ohne aufwändige und teure streckenseitige Installationen auskommen [2; 12].

Eine in [3] vorgeschlagene Ortungsmethode nutzt gezielt die vorhandene Information über die Topologie des Gleisnetzes. Diese wird in einem digitalen Streckenatlas bereitgestellt, wobei die Verzweigungen (Weichen und Kreuzungen) als Knoten und die Strecken als Kanten dargestellt werden. Die Fahrzeugortung basiert hier auf der bordautonomen Detektion solcher Knoten und der dort eingeschlagenen Fahrroule. Mit einer konventionellen Wegmessung – z.B. auf Basis der zeitlichen Integration der gemessenen Geschwindigkeit – kann außerdem die Fahrzeugposition zwischen den Knoten einfach bestimmt werden. Eine weitere in [3] vorgestellte Methode der Ortung stützt sich auf die Detektion individueller Ereignisse des Fahrweges (Weichen, Schienenstöße und dergleichen) mit Hilfe geeigneter bordautonomer Sensoren, die das Streckenumfeld erfassen. Die eigentliche Positionsbestimmung erfolgt durch Vergleich der Sensorsignale mit den Daten des Streckenatlases.

Im vorliegenden Beitrag werden verallgemeinerte Korrelationsverfahren zur Erkennung streckenspezifischer Sensorsignale im spurgebundenen Verkehr vorgestellt. Die hier dargestellten Ansätze stützen sich zwar auf die bekannte Kreuzkorrelationsfunktion (KKF) [13], sind jedoch im Gegensatz hierzu auch auf die Detektion nichtlinearer Ähnlichkeiten beim Vergleich stochastischer Signale zugeschnitten. Zur Signalerzeugung sind verschiedene Sensorarten denkbar, wie z.B. Wirbelstrom-Sensoren [6; 12], Radar-Sensoren [2; 10], optische Sensoren [4] und dergleichen. Die hier betrachtete Bahnanwendung erfordert jedoch sehr robuste und witterungsunempfindliche Sensoren, weshalb hier die Verfahren am Beispiel von Wirbelstrom-Sensorsignalen demonstriert werden.

Im Abschnitt 2 wird das Konzept eines Systems zur Erkennung streckenspezifischer Sensorsignale besprochen, wobei die Grundidee und die Anforderungen an die Signalverarbeitung erläutert werden. Der Abschnitt 3 behandelt die Detektion nichtlinearer Ähnlichkeiten von stochastischen Signalen in allgemeiner Form. Die vorgestellten Verfahren

werden exemplarisch auf Wirbelstrom-Sensorsignale von Weichen angewendet.

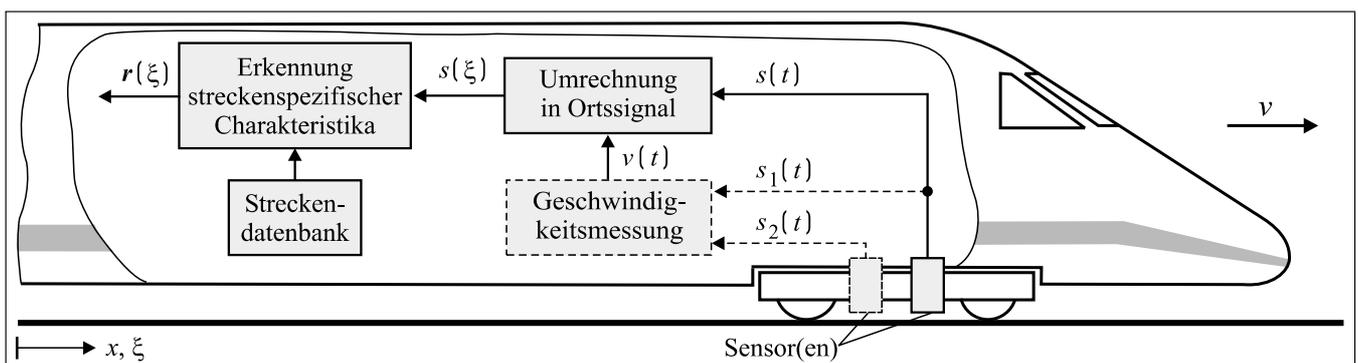
## 2 Systemkonzept

### 2.1 Grundidee

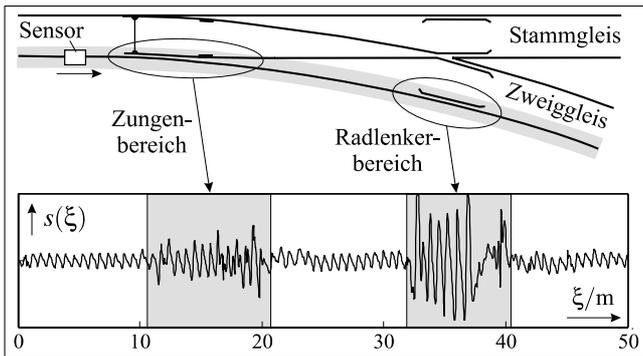
Bild 1 zeigt das Grundprinzip der bordautonomen Erkennung streckenspezifischer Charakteristika. Am Schienenfahrzeug befinden sich  $N$  Sensoren, welche die relevanten Bereiche der Strecke – z. B. eine oder beide Schienen, aber auch das Gebiet zwischen den Schienen – erfassen. Die Form der resultierenden Sensorsignale  $s_i(t)$ ,  $i = 1, \dots, N$ , hängt im Wesentlichen ab von dem gewählten physikalischen Sensorprinzip, von der Ausrichtung der Sensoren im Bezug zur Strecke sowie von der Beschaffenheit des erfassten Streckenbereichs.

Für die Erkennung streckenspezifischer Charakteristika genügt prinzipiell ein Sensorsignal  $s(t)$ , das jedoch in ein Ortssignal  $s(\xi)$  mit  $\xi := \hat{x} = \int \hat{v}(t)dt$  umgerechnet werden muss, damit die Signalverarbeitung unabhängig von der Geschwindigkeit  $v$  des Zuges stattfinden kann. Werden zwei gleichartige, in Fahrtrichtung hintereinander angeordnete Sensoren verwendet, so kann die für die Berechnung von  $\xi$  erforderliche Geschwindigkeit  $v$  z. B. mit dem bekannten Laufzeit-Korrelationsverfahren [5] geschätzt werden. Die eigentliche Erkennung des Streckenumfeldes erfolgt dann auf Basis des Vergleichs der gemessenen Ortssignale mit den Daten eines Streckenatlases.

Nachfolgend wird die Grundidee des Verfahrens am Beispiel von Wirbelstrom-Sensoren erläutert. Die Sensoren, die am Fahrzeug im Abstand  $h$  über einer Schiene montiert sind, erfassen berührungslos Inhomogenitäten, die auf den lokalen elektromagnetischen Eigenschaften im Bereich der Schiene beruhen [5]. Aus bahnbetrieblichen Gründen muss – abhängig von der Sensorgröße – ein Sensorabstand zur Schiene  $h > 80$  mm gewählt werden. In diesem Fall sprechen die Wirbelstrom-Sensoren nur auf größere Inhomogenitäten an. Auf freier Strecke sind dies vorwiegend die Schienenbefestigungen. Im Bereich von Weichen werden zusätzlich auch metallische Weichenbauteile (z. B. Radlenker) erfasst. Dies zeigt Bild 2 am Beispiel der Bewegung



**Bild 1:** Bordautonome Erkennung streckenspezifischer Charakteristika ( $r(\xi)$ : Detektionsergebnisse).



**Bild 2:** Gemessenes Sensorsignal  $s(\xi)$  auf einem Zweiggleis einer Weiche.

des Sensors entlang der grau markierten Zweiggleis-Schiene einer Weiche [6]. Die Bereiche der Weichenzunge und des Radlenkers spiegeln sich eindeutig im Sensorsignal  $s(\xi)$  wider.

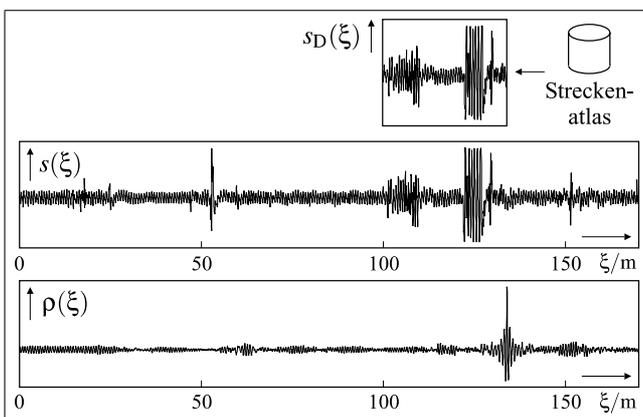
Zur Identifikation streckenspezifischer Charakteristika ist im Streckenatlas das Mustersignal  $s_{D,i}(\xi)$  jedes interessierenden Ereignisses zu speichern, wobei speziell im Falle von Weichen für jede Schiene und Weichenstellung ein solches Signal aufgenommen werden muss [6; 7]. Zwar ist der Aufwand hierfür erheblich, lässt sich jedoch mit den in [12] beschriebenen Verfahren weitgehend automatisieren.

Die eigentliche Identifikation des Ereignisses kann auf der Grundlage der Korrelation der Mustersignale  $s_{D,i}(\xi)$  aller in Frage kommenden Ereignisse mit dem gemessenen Sensorsignal  $s(\xi)$  erfolgen. Falls im Sensorsignal  $s(\xi)$  das Ereignis  $i$  enthalten ist, so weist die empirische KKF

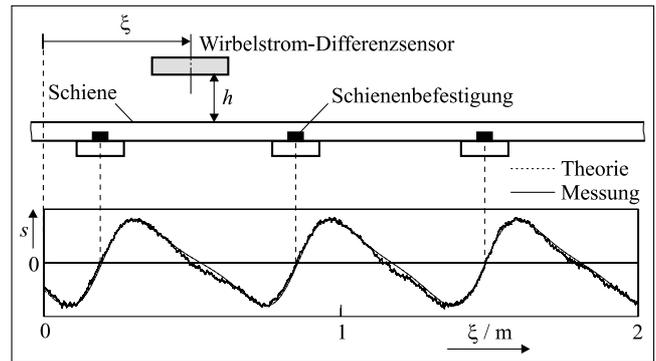
$$\rho(\xi) = s(\xi) \otimes s_{D,i}(\xi) = \int_{-\infty}^{\infty} s(\chi) s_{D,i}(\chi + \xi) d\chi \quad (1)$$

ein ausgeprägtes Maximum an der entsprechenden Stelle auf, welches einfach detektiert werden kann.

Bild 3 zeigt ein Beispiel zur Weichenidentifikation. Im Messsignal  $s(\xi)$  befindet sich ab  $\xi = 100$  m der Zungenbereich einer Weiche. In einer früheren Messfahrt wurde die gleiche Weiche bei ähnlichen Bedingungen (gleicher Sensortyp und gleicher Sensorabstand zur Schiene) erfasst und



**Bild 3:** Weichenidentifikation mit Korrelationsverfahren.



**Bild 4:** Gemessenes und mit einem Sensormodell berechnetes Sensorsignal.

als Mustersignal  $s_D(\xi)$  abgespeichert. Das untere Diagramm in Bild 3 zeigt den Verlauf der KKF  $\rho(\xi)$ , deren ausgeprägtes Maximum  $\max\{\rho(\xi)\} = 0,99$  die Lage der erkannten Weiche markiert.

In bestimmten Fällen können jedoch nichtlineare Ähnlichkeiten der beiden Signale vorliegen, die mit der KKF gemäß Gl. (1) nicht detektiert werden können. Zum Beispiel rufen Schwankungen des Sensorabstandes eine nichtlineare Verzerrung des Messsignals hervor. Da die KKF lediglich die lineare Abhängigkeit zweier Signale erfasst, kommt es in solchen Fällen zu einer geringeren Korrelation zwischen den Signalen. Daher werden in Abschnitt 2.2 allgemeinere Definitionen von Ähnlichkeit vorgestellt, die solche Verzerrungen berücksichtigen. Ferner werden im Abschnitt 3 Strategien behandelt, welche eine zuverlässige Erkennung derartiger Ähnlichkeiten erlauben.

Die im Streckenatlas gespeicherten Mustersignale können von zuvor durchgeführten Messfahrten stammen. Prinzipiell kommt aber auch die Berechnung der Mustersignale in Betracht, sofern ein geeignetes Modell des Sensors und der erfassten Umgebung vorliegt.

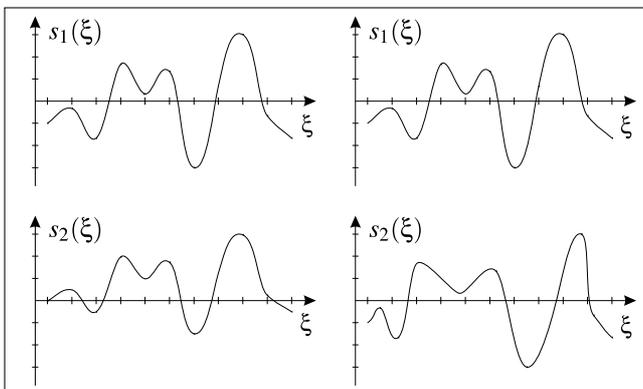
Zum Beispiel kann zur Berechnung von Wirbelstrom-Sensorsignalen ein in [5] vorgestelltes Signalmodell verwendet werden, sofern der Sensorabstand zur Schiene so groß ist, dass im Wesentlichen nur größere Anbauteile der Schiene das Sensorsignal prägen. Bild 4 zeigt exemplarisch ein solches berechnetes Mustersignal und das gemessene Sensorsignal auf einem geraden Gleisabschnitt, wobei der Signalverlauf hier hauptsächlich durch die Schienenbefestigungen geprägt wird. Es zeigt sich eine sehr gute Übereinstimmung des gemessenen und des berechneten Sensorsignals. Eine Erweiterung dieses Signalmodells für Weichen ist denkbar, wobei hier zusätzlich auch noch die Anbauteile der Weiche zu berücksichtigen sind.

## 2.2 Anforderungen an die Signalverarbeitung

In diesem Abschnitt werden die Anforderungen erläutert, welche der Vergleich der Sensorsignale erfüllen muss, um eine zuverlässige Detektion von Ähnlichkeiten zu ermöglichen. Obgleich der Ausdruck „Ähnlichkeit“ in der Technik oftmals als Synonym für „lineare Ähnlichkeit“

verwendet wird, ist diese Einschränkung keineswegs immer sinnvoll oder umfassend genug – weder in technischen noch in biologischen Systemen. Zur robusten Erkennung des Streckenumfeldes im spurgebundenen Verkehr ist eine Verallgemeinerung des Ähnlichkeitsbegriffes erforderlich, damit komplexere Zusammenhänge zwischen den Signalen ebenfalls erfasst werden:

- (a) Eine Verallgemeinerung betrifft die Amplitudenwerte der zu vergleichenden Signale. Hier soll Ähnlichkeit nicht notwendigerweise eine lineare Abhängigkeit der Signale implizieren. Im Allgemeinen führen Nichtlinearitäten im Übertragungsverhalten der Sensoren – bei Wirbelstrom-Sensoren z. B. infolge eines veränderten Sensorabstandes – sowie Quantisierungseffekte zu einer nichtlinearen Verzerrung der Sensorsignale, wobei die Rangordnung ihrer Amplitudenwerte in den meisten Fällen erhalten bleibt. Die Skalierung der Abszisse bleibt in diesem Spezialfall ebenfalls unverändert; siehe Bild 5 (links).
- (b) Auch die Abszissenwerte der Signale können lineare oder gar nichtlineare Verzerrungen aufweisen; siehe Bild 5 (rechts). Solche Signaleigenschaften sind typisch für zeitabhängige Prozesse, bei denen die Zeitbasis beispielsweise durch eine ungleichförmige Bewegung oder eine unpräzise Uhr aufgestellt wird. Neben der daraus resultierenden veränderlichen Dehnung der Abszisse kann hier ebenfalls eine nichtlineare Amplitudenskalierung gemäß Punkt (a) hinzukommen.
- (c) Ein hochgradig allgemeiner Ansatz, um Ähnlichkeiten zu definieren, verzichtet ganz auf die Betrachtung einer ordinalen Skala, um die Musterfunktionen bzw. die Ereignisse des interessierenden Prozesses zu beschreiben – die Realisationen des Prozesses brauchen also nicht einer hierarchischen Ordnung zu gehorchen. Vielmehr basiert dessen Beschreibung einzig und allein auf der Einzelwahrscheinlichkeit eines jeden Ereignisses. Im Gegensatz zu den weiter oben beschriebenen Verallgemeinerungsansätzen, bei denen Erweiterungen des Korrelationskalküls zu geeigneten Erkennungsstrategien führen können, bedarf dieser Fall von Ähnlichkeit den



**Bild 5:** Charakterisierung unterschiedlicher Arten von Ähnlichkeit: (links) nichtlineare Skalierung der Amplitude; (rechts) unregelmäßige Abszissenskalierung.

Einsatz informationstheoretischer Methoden wie z. B. der Kreuzentropieanalyse [9].

Vergleicht man den Umfang dieser Definitionen verallgemeinerter Ähnlichkeit miteinander, so fällt sofort auf, dass der Grad an Ähnlichkeit von (a) zu (c) abnimmt. Parallel erhöht sich aber die Notwendigkeit, unschärfere Ähnlichkeitsmodelle zu deren Erkennung einzusetzen, was im Allgemeinen nicht nur zu einer Erhöhung der Detektionswahrscheinlichkeit führt, sondern gleichzeitig auch der Falschalarmrate. Insbesondere erkauft man sich die Allgemeinheit der Verfahrensweise von Punkt (c) um den Preis eines kleineren Erkenntnisgewinns als im Falle der Korrelationsverfahren basierenden Ansätze [15]. Aus diesem Grund werden im folgenden Abschnitt ausschließlich Strategien behandelt, die sich auf das Korrelationskalkül zurückführen lassen, um eine Verallgemeinerung der Ähnlichkeitsbegriffe im Sinne von (a) und (b) zu erzielen.

### 3 Erkennung nichtlinearer Ähnlichkeiten

#### 3.1 Energieminimierungsansatz

Energieminimierungsmethoden liefern ein leistungsfähiges Werkzeug, um Optimierungsprobleme zu formulieren – selbst wenn zahlreiche Nebenbedingungen oder *Constraints* vorhanden sind. Diese Tatsache macht sie hochgradig interessant, um schlecht gestellte Probleme zu lösen, wie z. B. die Detektion verallgemeinerter Ähnlichkeiten. Das Optimierungsergebnis erhält man durch Minimierung einer verallgemeinerten Energiefunktion

$$E = \sum_i \lambda_i E_i \rightarrow \min, \quad (2)$$

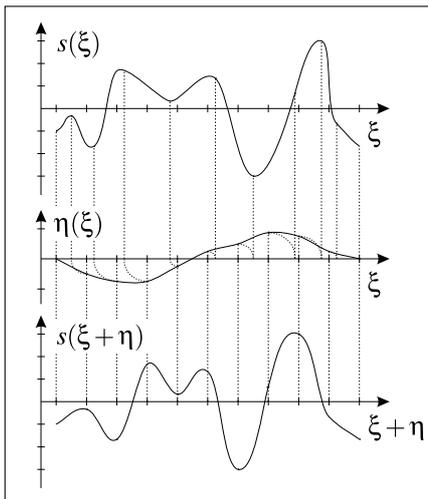
wobei die gewünschten Eigenschaften des Resultates durch die Energierterme  $E_i$  repräsentiert und mittels ihrer respektiven Faktoren  $\lambda_i$  gewichtet werden.

Daher müssen die Energien  $E_i$  derart gewählt werden, dass sie sowohl das A-priori-Wissen über das optimale Ergebnis als auch über die Nebenbedingungen widerspiegeln. Um eine sinnvolle Minimierung zu ermöglichen, müssen die Energierterme monoton abnehmende Werte zugunsten wünschenswerter Ergebnisse annehmen.

Die Anwendung von Energieminimierungsmethoden zur Detektion verallgemeinerter Ähnlichkeiten soll anhand von Bild 5 (rechts) demonstriert werden, in welchem die Signale unterschiedlich abgetastet wurden und daher ihre Abszisse lokal unterschiedlich skaliert erscheint.

Eine Möglichkeit zur Erschließung derartiger Ähnlichkeiten basiert auf der Anwendung einer Abszissenskalierung auf das Messsignal  $s(\xi)$ . Bild 6 zeigt sowohl das Beispiel-signal  $s(\xi)$  aus Bild 5 (rechts) als auch das Ergebnis der Anwendung der Abszissenskalierungsfunktion  $\eta(\xi)$ , welche das korrigierte Signal  $s(\xi + \eta)$  liefert.

Die Skalierung verändert die Abtastschrittweite und führt somit zu einer Erhöhung der linearen Ähnlichkeit, die anschließend mittels der KKF ermittelt werden kann. Aus



**Bild 6:** Abszissenskalierung.

Stabilitätsgründen, und um zusätzlich Artefakte bei der „Entzerrung“ des verformten Signals zu vermeiden, muss die Skalierungsfunktion einen glatten Verlauf aufweisen. Ferner sind hierbei niedrige Funktionswerte zu favorisieren. Diese gewünschten Eigenschaften können mit Hilfe einer Energiefunktion, bestehend aus drei Termen, ausgedrückt werden:

$$\begin{aligned}
 E &= E_{\text{Abst}}(\eta) + \lambda_1 E_{\text{Glatt}}(\eta) + \lambda_2 E_{\text{Ähnl}}(s, s_D) \\
 &= \sum_{\xi} \eta^2(\xi) + \lambda_1 \sum_{\xi} \left( \frac{d}{d\xi} \eta(\xi) \right)^2 \\
 &\quad + \lambda_2 (-1) [s(\xi + \eta(\xi)) \otimes s_D(\xi)], \quad \lambda_i > 0. \quad (3)
 \end{aligned}$$

Der erste Energieterm,  $E_{\text{Abst}}$ , führt eine quadratische Bewertung des Abstandes zwischen dem veränderten Signal  $s(\xi + \eta)$  und dem Ursprungssignal  $s(\xi)$  durch Bestrafen hoher Werte durch. Der zweite Term,  $E_{\text{Glatt}}$ , evaluiert die Glattheit der Skalierungsfunktion  $\eta(\xi)$  und nimmt mit wachsender Glattheit monoton ab. Der dritte Term,  $E_{\text{Ähnl}}$ , beurteilt schließlich die lineare Ähnlichkeit zwischen dem veränderten Messsignal  $s(\xi + \eta)$  und  $s_D(\xi)$  auf der Grundlage von Korrelationsverfahren. Der Faktor  $(-1)$  sorgt dafür, dass  $E_{\text{Ähnl}}(s, s_D)$  mit wachsender Ähnlichkeit fallende Werte annimmt.

Um die verschiedenen Energieterme geeignet zu gewichten, müssen die Regularisierungsparameter  $\lambda_i$  entsprechend gewählt werden. Im Idealfall liefert das Optimierungsergebnis das globale Minimum von  $E$  und damit sowohl ein Maß für die verformungsinvariante Ähnlichkeit  $E_{\text{Ähnl}}(s, s_D)$  als auch die zugehörige örtliche Korrekturfunktion  $\eta(\xi)$ .

Obwohl Energieminimierungsmethoden ein flexibles Mittel zur Formulierung von Optimierungsaufgaben bereitstellen, weist die Anwendung solcher Strategien gewisse Probleme auf:

- Die Minimierung der Energiefunktion Gl. (2) muss iterativ durchgeführt werden. Je nach Konditionierung der Aufgabe kann daher ein stabiles Ergebnis nicht immer garantiert werden. Um Instabilität und Konvergenzprob-

leme zu vermeiden, müssen aus diesem Grund die Regularisierungsparameter  $\lambda_i$  sorgfältig gewählt werden. Hierbei ist speziell im Beispiel von Gl. (3) der Beitrag des Glattheitsterms von großer Bedeutung. Andererseits kann jedoch solch eine Glättung gleichzeitig zu einer Abnahme des Ähnlichkeitsmaßes führen.

- Das Ergebnis der Minimierung hängt stark von der Wahl der Regularisierungsparameter  $\lambda_i$  ab. Da diese jedoch willkürlich innerhalb der Stabilitätsgrenzen festgelegt werden können, stellt das Ergebnis nur das Optimum bezüglich dieser Parameterwahl dar.
- Von einem praktischen Standpunkt aus betrachtet führt die Evaluierung und Optimierung der umfangreichen Energiefunktion zu einem gewaltigen Rechenaufwand. Aus diesem Grund wird bei zahlreichen Ansätzen, die sich auf Energieminimierungsmethoden stützen, nicht die Energiefunktion Gl. (2) explizit berechnet, sondern vielmehr das Minimum, basierend auf einer getrennten Optimierung der Einzelterme, approximiert [14; 16].

### 3.2 Nichtlineare Signaltransformationen

In diesem Abschnitt wird eine Strategie beschrieben, welche die Leistungsfähigkeit der Verfahren nach Abschnitt 2.1 verbessert im Falle, dass die statistische Abhängigkeit zwischen den Signalen im Wesentlichen nichtlinear ist. Um den Grundgedanken dieses Ansatzes zu erläutern, wird das Parameterschätzmodell gemäß Bild 7 herangezogen. Eine Signalquelle emittiert das mittels Korrelationsverfahren zu analysierende Signal  $s(\xi)$ . Das Zielsignal  $s(\xi)$  stellt das ideale – d. h. unverzerrte – Sensorsignal dar, wie man es etwa anhand des Modells gemäß Bild 4 berechnen könnte. Der nächste Block modelliert das reale Messsystem, welches  $s(\xi)$  nichtlinear auf die gemessenen Sensordaten  $q(\xi)$  abbilden kann (z. B. wenn Abstandsschwankungen vorliegen):

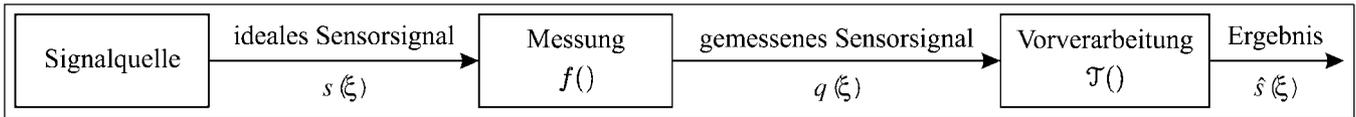
$$q(\xi) = f(s(\xi)). \quad (4)$$

Selbst bei perfekter Korrelation zwischen zwei Signalen  $s_1(\xi)$  und  $s_2(\xi)$ , die von der Signalquelle aus Bild 7 emittiert werden, können Nichtlinearitäten bei deren messtechnischer Erfassung diese derart beeinflussen, dass die resultierenden Signale  $q_i(\xi)$  eine viel geringere Korrelation aufweisen als vor der Abbildung  $f()$ .<sup>1</sup>

Um den Effekt von Nichtlinearitäten auf die Datenaufnahme zu minimieren, wird in einem Vorverarbeitungsschritt die nichtlineare Transformation  $\mathcal{T}\{\}$  angewandt, die im Idealfall die Abbildung Gl. (4) invertieren sollte:

$$\hat{s}(\xi) = \mathcal{T}\{q(\xi)\} \stackrel{!}{=} f^{-1}(q). \quad (5)$$

<sup>1</sup> Im Wesentlichen würde eine lineare Abbildung sich sowohl auf die Verschiebung als auch auf die Breite (und damit auch auf die Amplitude) der Wahrscheinlichkeitsdichtefunktion (WDF)  $p_q(q)$  der Signale  $q_i(\xi)$  auswirken. Für den Fall, dass die Signalamplituden nicht gaußverteilt sind, kann sich eine zusätzliche Verzerrung der WDF ergeben. Kommen jedoch Nichtlinearitäten bei der Messung vor, so könnte die Form der WDF  $p_q(q)$  eine erhebliche Veränderung erfahren, womit niedrige Korrelationswerte die Folge wären.



**Bild 7:** Parameterschätzmodell: Vorverarbeitung als Schätzvorschrift für die Messgröße  $s(\xi)$ .

Leider ist in vielen Fällen keine genaue Kenntnis über  $f()$  verfügbar, sodass sich hier keine geeignete Transformation  $\mathcal{T}\{\}$  angeben lässt. In solchen Fällen kann ein alternativer Weg eingeschlagen werden, bei welchem gewisse Eigenschaften der Statistik erster Ordnung der Signale<sup>2</sup> gezielt manipuliert werden.

Wird  $f()$  durch eine monotone Kurve beschrieben, so lässt sich eine Histogrammtransformation auf die Signale anwenden, um sicherzustellen, dass beide die gleiche Wahrscheinlichkeitsdichtefunktion (WDF) aufweisen und damit die gleiche Statistik erster Ordnung. In solchen Fällen kann man nach dieser Transformation höhere Korrelationswerte erwarten, falls die verglichenen Signale eine hinreichend hohe Ähnlichkeit aufweisen.

In den nächsten Unterabschnitten werden zwei Ansätze behandelt, die eine Egalisierung der Statistik erster Ordnung zweier Signale erlauben. In beiden Fällen werden den zu vergleichenden Signalen gewisse statistische Eigenschaften eingepreßt. Bei der ersten Methode wird hierzu eine verschiebungsinvariante Transformation des globalen Histogrammes durchgeführt. Der zweite Ansatz stellt eine Verfeinerung dieser Strategie dar, bei welcher die lokalen WDF an eine gegebene globale WDFs angepasst werden.

### 3.2.1 Verschiebungsinvariante Transformationen

Um eine verschiebungsinvariante Histogrammtransformation durchzuführen, sind die Amplituden  $q$  des Sensorsignals auf Werte  $\hat{s}(q)$  derart abzubilden, dass  $\hat{s}(q)$  gemäß  $p_{\hat{s}}(\hat{s})$  verteilt ist. Da dazu die kumulativen Verteilungen  $P_{\hat{s}}(\hat{s})$  und  $P_q(q)$  an der Stelle  $\hat{s}(q)$  gleich sein müssen [8], ergibt sich die gewünschte Abbildung wie folgt:

$$P_{\hat{s}}(\hat{s}(q)) = \int_{-\infty}^{\hat{s}(q)} p_{\hat{s}}(\beta) d\beta \stackrel{!}{=} \int_{-\infty}^q p_q(\beta) d\beta = P_q(q)$$

$$\Rightarrow \hat{s}(q) = P_{\hat{s}}^{-1}(P_q(q)). \tag{6}$$

Dabei führt  $P_q(q)$  eine Transformation von  $q$  auf eine im Intervall  $[0; 1]$  gleichverteilte Zufallsvariable durch, welche anschließend durch  $P_{\hat{s}}^{-1}()$  in eine weitere, gemäß  $p_{\hat{s}}(\hat{s})$  verteilte Zufallsvariable abgebildet wird; siehe Bild 8.

Um Gl. (6) auf digitale Signale anzuwenden, muss berücksichtigt werden, dass sowohl die Signalwerte als auch die Orte  $\xi$  diskret sind. Des Weiteren wird ein ergodischer Signalerzeugungsprozess angenommen, sodass die WDF

<sup>2</sup> In diesem Aufsatz wird ausschließlich die Ähnlichkeit zwischen Realisierungen eines Zufallsprozesses – d.h. zwischen Signalen  $s_i(\xi)$  – behandelt. Daher ist die Betrachtung der zweidimensionalen Verbundwahrscheinlichkeitsdichtefunktion nicht möglich.

mit Hilfe eines Histogrammes  $h(q)$  und eines kumulativen Histogrammes  $H(q)$  geschätzt werden kann:

$$h(q) = \frac{1}{|\mathcal{Q}|} \sum_{\xi \in \mathcal{Q}} \delta_{q(\xi)}^q, \quad H(q) = \sum_{\gamma=q_1}^q h(\gamma),$$

$$q \in \{q_1, q_2, \dots, q_Q\}, \quad \delta_a^b = \begin{cases} 1 & \text{für } a = b \\ 0 & \text{für } a \neq b \end{cases},$$

wobei  $\mathcal{Q}$  die diskrete Trägermenge des Signals  $q(\xi)$  bezeichnet, die aus  $|\mathcal{Q}|$  Elementen besteht. Eine Näherung für die in Gl. (6) angegebene Transformation ist:

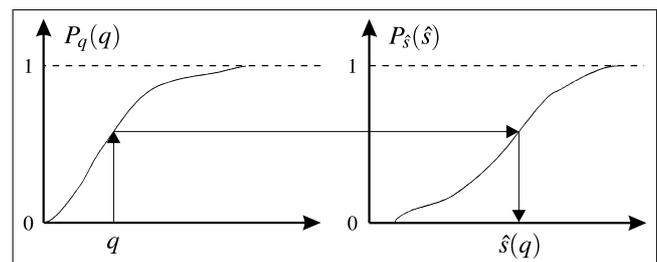
$$\mathcal{T}\{q(\xi); H_{\text{Ziel}}(q)\} = \arg \min_{\gamma \in \{q_1, \dots, q_Q\}} \{|H_{\text{Ziel}}(\gamma) - H(q)|\},$$

wobei  $H_{\text{Ziel}}(q)$  ein willkürlich vorgebares globales kumulatives Histogramm bezeichnet, zu dem alle lokalen Amplitudenverteilungen gleich sein sollen [15]. Im Idealfall sollte die Wahl eines geeigneten kumulativen Histogrammes  $H_{\text{Ziel}}(q)$  unter Berücksichtigung der Statistik des emittierten Signals  $s(\xi)$  getroffen werden. Da die Eigenschaften von  $s(\xi)$  jedoch oftmals nicht bekannt sind, besteht eine gangbare Lösung darin, etwa das Signal  $q_2(\xi)$  derart abzubilden, dass es das kumulative Histogramm  $H(q_1)$  von  $q_1(\xi)$  annimmt und dabei das Signal  $q_1(\xi)$  unverändert lässt:

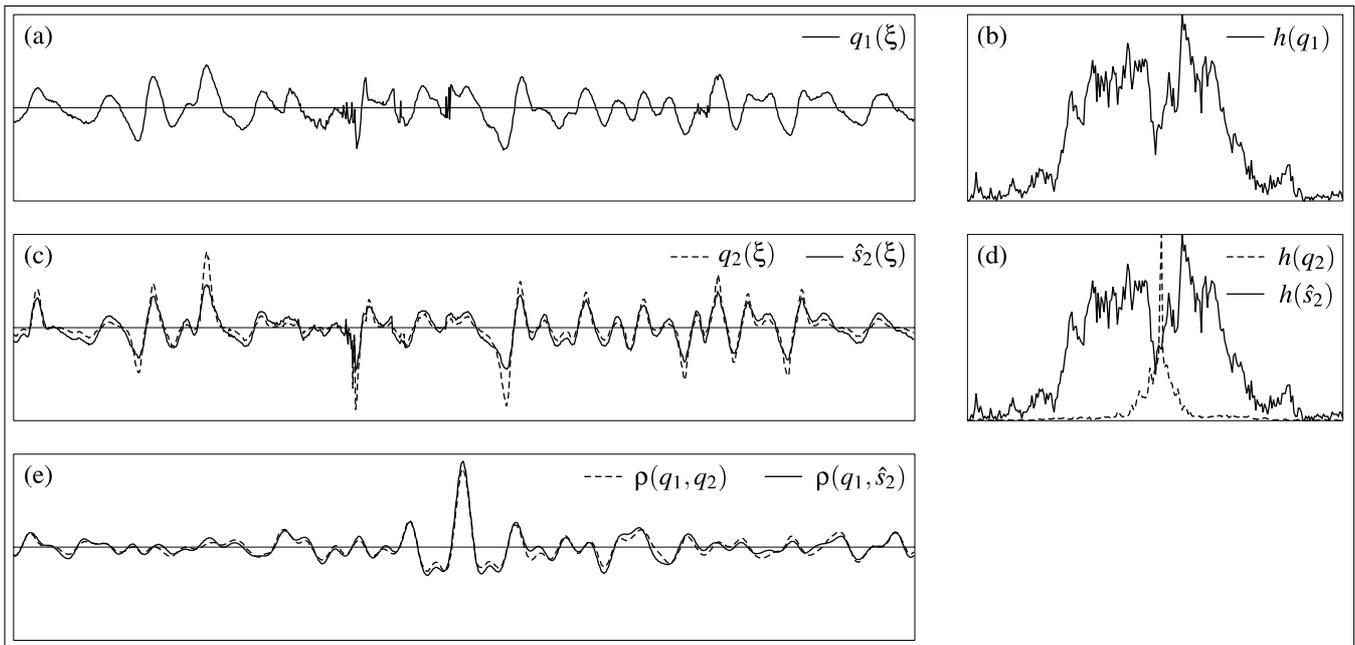
$$\hat{s}_1(\xi) = q_1(\xi), \quad \hat{s}_2(\xi) = \mathcal{T}\{q_2(\xi); H(q_1)\}. \tag{7}$$

Anschließend wird die KKF der Signale gemäß Gl. (1) berechnet.

Anhand von Bild 9 soll die Verbesserung, die mit dieser Vorgehensweise erzielt werden kann, am Beispiel der Erkennung einer Weiche demonstriert werden. Das im digitalen Streckenatlas gespeicherte Weichensignal  $q_1(\xi)$  wurde mit einem Sensorabstand  $z_1 = 120$  mm von der Schienenoberkante aufgenommen. Beim Passieren der gleichen Weiche wurde das Vergleichssignal  $q_2(\xi)$  erfasst, wobei der hier eingestellte Sensorabstand  $z_1 = 80$  mm zu einer nicht-linearen Verzerrung der Signalamplituden führt. Um eine



**Bild 8:** Abbildung der Signalwerte  $q$  auf  $\hat{s}(q)$ .



**Bild 9:** Detektionsergebnisse an einer Weiche: (a) Eintrag  $q_1(\xi)$  des digitalen Streckenatlases, aufgenommen mit  $z_1 = 120$  mm; (b) Histogramm  $h(q_1)$ ; (c) Sensordaten  $q_2(\xi)$  erfasst mit  $z_2 = 80$  mm und transformiertes Signal  $\hat{s}_2(\xi)$ ; (d) Histogramme  $h(q_2)$  und  $h(\hat{s}_2)$  der Sensordaten und des transformierten Signals (normiert auf den Maximalwert); (e) Korrelationsergebnisse:  $\max\{\rho(q_1, q_2)\} = 0,84$ ;  $\max\{\rho(q_1, \hat{s}_2)\} = 0,92$ .

Amplitudenentzerrung durchzuführen, wird das Sensorsignal  $q_2(\xi)$  auf das Signal  $\hat{s}_2(\xi)$  derart abgebildet, dass dessen Histogramm  $h(\hat{s}_2)$  identisch mit dem Histogramm  $h(q_1)$  des Streckenatlas-Signals ist. Durch anschließende Berechnung der empirischen KKF der Signale  $q_1(\xi)$  und  $\hat{s}_2(\xi)$  gemäß Gl. (1) wird eine schnelle Detektion ermöglicht. Die dabei erzielte Verbesserung kann am Maximalwert der KKF abgelesen werden, der in diesem Beispiel um 9% erhöht wird.

### 3.2.2 Verschiebungsvariante Transformationen

Wird gefordert, dass die Statistik erster Ordnung unabhängig von  $\xi$  ist, so ist eine verschiebungsvariante Histogrammtransformation durchzuführen. Dies ist äquivalent mit der Forderung, dass jede lokale WDF  $p_q(q; \xi)$  gleich der globalen WDF  $p_s(\hat{s})$  ist. Daher kann die Histogrammtransformation durch Egalisieren aller lokalen WDFs erfolgen.

Im Gegensatz zur im letzten Abschnitt beschriebenen Prozedur muss in diesem Fall die Abhängigkeit von der Verschiebung berücksichtigt werden. Hier werden daher die Signalamplituden  $q$  auf Werte  $\hat{s}(q; \xi)$  derart abgebildet, dass  $\hat{s}(q; \xi)$  gemäß  $p_s(\hat{s})$  verteilt ist. Folglich müssen die kumulativen Verteilungen  $P_s(\hat{s})$  und  $P_q(q; \xi)$  an der Stelle  $\hat{s}(q; \xi)$  gleich sein:

$$P_s(\hat{s}(q; \xi)) = \int_{-\infty}^{\hat{s}(q; \xi)} p_s(\beta) d\beta \stackrel{!}{=} \int_{-\infty}^q p_q(\beta; \xi) d\beta = P_q(q; \xi) \\ \Rightarrow \hat{s}(q; \xi) = P_s^{-1}(P_q(q; \xi)). \quad (8)$$

Um diese Gleichung auf digitale Signale anzuwenden, müssen nicht nur die Signalamplituden und ihre zugehörigen

Orte  $\xi$  diskretisiert werden. Zusätzlich ist hier ebenfalls lokale Ergodizität für den signalerzeugenden Prozess zu postulieren. Dafür wird eine Nachbarschaftsmenge  $\mathcal{U}$  des Ursprunges  $\xi$  derart definiert, dass lokale Fluktuationen der statistischen Prozesseigenschaften klein genug sind, dass sie innerhalb jeder lokalen Nachbarschaft vernachlässigt werden können:

$$\mathcal{U}(\xi) := \{\chi | \chi = \xi + \epsilon, \epsilon \in \mathcal{U}\}. \quad (9)$$

Andererseits sollte  $\mathcal{U}$  deutlich größer als die größten Details des Signals sein, um deren Verfälschung zu verhindern. Aufgrund der Annahme lokaler Ergodizität können die lokalen WDFs mittels lokaler Histogramme  $h(q; \xi, \mathcal{U})$  und kumulativer lokaler Histogramme  $H(q; \xi, \mathcal{U})$  geschätzt werden:

$$h(q; \xi, \mathcal{U}) = \frac{1}{|\mathcal{U}|} \sum_{\epsilon \in \mathcal{U}} \delta_{q(\xi+\epsilon)}^q, \quad (10)$$

$$H(q; \xi, \mathcal{U}) = \sum_{\gamma=q_1}^q h(\gamma; \xi, \mathcal{U}), \quad (11)$$

wobei  $|\mathcal{U}|$  die Größe der Nachbarschaft  $\mathcal{U}$  bezeichnet. Die folgende Approximation eignet sich zur diskreten Realisierung der Transformation  $\mathcal{T}$ :

$$\mathcal{T}\{q(\xi); H_{\text{Ziel}}(q), \mathcal{U}\} = \arg \min_{\gamma \in \{q_1, \dots, q_Q\}} \{ |H_{\text{Ziel}}(\gamma) - H(q; \xi, \mathcal{U})| \},$$

wobei  $H_{\text{Ziel}}(q)$  das einzuprägende globale kumulative Histogramm bezeichnet.

Die in Unterabschnitt 3.2.1 erläuterte Problematik zur Wahl eines geeigneten Zielhistogrammes  $H_{\text{Ziel}}(q)$  kann auch auf dieses Verfahren übertragen werden, weshalb eine analoge Vorgehensweise für den Fall, dass kein Wissen über die

Signalstatistik a priori verfügbar ist, Anwendung finden kann:

$$\hat{s}_1(\xi) = q_1(\xi), \quad \hat{s}_2(\xi) = \mathcal{T}\{q_2(\xi); H(q_1), \mathcal{U}\}. \quad (12)$$

## 4 Zusammenfassung

Der Beitrag behandelt eine Methode zur Ortung im spurgebundenen Verkehr, die auf der Erkennung streckenspezifischer Charakteristika beruht. Hierbei zeichnen am Fahrzeug angebrachte Sensoren Signale der Strecke auf, die mit Hilfe von Korrelationsverfahren mit den Daten eines Streckenatlases verglichen werden. Um eine geschwindigkeitsunabhängige Detektion zu ermöglichen, müssen die gemessenen Zeitsignale auf Basis einer Geschwindigkeitschätzung in Ortssignale umgewandelt werden. Aufgrund von statistischen Fehlern bei dieser Schätzung kann jedoch eine unerwünschte Dehnung der Abszisse auftreten, die unter Umständen zu deutlich niedrigeren Korrelationswerten führt. Probleme ergeben sich auch bei einer nichtlinearen Verzerrung der Signalamplituden. In der Praxis hat sich in diesen Fällen die herkömmliche Kreuzkorrelationsfunktion als unzureichend herausgestellt, da sie lediglich lineare Ähnlichkeiten erfasst.

In diesem Aufsatz wird eine Erweiterung der Korrelationsmethodik vorgestellt, welche auch auf nichtlinear verzerrte Signale anwendbar ist. Zur Erkennung von nichtlinear amplitudenverzerrten Signalen werden zwei Ansätze präsentiert, die auf Histogrammtransformationen basieren. Abszissenverzerrungen können zusätzlich mit Hilfe einer zunächst unbekanntem Korrekturfunktion berücksichtigt werden, die sich mittels einer Energieminimierungsmethode bestimmen lässt. Bei beiden Ansätzen zeigt sich eine deutlich höhere Robustheit als bei herkömmlichen Verfahren. Damit kann die vorgestellte Methodik bei der Ortung von Schienenfahrzeugen eingesetzt werden, aber auch in anderen Bereichen der Mustererkennung.

## Literatur

- [1] E. Abbott, D. Powell, „Land-vehicle navigation using GPS“, *Proceedings of the IEEE* **87** (1), p. 145–162, 1999.
- [2] G. Bikker, „Integration von Sensorverfahren für eine fahrgaugautarke Ortung im spurgebundenen Verkehr“, In: *Sensoren und Meßsysteme 2000*, VDI-Berichte 1530, S. 911–920, VDI Verlag, Düsseldorf, 2000.
- [3] G. Bikker, K.-A. Klinge, M. Schroeder, E. Schnieder, „Concepts of an intelligent route atlas for localisation in guided traffic“, In: *Proceedings of the 4th International Conference on Vehicle Navigation*, Hannover, 1998.
- [4] T. Engelberg, D. vom Stein, R. Zeitler, „Berührungslose Geschwindigkeitsmessung fester Oberflächen“, *Technisches Messen* **64** (10), S. 380–386, 1997.
- [5] T. Engelberg, *Geschwindigkeitsmessung von Schienenfahrzeugen mit Wirbelstrom-Sensoren*, Fortschritt-Berichte VDI, Reihe 8, Nr. 896, VDI Verlag, Düsseldorf, 2001.
- [6] T. Engelberg, F. Mesch, F. Puente León, „Bordautonome Identifikation von Eisenbahnweichen mit Wirbelstrom-Sensoren“, In: *Sensoren und Meßsysteme 2000*, VDI-Berichte 1530, S. 891–900, VDI Verlag, Düsseldorf, 2000.
- [7] A. Geistler, „Train location with eddy current sensors“, In: *Computers in Railways VIII*, J. Allen, R.J. Hill, C.A. Brebbia, G. Sciutto, S. Sone (Hrsg.), S. 1053–1062, WIT Press, Southampton, 2002.
- [8] R.C. González, R.E. Woods, *Digital Image Processing*, Addison-Wesley, Reading, 1993.
- [9] S. Kutscha, *Statistische Bewertungskriterien für die Entropieanalyse dynamischer Systeme*, VDI Verlag, Düsseldorf, 1989.
- [10] H. Laqua, *Berührungslose Geschwindigkeitsmessung von Straßen- und Schienenfahrzeugen mit Mikrowellensensoren*, Fortschritt-Berichte VDI, Reihe 8, Nr. 543, Düsseldorf, 1996.
- [11] D. Leinhos, *Analyse und Entwurf von Ortungssystemen für den Schienenverkehr mit strukturierten Methoden*, Fortschritt-Berichte VDI, Reihe 12, Nr. 296, Düsseldorf, 1996.
- [12] F. Mesch, F. Puente León, T. Engelberg, „Train-based location by detecting rail switches“, In: *Computers in Railways VII*, J. Allen, R.J. Hill, C.A. Brebbia, G. Sciutto, S. Sone (Hrsg.), S. 1251–1260, WIT Press, Southampton, 2000.
- [13] A. Papoulis, *Probability, random variables and stochastic processes*, McGraw-Hill, New York, 1991.
- [14] F. Puente León, *Automatischer Vergleich von Schußwaffen*, Fortschritt-Berichte VDI Reihe 8, Nr. 787, VDI Verlag, Düsseldorf, 1999.
- [15] F. Puente León, M. Heizmann, „Strategies to detect nonlinear similarities by means of correlation methods“, In: *Intelligent Robots and Computer Vision XX: Algorithms, Techniques, and Active Vision*, D.P. Casasent (Hrsg.), Proceedings of SPIE, Vol. 4572, S. 513–524, 2001.
- [16] F. Puente León, „Komplementäre Bildfusion zur Inspektion technischer Oberflächen“, *Technisches Messen* **69** (4), S. 161–168, 2002.

---

**Dr.-Ing. T. Engelberg**, Robert Bosch GmbH, Zentralbereich Forschung und Vorausentwicklung Systeme 2, Telematik, Funk- und Bildverarbeitende Systeme, Robert-Bosch-Str. 200, D-31139 Hildesheim, Tel.: +49-5121-49 5008, E-Mail: Thomas.Engelberg@de.bosch.com

**Dr.-Ing. F. Puente León**, Institut für Mess- und Regelungstechnik (Prof. Dr.-Ing. C. Stiller), Universität Karlsruhe (TH), Engler-Bunte-Ring 21, D-76131 Karlsruhe, Tel.: +49-721-608 2341, E-Mail: puente@mrt.uka.de