



MASTERARBEIT

Herr
Alexander Oehler

**Entwicklung einer Methode zur
Einzelfehlererkennung und
-klassifikation im Gleisoberbau**

2014

Fakultät **Mathematik/Naturwissenschaften/Informatik**

MASTERARBEIT

Entwicklung einer Methode zur Einzelfehlererkennung und -klassifikation im Gleisoberbau

Autor:

Alexander Oehler

Studiengang:

Diskrete und Computerorientierte Mathematik

Seminargruppe:

ZD11

Erstprüfer:

Prof. Dr. Thomas Villmann

Zweitprüfer:

Dipl.-GeoInf. Christian Linder

Mittweida, April 2014

Bibliografische Angaben

Oehler, Alexander: Entwicklung einer Methode zur Einzelfehlererkennung und -klassifikation im Gleisoberbau, 59 Seiten, 28 Abbildungen, Hochschule Mittweida, University of Applied Sciences, Fakultät Mathematik/Naturwissenschaften/Informatik

Masterarbeit, 2014

Satz: \LaTeX

Referat

Die Qualitätsanforderungen an den Gleisoberbau steigen mit zunehmenden Fahrtgeschwindigkeiten und größer werdender Belastung. Umso wichtiger ist es Unregelmäßigkeiten und Fehler im Gleis frühzeitig zu identifizieren und zu erkennen. Für die Analyse aufgezeichneter Messdaten eignen sich vor allem Methoden aus dem Bereich der Computational Intelligence, welche durch selbstlernende und Prototyp-basierende Algorithmen Muster erkennen können. Diese Möglichkeit bestimmte Datenverläufe wieder zu erkennen und zu klassifizieren, bietet in der Bahnindustrie sowohl wirtschaftliche als auch sicherheitsrelevante Vorteile.

I. Inhaltsverzeichnis

Inhaltsverzeichnis	I
Abbildungsverzeichnis	II
Tabellenverzeichnis	III
Abkürzungsverzeichnis	IV
1 Einleitung	1
1.1 Einführung in die Thematik	1
1.2 AUTOMAIN	2
1.3 Zielstellung und Motivation	3
1.4 Aufbau der Arbeit	4
2 Bahntechnische Grundlagen	5
2.1 Gleisoberbau	5
2.2 Qualitätsbetrachtungen	7
2.3 Fehlertypen	9
2.4 Normen und Richtlinien	13
3 Mathematische Grundlagen	17
3.1 Diskrete Fourier-Transformation	17
3.2 Diskrete Wavelet-Transformation	18
3.3 Selbstlernende Klassifizierer	19
3.3.1 Vorbetrachtung	19
3.3.2 Learning Vector Quantization und Generalized Learning Vector Quantization	21
3.3.3 Generalized Matrix Learning Vector Quantization	23
3.3.4 Support Vector Machine	26
4 Datenverarbeitung und -analyse	31
4.1 Datenursprung	31
4.2 Datenvorverarbeitung	32
4.3 Beschleunigungsdaten	33
4.4 Versatzdaten	39
4.5 Statistische Auswertung	44
4.6 Vergleich und Auswertung der Ergebnisse	46
4.7 Zusammenfassung der Methode	49
5 Schlussbetrachtung	51
5.1 Ausblick und Limitierung der Arbeit	51
5.2 Fazit	52
A Beispiel Wavelets	53
Literaturverzeichnis	55

II. Abbildungsverzeichnis

2.1	Aufbau des Gleisoberbaus	5
2.2	Lastverteilung auf den Schwellen	6
2.3	Bildung einer Hohllage	6
2.4	Schematischer Gleisqualitätsverlauf	8
2.5	Übersicht der Fehlertypen	9
2.6	Modellhafter sinusförmiger Gleislagefehler	10
2.7	Gleis mit vertikalen Fehlern	12
2.8	Einzelfehler in der Gleislage	12
3.1	Rasterung der Zeit-Frequenz-Ebene	19
3.2	Schematisches Beispiel eines 3-Klassen Problems	21
3.3	Klassifizierung mittels Support Vector Machine	27
3.4	Zusammenhang der metrischen Räume unter Verwendung eines Kernels	29
4.1	Datenverarbeitung der CTM Installation an einem ICE 2	31
4.2	Übereinandergeschobene Messdaten	33
4.3	Ausschnitt einer Weiche (Beschleunigungsdaten)	34
4.4	Reduzierung der Dimensionen auf 128, 256 und 512 Datenpunkte	35
4.5	Frequenzspektrum mit 128 Koeffizienten	36
4.6	Ergebnis des GMLVQ mit Fourierkoeffizienten	37
4.7	2-Level Wavelet Dekomposition	38
4.8	Spektralanalyse des Beschleunigungssignals	39
4.9	Ausschnitt einer Weiche (Versatzdaten)	40
4.10	Reduzierung der Dimension auf 128 Datenpunkte	41
4.11	Gemittelte Versatzdaten der Weichen und Nicht-Weichen	42
4.12	Frequenzspektrum der Weichen und Nicht-Weichen	42
4.13	Ergebnis des GMLVQ mit 40 Fourierkoeffizienten	43
4.14	Level 2 Wavelet Dekomposition einer Weiche	44
4.15	Häufigkeiten gefundener Weichen bei 9 Messreihen	45
4.16	Schematischer Ablauf der Methode	50

III. Tabellenverzeichnis

2.1 Werte für Längshöhenfehler nach EN 13848	14
2.2 Werte für Längshöhenfehler nach KoRil 820.2001	15
4.1 Klassifikationsergebnisse der unverarbeiteten Beschleunigungsdaten (BD) und Versatzdaten (VD) in Abhängigkeit der Intervalllänge	46
4.2 Klassifikationsergebnisse des Frequenzspektrums der Beschleunigungsdaten (BD) und Versatzdaten (VD) in Abhängigkeit der Intervalllänge	47
4.3 Klassifikationsergebnisse der Waveletkoeffizienten der Beschleunigungsdaten (BD) und Versatzdaten (VD) in Abhängigkeit der Intervalllänge	47
4.4 Klassifikationsergebnisse in Abhängigkeit des gewählten Mother Wavelets bei einer Intervalllänge von 64 Metern mit Versatzdaten	48
4.5 Klassifikationsergebnisse des GMLVQ in Abhängigkeit der Anzahl der Prototypen pro Klasse	48

IV. Abkürzungsverzeichnis

- AL Aufmerksamkeitsgrenze, Seite 13
CTM Continuous Track Monitoring, Seite 31
DB AG Deutsche Bahn AG, Seite 1
DLR Deutsches Zentrum für Luft- und Raumfahrt e.V., Seite 39
EN Europäische Norm, Seite 13
GLVQ Generalized Learning Vector Quantization, Seite 22
GMLVQ Generalized Matrix Learning Vector Quantization, Seite 23
GPS Global Positioning System, Seite 3
IAL Sicherheitsgrenze, Seite 13
IL Eingriffsgrenze, Seite 13
KoRil Konzernrichtlinie, Seite 13
LVQ Learning Vector Quantization, Seite 21
RBF Radial Basis Function, Seite 28
SVM Support Vector Machine, Seite 26

1 Einleitung

1.1 Einführung in die Thematik

Das System Gleis wurde in den letzten Jahrzehnten stets weiterentwickelt und muss immer höher werdenden Ansprüchen gerecht werden. Im Jahr 2012 wurden laut Angaben der Deutsche Bahn AG (DB AG) täglich ca. 5,4 Millionen Kunden und 670.000 Tonnen Güter über das rund 33.500 Kilometer lange Streckennetz befördert¹. Bei über 30.000 Zugfahrten pro Tag werden vor allem die Bahnschienen unterschiedlichsten Kräften ausgesetzt. Neben den exogenen Kräften, wie Wind und Wasser, die zur Verwitterung führen, tragen hauptsächlich die höher werdenden Geschwindigkeiten und steigenden Achslasten der Züge zur Abnutzung und Verformung und somit zum Auftreten von Unregelmäßigkeiten im Gleisoberbau bei. Die Qualität und die damit verbundene Instandhaltung, Erkennung und Klassifikation von Abweichungen spielt dementsprechend eine zunehmend größere Rolle. Die Problematik der Qualitätsbestimmung beginnt bereits bei der Wahl der passenden Fehlermessmethode und endet bei der entsprechenden Auswertung der aufgezeichneten Daten. Erschwerend kommt die Anzahl vielfältiger Fehlerarten hinzu, die angepasste Messverfahren voraussetzt. Immer mehr Aufmerksamkeit wird dabei auf eine frühzeitige Identifikation und Charakterisierung der Fehler gelegt, um so die zunehmende Verschlechterung der Qualität zeitlich zu überwachen und möglichst noch vor Eintritt der Schadgrenzen instandzuhalten. Die DB Netz AG investiert laut eigenen Angaben pro Jahr über eine Milliarde Euro in die Inspektion, Wartung, Entstörung und Instandsetzung der Schieneninfrastruktur². Dies macht deutlich wie wichtig die Qualität des Fahrweges ist, um unter anderem einen hohen Fahrkomfort und möglichst hohe Streckenverfügbarkeit zu gewährleisten.

Neben den reinen technischen Möglichkeiten Fehler im Gleisoberbau zu erkennen, spielt die Verarbeitung und nachträgliche Analyse der gesammelten Daten eine immer größere Rolle. Verfahren aus der Signalverarbeitung bilden hierfür ein sehr gutes Hilfsmittel um wichtige Informationen aus aufgezeichneten Zeitverläufen zu extrahieren. Mathematische Methoden aus dem Bereich der Computational Intelligence bieten mit selbstlernenden Algorithmen eine gute Grundlage zur Mustererkennung und Klassifikation in großen Datensätzen. Durch die Kombination der Methoden der Signalanalyse, der Prototyp-basierenden Algorithmen und der Daten über die Qualität des Gleises, besteht somit die Möglichkeit Fehler und wiederauftretende Muster zu erkennen und zu klassifizieren.

¹ Kennzahlen 2012 des DB-Konzerns

² Instandhaltung - Kernkompetenz der DB Netz AG

1.2 AUTOMAIN

Die vorliegende Arbeit entstand im Rahmen des durch das 7. Forschungsprogramm der EU geförderten Projektes AUTOMAIN (Augmented Usage of Track by Optimisation of Maintenance, Allocation and Inspection of railway Networks), welches von 2011 bis 2014 stattfand. Die Grundidee des Projektes ist es die Instandhaltung und Wartung des Fahrweges, dabei insbesondere des Oberbaus und der Weichen, zu verbessern, so dass es einen Eingriff in die Infrastruktur nur dann gibt, wenn es wirklich notwendig und erforderlich ist. Die durch die Instandhaltungsmaßnahmen hervorgerufenen Sperrzeiten des Gleises, unter Umständen auch des Nachbargleises, stellen einen Eingriff in den Betriebsablauf dar. Dieser Ansatz der zustandsorientierten Instandhaltung unterscheidet sich von der bisherigen Instandhaltungsstrategie, die intervallbasierte, zeitlich punktuelle Inspektionen vorsieht und anhand dieser Informationen eine Instandsetzung auslöst. Um jedoch zustandsorientiert instandhalten zu können, müssen folglich auch Daten (konkret: Messdaten) über den Anlagenzustand vorliegen. Dazu ist eine kontinuierliche Datenerfassung und Datenauswertung notwendig. Speziell zur Datenauswertung soll die vorliegende Arbeit einen Beitrag leisten. Um diese Innovationen schrittweise vorzunehmen, werden im AUTOMAIN Projekt folgende Ansätze verfolgt [Aut01]:

- *Erhöhte Zuverlässigkeit:* Kann erreicht werden durch effektivere Wartung in Verbindung mit verbesserten Kontroll- und Überwachungsmöglichkeiten.
- *Erhöhte Verfügbarkeit:* Reduzierung der Sperrzeiten durch Automatisierung und Optimierung der Instandhaltungsplanung und mittels Beschleunigung der Wartungsarbeiten.
- *Verbesserte Wartbarkeit:* Umsetzbar durch eine Reduzierung der Zeit, die notwendig ist für die Installation und Wartung der Infrastruktur durch Verwenden neuer Technologien.
- *Erhöhtes Datenvolumen:* Die durch die neuen Methoden des Monitorings aufgezeichneten Daten bilden eine wesentlich bessere Grundlage um Erkenntnisse über den gesamten Anlagenzustand zu zulassen und neueste mathematische Methoden aus dem Bereich der Klassifizierung anzuwenden.
- *Verbesserte Wirtschaftlichkeit:* Die Kombination der oben aufgezeigten Ansätze führt insgesamt zu einer erhöhten Wirtschaftlichkeit durch verringerte Kosten bei gleichzeitig verbesserter Effektivität.

Um dies zu realisieren, werden die neusten Technologien aus anderen Industriezweigen, wie der Automobilbranche oder der Luft- und Raumfahrt, entsprechend adaptiert, beziehungsweise weiterentwickelt und verbessert. Vor allem die automatisierte Streckeninspektion mit neuartigen Systemen kann den Aufwand und die Zeit für die Instandhaltung signifikant reduzieren.

1.3 Zielstellung und Motivation

Ziel dieser Arbeit ist es, ein Verfahren zu entwickeln mit dem die aufgezeichneten Daten über die Qualität des Gleises analysiert und ausgewertet werden können. Im Vordergrund steht dabei die Einzelfehlererkennung- und Klassifikation die am Beispiel von Weichen gezeigt werden soll. Daraus ergeben sich folgende wiederkehrende Aufgaben bzw. Fragestellungen:

- In welcher Art und Weise müssen die vorliegenden Rohdaten verarbeitet werden um sinnvolle Resultate daraus herzuleiten?
- Welche mathematischen Algorithmen sind dafür sinnvoll?
- Wie sind die Ergebnisse zu interpretieren und was lässt sich daraus schlussfolgern?

Die Motivation für die Entwicklung einer solchen Methode liegt auch in der Verbesserung der Wirtschaftlichkeit begründet. Algorithmisches Erkennen von Fehlern führt zu besseren und effektiveren Instandhaltungsmaßnahmen und kann somit größere materielle und finanzielle Schäden vorbeugen. Für die einfache Erkennung von Einzelfehlern bezüglich der Gleislage existiert momentan eine Verfahrensweise, die jedoch nur die Amplitude eines Fehlers und die Überschreitung eines Grenzwertes betrachtet. Eine Methode zur Untersuchung und Beurteilung der Fehlerform existiert bislang nicht, denn neben der Amplitude ist auch der Verlauf und die damit verbundene Gestalt eines Fehlers von hohem Interesse. Ein erster Ansatz der in diese Richtung zielt, wurde in [Wol13] von K. U. Wolter und F. Erhard vorgestellt, bei dem Gleislageabweichungen unter der Verwendung von Wavelets analysiert worden sind. Mit der vorliegenden Arbeit soll gezeigt werden, dass es mittels mathematischer Algorithmen aus der Signalverarbeitung und der Computational Intelligence möglich ist potenzielle Fehler, beziehungsweise immer wiederkehrende Muster in den Daten über die Gleisqualität zu erkennen. Vor allem in Kombination mit dem Prognoseverfahren zur Gleislageabweichung bei Einzelfehlern, welches von C. Linder in [Lin14] veröffentlicht wurde, ergibt sich ein innovatives und neuartiges Verfahren, welches nicht nur Einzelfehler erkennt, sondern auch deren Qualitätsverlauf prognostizieren kann.

Die dafür verwendeten Daten wurden von der Deutsche Bahn AG im Rahmen des AUTOMAIN Projektes zur Verfügung gestellt. Das Verhalten des Gleises einer ca. 80 km lange Bahnstrecke wurde dabei an 13 Tagen aufgezeichnet, zusätzlich wurde die Position des Schienenfahrzeugs mittels Global Positioning System (GPS) erfasst. An zwei Radsätzen wurde dabei jeweils an beiden Seiten die Beschleunigung des jeweiligen Rades in vertikaler Richtung gemessen. Da die Deutsche Bahn AG keine Aussage über potentielle Fehler auf dieser Strecke trifft, wurden als Beispiel für sich wiederholende Unregelmäßigkeiten die Verläufe von Weichen näher betrachtet und als Fehler angenommen. Die exakte Position der Weichen wurde dem Weichenverzeichnis entnommen. Für die Entwicklung dieser Methode zur Einzelfehlerbeurteilung und Klassifikation ist es dabei irrelevant, dass Weichenüberfahrten im Prinzip keine Fehler sind. Da jedoch

die Möglichkeit bestand, anhand eines Weichenverzeichnisses die genaue Position von Weichen zu ermitteln, konnten die Muster, die bei der Überfahrt entstehen, isoliert und klassifiziert werden. Anhand der Messdatencharakteristik einer Weichenüberfahrt soll gezeigt werden, dass die Methode valide ist und auf jeden anderen Fehler, sofern dessen Messdatencharakteristik bekannt ist, übertragen werden kann.

1.4 Aufbau der Arbeit

Zunächst werden in Kapitel 2 die wichtigsten Grundlagen aus bahntechnischer Sicht erarbeitet. Neben dem Aufbau des Oberbaus werden die wichtigsten Fehlertypen und die entsprechenden Normen und Richtlinien dargestellt. In Kapitel 3 werden die mathematischen Grundlagen formuliert, die für die nachfolgenden Kapitel vorausgesetzt werden. Neben den selbstlernenden Algorithmen werden auch Fourier- und Wavelet-Transformation kurz beschrieben. Die komplette Datenverarbeitung wird in Kapitel 4 dargestellt und bildet die Schnittstelle zwischen den Algorithmen aus Kapitel 3 und der Bahntechnik aus Kapitel 2. Das Ergebnis ist die daraus resultierende Methode zur Einzelfehlererkennung. Das letzte Kapitel ist eine Zusammenfassung der Arbeit und gibt einen Ausblick und Ansätze für eine weitere Verwendung der entwickelten Methode.

2 Bahntechnische Grundlagen

In diesem Kapitel werden die Grundlagen aus bahntechnischer Sicht beschrieben. Im Vordergrund steht dabei das System Gleis und die damit verbundenen Qualitätsbe trachtungen. Neben verschiedenen Normen und Richtlinien werden auch die unterschiedlichen Fehlertypen erläutert. Die Informationen stammen aus [Lic09], [Lic10] und [Vei06].

2.1 Gleisoberbau

Die Grundlage für den Bahnverkehr bildet das Gleis, welches als Fahrbahn für Schienenfahrzeuge dient. Das Gleis soll dabei:

- die Fahrzeuge entgleisungssicher führen,
- die vertikalen, horizontalen und lateralen Fahrzeugkräfte aufnehmen,
- diese Kräfte über das Schotterbett in den Untergrund ableiten,
- einen guten Fahrkomfort sicherstellen und
- eine hohe Verfügbarkeit für die Produktion gewährleisten [Lic10, S. 21].

Die meisten Gleistrassen bestehen entweder aus dem typischen Querschwellenoberbau mit Schotterbettung oder sind als feste Fahrbahn konstruiert, wie es bei vielen Hochgeschwindigkeitsstrecken der Fall ist. Der Aufbau des Gleises bei der Schotterbauweise lässt sich in zwei Bereiche einteilen, der Oberbau und dem darunterliegenden Unterbau und Untergrund. Der Oberbau, wie in Abbildung 2.1 dargestellt, besteht für alle eingeschotterten Gleisbauarten aus den Schienen, den Schwellen und deren Befestigung und aus einem dauerstabilen Schotterbett, sowie aus den beiden Schutzschichten: Planumsschutzschicht und Frostschutzschicht [Lic10].

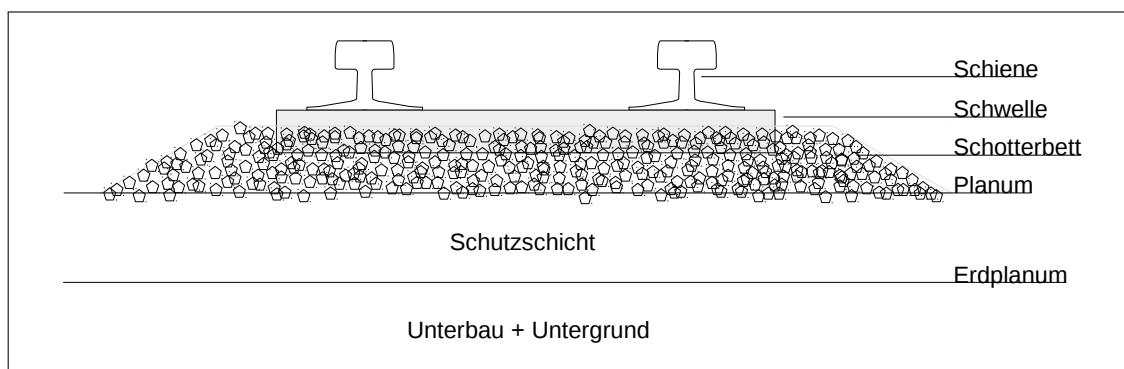


Abbildung 2.1: Aufbau des Gleisoberbaus nach [Bae08]

Die Schienen werden mittels geeigneter Befestigungsmittel auf den Schwänen fixiert und bilden somit einen starren Rahmen. Die Schwänen, bestehend aus Holz, Stahl oder Stahlbeton, dienen vor allem der Herstellung und Beibehaltung der Spurweite, sowie der Erhöhung des Querverschiebewiderstandes, der dafür sorgt, dass laterale Kräfte (Brems- und Beschleunigungsvorgänge) und horizontale Kräfte (Seitenbeschleunigungen der Fahrzeuge) nicht dazu führen, dass das Gleis die Soll-Lage verlässt. Eine der Hauptaufgaben des Gleisrostes ist es also, die vertikal wirkenden Kräfte (Radaufstands- kraft) möglichst gleichmäßig in den Untergrund weiterzuleiten [Lic10].

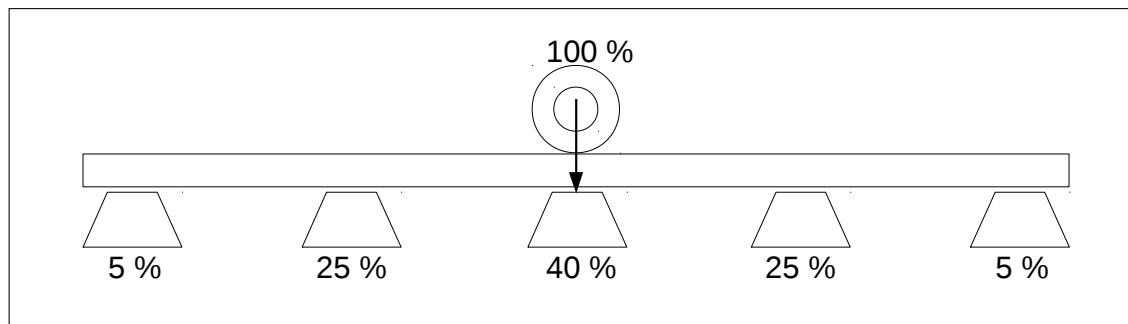


Abbildung 2.2: Lastverteilung auf den Schwänen nach [Lic10]

Über die Schienendurchbiegung wird die Radlast auf die Schwänen verteilt, Abbildung 2.2 stellt dies schematisch dar. Im Normalfall übernimmt die Schwelle auf der das Rad steht 40% der Radlast, die beiden Nachbarschwänen zusammen 50% und die beiden darauf folgenden Schwänen insgesamt 10%. Die Verteilung der Radlast auf die einzelnen Schwänen hängt vom Schwänenabstand, der Biegesteifigkeit der Schienen und der Bettungszahl ab [Lic10, S. 197]. Neben dem Dämpfen der Schwingungen der Schienen werden außerdem die wirkenden Kräfte auf die Bettung verteilt und weitergeleitet. Dieser dadurch entstehende Druck soll möglichst gleichmäßig durch das Schotterbett in den Untergrund übertragen werden. Dieser Druck begünstigt zudem den Abrieb der Schottersteine, wodurch sogenannten Hohllagen entstehen können [Bae08], wie es in Abbildung 2.3 dargestellt ist.

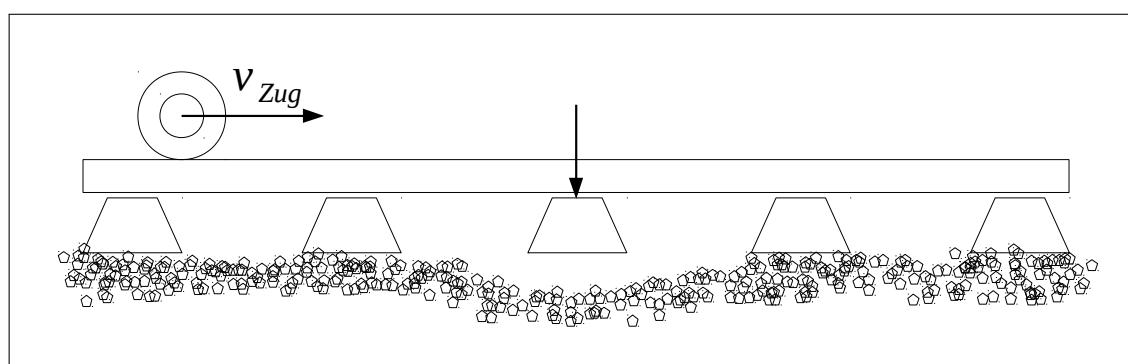


Abbildung 2.3: Bildung einer Hohllage nach [Bae08]

Solche Hohllagen entstehen meist durch schlechten Wasserabtransport und durch Abnutzung des Schotters. Ein Problem für die Instandhaltung und Inspektion ist, dass Hohllagen durch einfache Besichtigung der Strecke kaum erkannt werden können. Die Steifigkeit der Schienen und die daran befestigten Schweller führen dazu, dass ein solcher Fehler erst unter Last, bei der Überfahrt eines Schienenfahrzeugs, identifiziert werden kann. Durch die vertikal wirkenden Kräfte verbiegen sich die Schienen nach unten und drücken somit die Schwelle in den Hohlraum. Diese Auslenkung kann dann mittels geeigneter Sensorik erfasst und vermessen werden.

Eine frühzeitige Erkennung solcher Fehler im Gleis und anderer Einzelfehler, wie beispielsweise Schienenbrüche, ist die Grundlage für eine effektive Instandsetzung, verbunden mit einer Gewährleistung des Fahrkomforts und der Sicherheit. Dies lässt erkennen, dass vor allem der Zustand des Schotterbetts in dem System Gleis eine wichtige Rolle spielt und oft die Ursache für die Entstehung von Einzelfehlern ist.

2.2 Qualitätsbetrachtungen

Für die Qualität im Gleisoberbau sind zwei Faktoren maßgeblich: Investition bzw. Erneuerung und Instandhaltung. Wichtig dabei ist das Schaffen einer adäquaten Ausgangsqualität und das Übersetzen dieser Qualität in eine entsprechende Liegedauer. Drei Eigenschaften sorgen dafür, dass sich der Oberbau von anderen technischen Systemen deutlich unterscheidet [Vei06]:

- Eine lange Nutzungsdauer mit rund 25 bis 50 Jahren,
- der Oberbau reagiert auf unpflegliche Behandlung relativ lange gutmütig und
- das Gleis reagiert zeitversetzt und unumkehrbar auf diese Behandlung mit einer Reduktion der Liegedauer.

Diese Eigenschaften haben zur Folge, dass kurzfristige Einsparungen zu Lasten der Qualität erst mittel- bis langfristig negative Auswirkungen zeigen. Das bedeutet außerdem, dass Maßnahmen zur Verbesserung der Qualität auch erst nach einem langfristigen Zeitraum beurteilt werden können. Wirtschaftlich gesehen ergeben sich Kosten für den Lebenszyklus des Gleises aus Investition bzw. Reinvestition, planbarer und nicht planbarer Instandhaltung und betrieblichen Behinderungen infolge unzureichender Qualitäten.

Mathematisch kann der Zusammenhang zwischen dem Gleis und seiner Qualität in zwei Formen dargestellt werden [Lic10, S. 407], einmal als exponentielle Definition:

$$Q = Q_0 \cdot e^{k \cdot M} \quad (2.1)$$

und als lineare:

$$Q = Q_0 + k \cdot M \quad (2.2)$$

mit

- Q aktuelle Gleisqualität [mm],
- Q_0 Anfangsqualität [mm],
- k Verschlechterungsrate [mm/Mio t],
- M Betriebsbelastung [Mio t].

Die Anfangsqualität Q_0 ist einer der wichtigsten Faktoren im Gleisqualitätsverlauf, denn je höher Q_0 ist, desto länger dauert es bis die Eingriffsschwelle Q_E erreicht ist, d.h. es existiert ein größerer Abnutzungsvorrat. Erreicht werden kann eine hohe Ausgangsqualität durch optimale Arbeitstechnologien und Arbeitsmethoden und durch hochwertige Gleisbaumaschinen und Gleisbaumaterialien, Q_0 ist also das Resultat der Investitionen. Da die Ausgangsqualität durch spätere Maßnahmen nicht mehr erhöht werden kann, ist dies ein Qualitätslimit für die gesamte Liegedauer des Gleises [Vei06]. Abbildung 2.4 zeigt, dass diese untere Grenze nicht unterschritten werden kann, durch angebrachte Instandhaltung kann jedoch ein ähnlicher Wert erreicht werden, dessen Differenz mit steigender Betriebsbelastung auch größer wird.

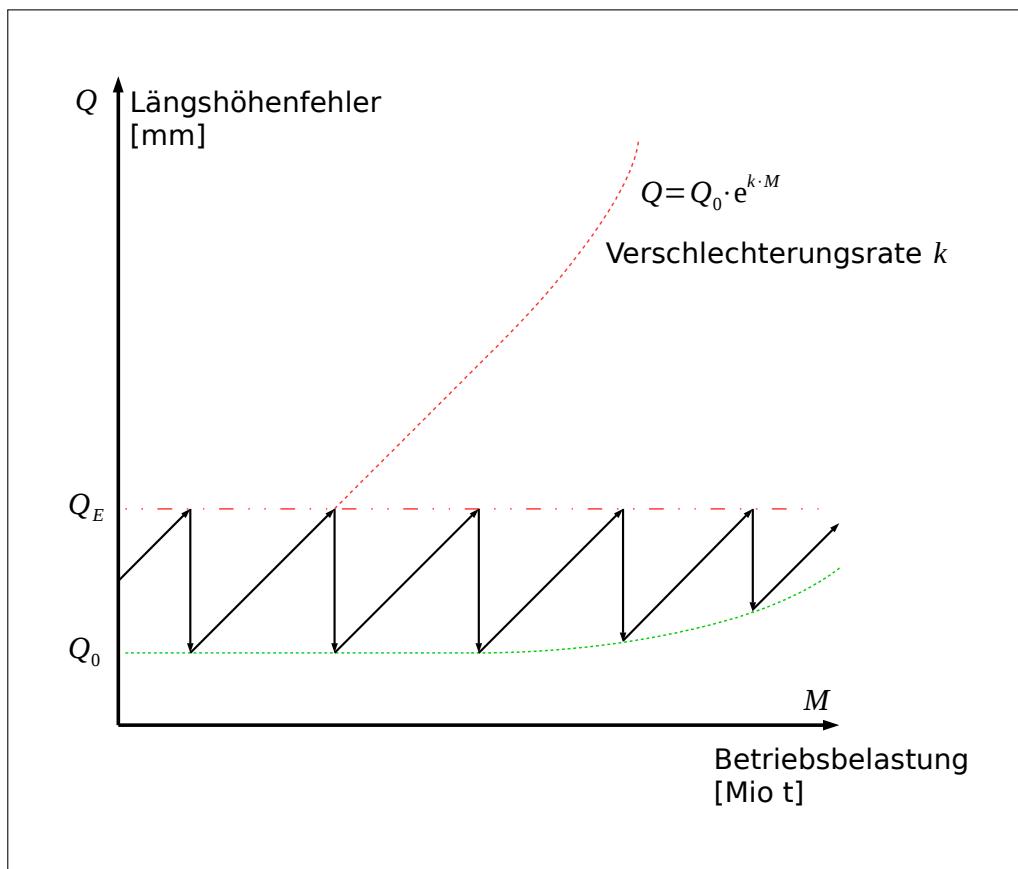


Abbildung 2.4: Schematischer Gleisqualitätsverlauf nach [Lic07]

Die Verschlechterungsrate k entspricht der Steigung der Kurve, für überbeanspruchte Gleise geht der lineare Verlauf dabei in einen exponentiellen über, was eine Kombi-

nation aus (2.1) und (2.2) darstellt. Je flacher die Steigung verläuft, umso größer sind die Instandhaltungsintervalle und umso geringer ist der damit verbundene Instandhaltungsaufwand, was sich letztendlich auch positiv auf die Wirtschaftlichkeit auswirkt. Die Verschlechterungsrate ist durch folgende Parameter beeinflussbar [Lic10, S. 410]:

- Ein größeres Trägheitsmoment der Schiene verlangsamt den Verfall,
- ein Verkleinern des Schwellenabstandes wirkt sich positiv aus,
- enge Kurvenradien haben einen nachteiligen Effekt,
- homogen verdichteter Untergrund ist ein wichtiger Faktor für die Dauerhaftigkeit der Gleislage,
- hohe Geschwindigkeiten beeinflussen die Verschlechterungsrate stark.

Wichtig ist es, eine passende Strategie für das Qualitätsverhalten im Gleisoberbau zu finden. Der verhältnismäßig kostengünstige Einzelteilewechsel, der kurzfristig eine Qualitätsverbesserung mit sich bringt, steht einer kompletten Neulage der Gleise gegenüber, wodurch eine wesentlich bessere Ausgangsqualität erreicht werden kann. Dies zeigt, wie wichtig es ist Fehler frühzeitig zu erkennen und angemessen darauf zu reagieren.

2.3 Fehlertypen

Die Lebensdauer der Gleiskomponenten ist, wie bereits beschrieben, abhängig von der Ausgangsqualität, die wirkenden äußeren Kräfte auf das Gleis sind aber ebenfalls ein wichtiger Faktor für die Liegedauer. Je größer die wechselwirkenden Kräfte zwischen Fahrzeug und dem Oberbau sind, umso höher wird der Verschleiß bei sinkender Qualität und damit fallendem Fahrtkomfort. Allgemein betrachtet können Fehler in zwei große

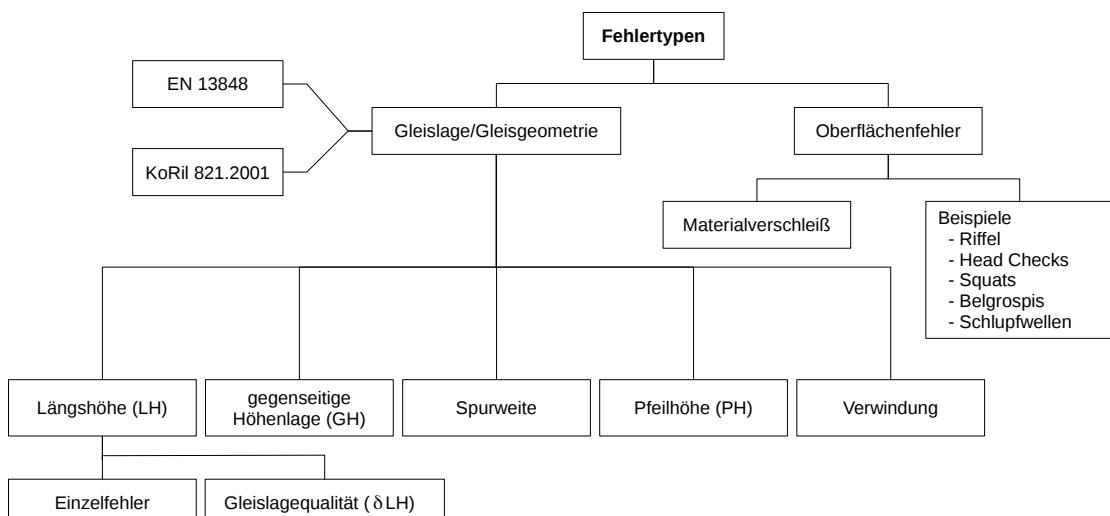


Abbildung 2.5: Übersicht der Fehlertypen

Klassen eingeteilt werden, siehe Abbildung 2.5. Eine Klasse der Fehlertypen sind Oberflächenfehler, wie Riffel oder Squats, die mittels Ultraschall- oder Wirbelstromprüfung erkannt werden können. Diese Fehler liegen im Wellenlängenbereich von einigen Zentimetern. Die zweite große Klasse bilden Gleisgeometriefehler, die auf eine Veränderung der Gleislage zurückzuführen sind. In dieser Arbeit werden ausschließlich kurzwellige Geometriefehler bezüglich der Längshöhe betrachtet, deren typischer Wellenlängenbereich zwischen 3 und 10 Metern liegt. Im Allgemeinen unterteilen sich die Gleisgeometriefehler in drei unterschiedliche Wellenlängenintervalle: 3-25 Meter, 25-70 Meter und 70-150 Meter. Das heißt, dass die zu untersuchenden Einzelfehler in dieser Fehlerklasse als kurzwellig angesehen werden können, im Vergleich zu den Oberflächenfehlern sind sie aber sehr langwellig. Solche Einzelfehler in der Längshöhe entstehen hauptsächlich durch eine Veränderung der Eigenschaften des Untergrundes beziehungsweise des Unterbaus. Infolge unterschiedlicher Untergrundbeschaffenheit treten solche Erscheinungen meist bei Bahnübergängen oder an Weichen auf.

Wenn der Gleislagefehler $F(x)$ vereinfacht als sinusförmiger Verlauf angenommen wird, wie in Abbildung 2.6 schematisch dargestellt, kann der Fehler folgendermaßen beschrieben werden [Lic09]:

$$F(x) = F_0 \cdot \sin\left(\frac{2\pi}{\lambda} \cdot x\right) \quad (2.3)$$

mit

- F_0 Fehleramplitude,
- λ Wellenlänge,
- x zurückgelegter Weg.

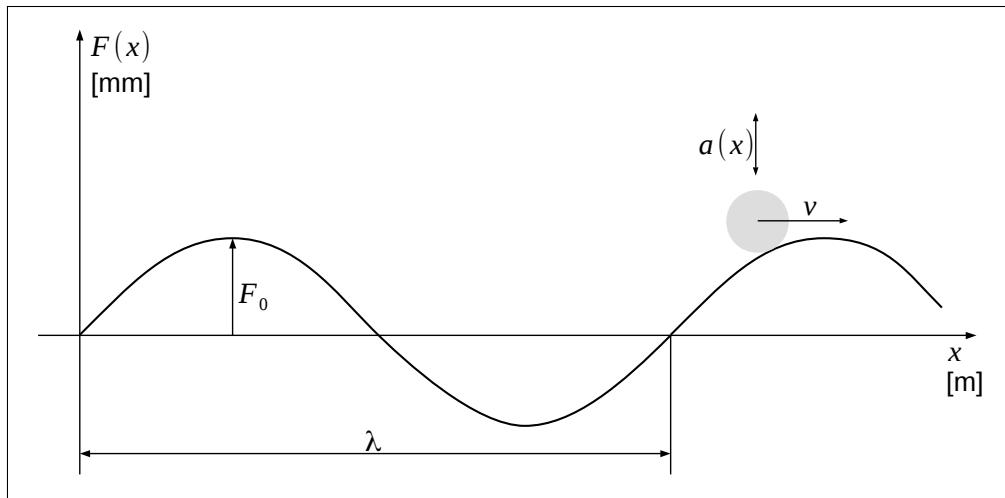


Abbildung 2.6: Modellhafter sinusförmiger Gleislagefehler nach [Lic09]

Das Schienenfahrzeug beziehungsweise das Rad bewegt sich mit der Geschwindigkeit

v. Daraus ergibt sich für den mit der Zeit t zurückgelegten Weg x des Rades:

$$x = v \cdot t \quad (2.4)$$

Durch Einsetzen von (2.4) in (2.3) folgt:

$$F(x) = F_0 \cdot \sin\left(\frac{2\pi}{\lambda} \cdot v \cdot t\right) \quad (2.5)$$

Durch zweimaliges Ableiten von (2.5) nach der Zeit t ergibt sich:

$$\frac{\partial^2 F(x)}{\partial t^2} = -F_0 \cdot \left(\frac{2\pi v}{\lambda}\right)^2 \cdot \sin\left(\frac{2\pi v}{\lambda} \cdot t\right) \quad (2.6)$$

Physikalisch gesehen, ergibt sich aus der zweiten Ableitung des Ortes x nach der Zeit t die Beschleunigung $a(x)$. Nach Umstellen von (2.5) nach F_0 und durch das Einsetzen in (2.6), folgt:

$$a(x) = -F(x) \cdot \left(\frac{2\pi v}{\lambda}\right)^2 \quad (2.7)$$

Aus Gleichung (2.7) wird ersichtlich, dass die vertikale Beschleunigung des ungefedernten Rades proportional mit dem Quadrat der Geschwindigkeit v und indirekt proportional mit der quadratischen Fehlerwellenlänge λ zusammenhängt. Betrachtet man zusätzlich die Beanspruchung des Gleises, so ergibt sich aus der Multiplikation der Beschleunigung mit der Masse des Rades die daraus resultierende Kraft.

Dieses stark vereinfachte Modell zeigt, dass je höher die Fahrgeschwindigkeit v ist, desto niedriger die Fehleramplituden F_0 gehalten werden müssen um eine entsprechende Qualitätsanforderung zu erfüllen. Außerdem ist es von Vorteil, wenn die Fehlerwellenlänge λ möglichst groß, d.h. langwellig, ist. Die Lebensdauer der Gleiskomponenten hängt von der Langwelligkeit und der Größe der Fehler ab, weil diese die wirkenden Kräfte beeinflussen. Somit zeigt sich die negative Auswirkung der Einzelfehler und warum es so wichtig ist diese zu erkennen und zu finden, denn sie sind verhältnismäßig teuer in der Reparatur und haben große Auswirkungen auf den Komfort und die Sicherheit.

Einzelfehler in der Gleislage, die beispielsweise durch das Versenken einer Schwelle entstehen oder aufgrund unterschiedlicher Materialien im Unterbau, wie es bei Bahnübergängen oder bei Weichen der Fall ist, können besonders kritisch sein und werden gesondert betrachtet. Abbildung 2.7 zeigt ein extremes Beispiel der australischen Bahn [Pic01], bei dem mehrere vertikale Fehler innerhalb weniger Meter aufgetreten sind.



Abbildung 2.7: Gleis mit vertikalen Fehlern [Pic01]

Solche Fehler können in den aufgezeichneten Daten als kurzzeitiger positiver oder negativer Ausschlag erkannt werden, wie es in Abbildung 2.8 der Fall ist. Auf der X-Achse ist der zurückgelegte Weg und auf der Y-Achse der entsprechende Ausschlag des Rades in Metern zu erkennen.

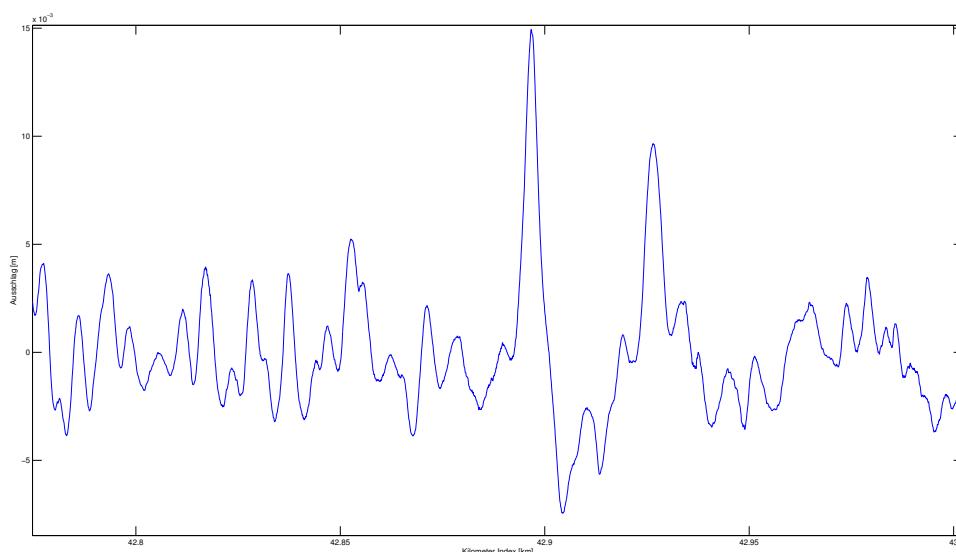


Abbildung 2.8: Einzelfehler in der Gleislage

Solche extremen Abweichungen vom normalen Verlauf der Strecke stellen ein nicht zu unterschätzendes Sicherheitsrisiko dar. Neben einer Beeinträchtigung des Fahrkomforts besteht außerdem die Gefahr der Entgleisung des Schienenfahrzeugs. Aus diesen Gründen muss der zuständige Instandhalter sofort reagieren, was oftmals in sehr kostenintensiven und ungeplanten Sofortmaßnahmen endet. Hier können Kosten ge-

senkt werden, wenn diese Fehler frühzeitig erkannt, beobachtet, analysiert und anschließend passend instandgehalten werden. Die eigentliche Instandhaltung sollte dann bestenfalls außerhalb der Hauptverkehrszeiten durchgeführt werden. Optimal wäre eine frühzeitige Erkennung des Fehlers noch bevor der Ausschlag ein sicherheitskritisches Level erreicht oder überschritten hat. Dies setzt jedoch eine kontinuierliche Überwachung der Strecke und der darin enthaltenden Fehler voraus. Sollte ein Fehler entdeckt worden sein, ist es vor allem wichtig den Fehlerart zu bestimmen, um mit geeigneten Instandhaltungsmaßnahmen zu reagieren. Wie ein Fehler definiert ist, wird im folgenden Abschnitt genauer betrachtet.

2.4 Normen und Richtlinien

Für das deutsche Schienennetz existieren zwei wichtige Regelwerke, in der die Qualitätsanforderungen für Schienenfahrwege definiert sind. Zum einen ist dies die neue Europäische Norm (EN), zum anderen die bislang noch gültige Konzernrichtlinie (KoRil) der DB AG.

Die Europäische Norm EN 13848 legt die Mindestanforderungen für die Qualitätsstufen der Gleisgeometrie fest und definiert die Sicherheitsgrenzen für unterschiedliche Parameter. Die Norm beinhaltet die Beschreibung der Qualitätsstufen, die verhältnismäßige Bedeutung der Parameter, Sicherheitsgrenzen und die Betrachtung anderer Qualitätsstufen. Die EN 13848 gilt für Hochgeschwindigkeits- und konventionelle Strecken mit 1435 mm und größeren Spurweiten. Der Hauptzweck dieser Norm ist die Festlegung der minimalen Qualität der Gleisgeometrie, um den sicheren Betrieb der Züge, basierend auf den Erfahrungen der unterschiedlichen europäischen Infrastrukturteilnehmer, sicherzustellen.

Für die Bewertung der Qualität der Gleisgeometrie werden drei Hauptniveaus betrachtet [Eur10]:

- *Sicherheitsgrenze (IAL)*: Bezieht sich auf den Wert, der, wenn er überschritten wird, Maßnahmen erfordert, welche zur Reduzierung des Risikos der Entgleisung führt. Dies kann entweder durch Sperren des Gleises, Reduzierung der Geschwindigkeit oder durch Korrektur der Gleisgeometrie erfolgen.
- *Eingriffsgrenze (IL)*: Bezieht sich auf den Wert, der, wenn er überschritten wird, korrigierende Instandhaltungsmaßnahmen erfordert, damit die Sicherheitsgrenze nicht vor der nächsten Inspektion erreicht werden kann.
- *Aufmerksamkeitsgrenze (AL)*: Bezieht sich auf den Wert, der, falls er überschritten wird, zu einer Analyse des geometrischen Gleiszustandes führt, und der in der regulär geplanten Instandhaltungsarbeiten berücksichtigt wird.

Neben diesen drei Grenzen gibt es zusätzlich drei Kennwerte, die der Beschreibung der Qualität der Gleisgeometrie dienen:

- Extremwerte von Einzelfehlern,
- Standardabweichung über einer definierten Länge (meist 200m) und der
- Mittelwert.

In diese Arbeit wird die Einzelfehlererkennung bezüglich der Längshöhe betrachtet. Tabelle 2.1 zeigt die nach EN 13848 vorgeschriebenen Werte für die drei Grenzen AL, IL und IAL in Abhängigkeit der Geschwindigkeit.

Geschwindigkeit [km/h]	AL [mm]		IL [mm]		IAL [mm]	
	D1	D2	D1	D2	D1	D2
$v < 80$	12 - 18	N/A	17 - 21	N/A	28	N/A
$80 < v \leq 120$	10 - 16	N/A	13 - 19	N/A	26	N/A
$120 < v \leq 160$	8 - 15	N/A	10 - 17	N/A	23	N/A
$160 < v \leq 230$	7 - 12	14 - 20	9 - 14	18 - 23	20	33
$230 < v \leq 300$	6 - 10	12 - 18	8 - 12	16 - 20	16	28

Tabelle 2.1: Werte für Längshöhenfehler nach EN 13848

Zusätzlich wird unterschieden nach dem Wellenlängenbereich D1 ($3m < \lambda \leq 25m$) und D2 ($25m < \lambda \leq 70m$). Die Millimeter-Werte für AL, IL und IAL beziehen sich auf den Abstand zwischen dem Mittelwert und der Spitze. N/A steht für nicht anwendbar, d.h. es ist nicht möglich für diesen Wellenlängenbereich unter Berücksichtigung des entsprechenden Geschwindigkeitsintervalls einen Wert anzugeben.

Neben der EN 13848 existiert außerdem die Konzernrichtlinie der Deutsche Bahn AG. Die KoRil 821.1000 legt die Grundsätze für die Inspektion des Oberbaus im Netz der Deutschen Bahn fest, die Richtlinien ab 821.2001 enthalten die Prüfbestimmungen für die einzelnen Inspektionen. Die Einhaltung der Bestimmungen der Richtlinien soll die Funktionsfähigkeit des Oberbaues für das jeweilige Anforderungsprofil und somit eine sichere Betriebsführung gewährleisten. Auch die Konzernrichtlinie der DB AG definiert drei Beurteilungsmaßstäbe [Kon04]:

- SR_A ist der Wert, bei dessen Überschreitung eine Beurteilung hinsichtlich der Einplanung einer Instandsetzungsmaßnahme unter wirtschaftlichen Gesichtspunkten erforderlich ist.
- SR_{100} ist der Wert, der den technisch/wirtschaftlichen Abnutzungsvorrat beinhaltet. Bei dessen Überschreitung ist eine Instandsetzung bis zur nächsten Regelspektion erforderlich.
- SR_{lim} ist der Wert, bei dessen Überschreitung eine Beeinträchtigung der Funktionsfähigkeit zu erwarten ist. Eine Instandhaltung ist in kürzest möglicher Zeit durchzuführen.

In Tabelle 2.2 sind die Beurteilungsmaßstäbe der Deutsche Bahn AG für Einzelfehler bezüglich der Gleislage dargestellt. Im Gegensatz zur EN 13848 werden exakte Werte für die Abweichungen angegeben und es wird nicht unterschieden nach verschiedenen Wellenlängenbereichen.

Geschwindigkeit [km/h]	SR_A [mm]	SR₁₀₀ [mm]	SR_{lim} [mm]
$v < 80$	12	15	21
$80 < v \leq 120$	10	13	17
$120 < v \leq 160$	8	11	14
$160 < v \leq 230$	6	9	11
$v > 230$	5	7	9

Tabelle 2.2: Werte für Längshöhenfehler nach KoRil 820.2001

Die beiden oben beschriebenen Regelwerke betrachten dabei die einzelnen Fehler ausschließlich anhand der vertikalen Abweichung, also an der Amplitude des Ausschlags, was in der Vergangenheit auch zu einem sehr guten Sicherheitsniveau geführt hat. In Folge technologischer Weiterentwicklung und unter dem Bestreben die Wirtschaftlichkeit zu optimieren, sind weiterführende und verbesserte Verfahren nötig. Neben der messbaren Abweichung ist es außerdem von großem Vorteil die Art des Fehlers zu bestimmen. Dies sollte im besten Fall, noch bevor diese potentielle Fehlerstelle eine der oben genannten Sicherheitsgrenzen überschreitet, passieren. Lässt sich ein solcher Fehler nun frühzeitig identifizieren, besteht die Möglichkeit mit den in [Lin14] beschriebenen Prognoseverfahren, basierend auf einem Regressionsmodell, eine Überschreitung der sicherheitsrelevanten Grenzen zeitlich zu prognostizieren. Somit wäre es möglich die Instandhaltung effektiv zu planen und durchzuführen, denn neben dem errechneten Zeitpunkt des Eingreifens wäre auch der Fehlerart bekannt.

3 Mathematische Grundlagen

Nachdem die bahntechnischen Grundlagen beschrieben wurden, beschäftigt sich dieses Kapitel mit der Erläuterung der, für die Datenverarbeitung relevanten, mathematischen Verfahren. Dies sind zum einen die Fourier- und Wavelet-Transformationen, die für die Signalverarbeitung notwendig sind und ein wichtiges Hilfsmittel darstellen um Informationen über Frequenzen zu erhalten. Zum anderen werden selbstlernende Algorithmen näher beschrieben, die für das Klassifizieren der Daten zuständig sind.

3.1 Diskrete Fourier-Transformation

Die diskrete Fourier-Transformation überführt eine zeit- bzw. ortsabhängige Funktion in eine neue, frequenzabhängige Funktion. Diese Fourier-Transformierte ermöglicht es Informationen über die Frequenzen der Ausgangsfunktion darzustellen. Da in der Praxis meist Messreihen aufgezeichnet werden, d.h. Daten zu diskreten Zeitpunkten, betrachtet dieser Abschnitt die diskrete Fourier-Transformation und nicht die kontinuierliche. Für weitere Einzelheiten zur Fourier-Transformation sei auf [But11] und [Bri97] verwiesen. Gegeben seien N diskrete Zeiten:

$$t_k = k\Delta t, \quad k = 0, 1, \dots, N - 1$$

das heißt, es wurden Messdaten $f(t_k) = f_k$ zu den Zeitpunkten t_k genommen. Die Zahlenfolge $\{f_k\}$ repräsentiert also den Datensatz. Außerhalb des Intervalls $T = N\Delta t$ ist die Funktion unbekannt, die diskrete Fourier-Transformation geht jedoch davon aus, dass die Folge $\{f_k\}$ periodisch fortgesetzt wird, was jedoch kein Problem darstellt. Einzelheiten dazu können in [But11, S. 118] nachgelesen werden. Weiter sei N eine Potenz von 2, was für den Algorithmus der Schnellen-Fourier-Transformation die optimalen Ergebnisse liefert, jedoch keine notwendige Bedingung ist. Das Spektrum F_j ergibt sich aus der Definition [But11, S. 96]:

$$F_j = \frac{1}{N} \sum_{k=0}^{N-1} f_k e^{-\frac{-2\pi i j k}{N}}. \quad (3.1)$$

Eine schnelle algorithmische Umsetzung der diskreten Fourier-Transformation stellt die Schnelle-Fourier-Transformation dar, welche durch effiziente Berechnung mittels dem 'divide and conquer' Prinzip die Werte der Fourier-Transformation berechnet. Der unter anderem auch von MATLAB verwendete Algorithmus wurde von Cooley und Tukey 1965 vorgestellt [Coo65].

3.2 Diskrete Wavelet-Transformation

Neben der Fourier-Transformation ist die Wavelet-Transformation ein weiteres Verfahren aus der Signaltechnik. Durch die Zeit-Frequenz-Transformation ist es möglich, neben den Informationen über die in dem Signal enthaltenen Frequenzen, auch Informationen über Zeit bzw. Ort zu erhalten [Kru02, S. 99]. Für das zu analysierende Signal $f(t)$ ergeben sich folgende Koeffizienten:

$$C_{a,b} = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} f(t) \psi\left(\frac{t-b}{a}\right) dt. \quad (3.2)$$

Die Waveletkoeffizienten $C_{a,b}$ sind dabei maßgeblich von drei Faktoren abhängig: Dem gewählten Wavelet ψ , der Skalierung $a \in \mathbb{R}^+$ und der Verschiebung $b \in \mathbb{R}$. Das Wavelet ψ dient dabei als eine Art Referenzfunktion, auch 'Mother Wavelet' genannt, welches die Zulässigkeitsbedingung

$$\int_{-\infty}^{\infty} \psi(t) dt = 0$$

erfüllen muss [Bla03, S. 54]. Ein typischer Vertreter für Wavelets ist der 'Mexican Hat'. Es existieren jedoch unendlich viele Wavelets. Einige ausgewählte Wavelets der Daubechies und der Symlets Familie sind in Anhang A dargestellt. Der Parameter a in (3.2) staucht bzw. streckt die Waveletfunktion, b verschiebt das Wavelet gegenüber dem Signal $f(t)$.

Für die Betrachtung diskreter Zeitfunktionen $f(n), n \in \mathbb{Z}$ ergeben sich unter den Bedingungen $a_m = 2^m$ und $b_{mk} = k \cdot 2^m$ mit $k, m \in \mathbb{Z}, m > 0$ folgende diskrete Wavelet-Koeffizienten [Kru02, S. 104]:

$$D(n) = 2^{-\frac{m}{2}} \sum_n f(n) \psi(n \cdot 2^{-m} - k) \quad (3.3)$$

Die Wavelet-Transformation unterliegt, wie alle linearen Zeit-Frequenz-Transformationen, der Unschärferelation der Nachrichtentechnik, auch als küpfmüllersche Unbestimmtheitsrelation bezeichnet [Hof05, S. 94]. Es ist eine Aussage darüber, dass Zeit und Frequenz nicht gleichzeitig beliebig genau betrachtet werden können. Das heißt, es sollte eine Entscheidung getroffen werden, ob die Einzelheiten zu Zeit bzw. Ort wichtige Informationen liefern könnten oder die dazugehörigen Frequenzen. Das betrachtete Zeit-Frequenz-Fenster eines gegebenen Signals kann durch eine Fläche beschrieben werden, deren Größe durch das gewählte Wavelet bestimmt wird. In Abbildung 3.1 ist die Rasterung der Zeit-Frequenz-Ebene als Gitter dargestellt, welches durch die Wahl von $a = 2^m$ entsteht.

Bei einer Streckung des Wavelets von a_1 zu a_2 , was eine Verkleinerung der Frequenz-

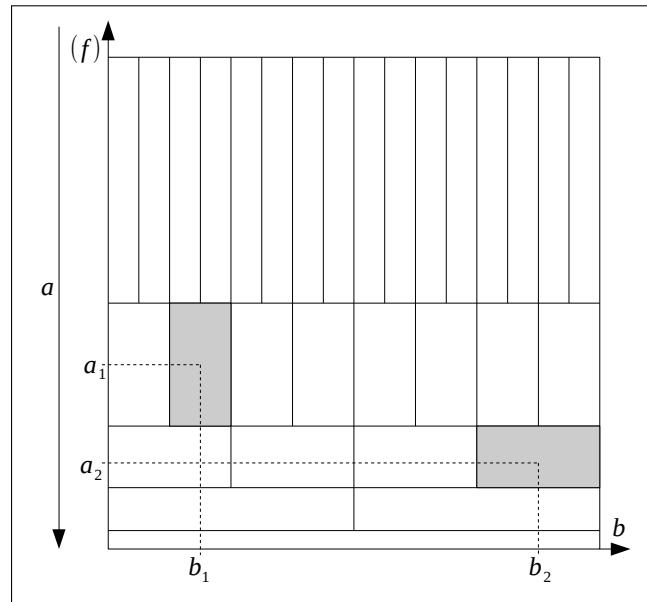


Abbildung 3.1: Rasterung der Zeit-Frequenz-Ebene

auflösung impliziert, vergrößert sich automatisch das Orts- bzw. Zeitfenster von b_1 auf b_2 . Das heißt, eine hohe Analysefrequenz ergibt eine gute Zeit- und eine schlechte Frequenzauflösung. Umgekehrt ergibt eine niedrige Analysefrequenz eine gute Frequenz- und eine schlechte Zeitauflösung. Die berechneten Waveletkoeffizienten $C_{a,b}$ sind ein Maß für die Ähnlichkeit des verwendeten Wavelets mit dem zu analysierenden Signal $f(t)$. Das Wavelet wird dabei gleitend über das Signal geschoben und berechnet an welcher Position $f(t)$ und das Wavelet ψ am besten korrelieren.

3.3 Selbstlernende Klassifizierer

3.3.1 Vorbetrachtung

Folgend werden einige Grundbegriffe genauer betrachtet, die für das Verständnis des Klassifizierers benötigt werden. Bezug genommen wird auf die Literatur [Har12, S. 7].

Seien $\mathbf{x} = (x_1, \dots, x_n)^T$ und $\mathbf{y} = (y_1, \dots, y_n)^T$ Datenvektoren aus einer Datenmenge \mathcal{X} . Die auf \mathcal{X} definierte Metrik ist gegeben durch die Abbildung $d : \mathcal{X} \times \mathcal{X} \rightarrow \mathbb{R}^n$. $(\mathcal{X}, d(\mathbf{x}, \mathbf{y}))$ bilden somit einen metrischen Raum, den Datenraum. Weiter sei \mathcal{K} die Klassenmenge, wobei jedes Element des Datenraumes genau einer Klasse $k \in \mathcal{K}$ zugeordnet ist. Diese eindeutige Zuordnung ist gegeben durch eine Klassifikatorfunktion

$$\kappa : \mathcal{X} \rightarrow \mathcal{K} : \kappa(\mathbf{x}) \mapsto k.$$

Da jeder Datenpunkt nur einer Klasse zugehörig sein kann, kann der Datenraum somit in k -viele disjunkte Klassen

$$\mathcal{X}_k = \{\mathbf{x} \in \mathcal{X} \mid \kappa(\mathbf{x}) = k\} \subseteq \mathcal{X}, \forall k \in \mathcal{K}$$

zerlegt werden, so dass

$$\mathcal{X} = \bigcup_{k \in \mathcal{K}} \mathcal{X}_k$$

gilt. Diese Partition des Datenraumes bezüglich der Klassen, wird als Klassentrennung oder Klassenzerlegung bezeichnet. Eine weitere Teilmenge der Daten, $\mathcal{T} \subset \mathcal{X}$, wird als Trainingsmenge bezeichnet, vorausgesetzt, dass für die Daten in \mathcal{T} die Klassifikatorfunktion κ bekannt ist.

Ziel ist es anhand der Trainingsdatenmenge \mathcal{T} eine Klassentrennung für den kompletten Datenraum \mathcal{X} zu lernen, wobei die durch κ gegebene und bekannte Klassifikatorfunktion für \mathcal{T} erlernt und auf \mathcal{X} angewendet werden soll. Diese erlernte Funktion wird mit κ' bezeichnet und das Ziel ist es so zu lernen, dass

$$\kappa'(\mathbf{x}) = \kappa(\mathbf{x}), \forall \mathbf{x} \in \mathcal{T}$$

gilt. Ein großes Problem stellt das Auswendiglernen der Algorithmen dar. Um dem entgegen zu wirken, wird der Datenraum \mathcal{X} in den Trainingsraum \mathcal{T} und den Testdatenraum $\mathcal{T}' = \mathcal{X} \setminus \mathcal{T}$ aufgeteilt. Da für \mathcal{T} die Klassifikatorfunktion durch κ gegeben ist, kann κ als Referenz für die neu erlernte Funktion κ' genutzt werden um so die Qualität und Güte zu bestimmen. Diese Genauigkeitsrate r_a lässt sich folgendermaßen berechnen:

$$r_a = \frac{1}{|\mathcal{T}'|} \sum_{\mathbf{x} \in \mathcal{T}'} g(\mathbf{x}),$$

wobei

$$g(\mathbf{x}) = \begin{cases} 1, & \kappa(\mathbf{x}) = \kappa'(\mathbf{x}) \\ 0, & \kappa(\mathbf{x}) \neq \kappa'(\mathbf{x}) \end{cases}.$$

Für Prototyp-basierende Verfahren des überwachten Lernens, sind für die Lernaufgabe Repräsentanten der einzelnen Klassen $k \in \mathcal{K}$ notwendig, sogenannte Prototypen \mathbf{w}_i^k . Die Menge aller Prototypen ist gegeben durch

$$W = \bigcup_k W^k$$

wobei

$$W^k = \{\mathbf{w}_i^k \mid i = 1, \dots, n_k\}.$$

n^k gibt die Anzahl der Prototypen in der entsprechenden Klasse $k \in \mathcal{K}$ an, es können unterschiedlich viele Prototypen pro Klasse initialisiert werden, was sich positiv auf das Endergebnis auswirken kann. Die Prototypen sollen mit einem Algorithmus so im Datenraum \mathcal{X} platziert werden, dass die Informationen der entsprechenden Klassen mög-

lichst gut repräsentiert werden können. Abbildung 3.2 zeigt dazu ein sehr vereinfachtes Beispiel bei dem 3 Klassen und die jeweils dazugehörigen Prototypen dargestellt werden. In diesem trivialen Fall ist es möglich die Klassen zu 100 Prozent zu trennen, was in der Praxis jedoch nicht immer zutrifft, da die gegebenen Daten oft sehr eng beieinander liegen und die Klassengrenzen somit nicht eindeutig sind.

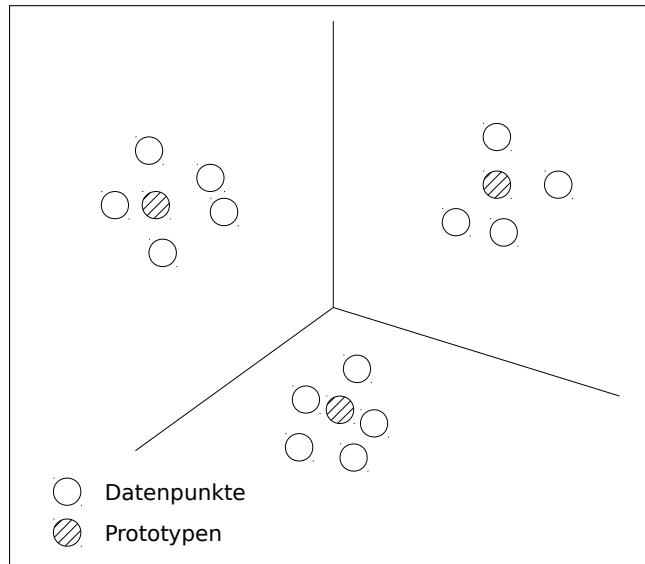


Abbildung 3.2: Schematisches Beispiel eines 3-Klassen Problems

Jedem Datenvektor aus \mathcal{X} wird demnach eine Klasse anhand des Prototypen zugeordnet. Diese Klassifikation der Daten basiert auf dem Prinzip des kleinsten Abstandes

$$\mathbf{x} \in \mathcal{X}_k \Leftrightarrow \min_i d(\mathbf{x}, \mathbf{w}_i^k) \leq \min_j d(\mathbf{x}, \mathbf{w}_j^l), \forall l \neq k.$$

Der Prototyp, der den geringsten Abstand zu dem gewählten Datenpunkt hat, bestimmt somit die Klassenzugehörigkeit. Für den Fall, dass zwei oder mehr Prototypen den gleichen Abstand zu einem Datenvektor \mathbf{x} haben, entscheidet der Zufall über die Zuteilung einer Klasse.

3.3.2 Learning Vector Quantization und Generalized Learning Vector Quantization

Der erste Learning Vector Quantization (LVQ) Algorithmus ist der LVQ1 und wurde von T. Kohonen vorgestellt [Koh90], mit dem oben genannten Ziel, die Prototypen möglichst klassentypisch im Laufe des Algorithmus zu platzieren. Dabei werden die Prototypen zufällig initialisiert oder es werden bereits vorhandene Datenpunkte per Zufall als Prototypen der entsprechenden Klassen gesetzt. Während der Lernphase wird in jedem Schritt ein Datenvektor \mathbf{x} mit der dazugehörigen Klasse $\kappa(\mathbf{x})$ gewählt. Anschließend wird der Abstand, beziehungsweise ein Ähnlichkeitsmaß, $d : \mathbb{R}^n \times \mathbb{R}^n \rightarrow \mathbb{R}^+$ zu jedem

einzelnen Prototypen berechnet und der Gewinner \mathbf{w}^+ mit dem geringsten Abstand ermittelt:

$$\mathbf{w}^+ = \min_i d(\mathbf{x}, \mathbf{w}_i).$$

Bemerkung 3.1 Der Begriff des Ähnlichkeitsmaßes bzw. Unähnlichkeitsmaßes wurde erstmals 2005 in [Pek05] eingeführt. Auch wenn im weiterem Verlauf der Arbeit der Begriff Abstand verwendet wird, liegt ein Ähnlichkeitsmaß zu Grunde.

Die Adaption des Gewinnerprototypen \mathbf{w}^+ erfolgt anhand der Regel:

$$\mathbf{w}^+ = \mathbf{w}^+ \begin{cases} +\varepsilon \cdot (\mathbf{x} - \mathbf{w}^+), & \text{wenn } \kappa(\mathbf{x}) = \kappa(\mathbf{w}^+) \\ -\varepsilon \cdot (\mathbf{x} - \mathbf{w}^+), & \text{sonst.} \end{cases},$$

wobei die Lernrate $\varepsilon \in (0, 1)$ während des Lernprozesses Schritt für Schritt verringert werden sollte um die Konvergenz sicher zu stellen. Eine hinreichende und notwendige Bedingung für die Konvergenz, wenn $\varepsilon_r > 0$ die Lernrate im Lernschritt r ist, wurde in [Kus78] gezeigt:

$$0 < \varepsilon_r \ll 1, \quad (3.4)$$

$$\sum_{r=1}^{\infty} \varepsilon_r = \infty, \quad (3.5)$$

$$\sum_{r=1}^{\infty} \varepsilon_r^2 < \infty. \quad (3.6)$$

Dieser Trainingsprozess sollte solange durchgeführt werden bis die Prototypen korrekt platziert sind. Die Genauigkeit der Klassifikation ist abhängig von einigen Faktoren:

- Der Anzahl der Prototypen und deren Initialisierungsmethode,
- der Lernrate ε ,
- dem verwendeten Distanzmaß und
- der Anzahl der Lernschritte.

Eine Weiterentwicklung des LVQ bildet der Generalized Learning Vector Quantization (GLVQ) Algorithmus, der von A. Sato und K. Yamada in [Sat95] vorgestellt wurde. Der Hauptunterschied zum LVQ ist, dass der GLVQ eine Kostenfunktion verwendet, welche die Anzahl der fehlklassifizierten Datenvektoren approximiert. Diese Kostenfunktion wird mittels einem stochastischen Gradientenabstieg minimiert. Ein großer Vorteil liegt darin, dass die Konvergenz durch diese Kostenfunktion sicher gestellt ist, weiterhin gilt auch das Konvergenzkriterium von Kushner und Clark [Kus78] wie es auch beim LVQ der Fall ist. Die Klassifizierungsfunktion

$$\mu(x) = \frac{d(\mathbf{x}, \mathbf{w}^+) - d(\mathbf{x}, \mathbf{w}^-)}{d(\mathbf{x}, \mathbf{w}^+) + d(\mathbf{x}, \mathbf{w}^-)} \quad (3.7)$$

besitzt einen Wertebereich zwischen -1 und $+1$ und berechnet den relativen Fehler. Neben dem Gewinnerprototyp \mathbf{w}^+ wird zusätzlich der Verliererprototyp \mathbf{w}^- betrachtet, d.h. $\kappa(\mathbf{x}) \neq \kappa(\mathbf{w}^+) = \kappa(\mathbf{w}^-)$. Wird ein Datenpunkt \mathbf{x} richtig klassifiziert, ist der Abstand zum korrekten Prototyp kleiner als der zum nächsten falschen Prototyp und $\mu(\mathbf{x})$ nimmt einen negativen Wert an. Bei einer Falschklassifikation wird $\mu(\mathbf{x})$ dementsprechend positiv. Minimiert wird die Kostenfunktion

$$E^{GLVQ} = \sum_{\mathbf{x} \in \mathcal{T}} f(\mu(\mathbf{x}))$$

wobei f eine monoton wachsende Funktion, z.B. die Sigmoidfunktion oder die Identitätsfunktion, ist.

3.3.3 Generalized Matrix Learning Vector Quantization

Generalized Matrix Learning Vector Quantization (GMLVQ) wurde 2008 von Michael Biehl, Barbara Hammer und Petra Schneider in [Bie08] veröffentlicht. Das Prinzip ist ähnlich wie bei dem GLVQ: Eine Minimierung der Kostenfunktion durch einen stochastischen Gradientenabstieg, welche die Anzahl der Fehlklassifikationen approximiert.

Sei $\mathcal{T} = \{(\mathbf{x}, k) | \mathbf{x} \in \mathbb{R}^n, k \in \mathcal{K}\}$ die Trainingsdatenmenge mit n -dimensionalen Datenvektoren und $|\mathcal{K}|$ vielen Klassen. Die im GLVQ verwendete euklidische Metrik wird im GMLVQ durch folgendes Ähnlichkeitsmaß ersetzt:

$$d_{\Lambda}(\mathbf{x}, \mathbf{w}) = (\mathbf{x} - \mathbf{w})^T \boldsymbol{\Lambda} (\mathbf{x} - \mathbf{w}) \quad (3.8)$$

Wobei $\boldsymbol{\Lambda}$ eine $n \times n$ Matrix ist und am Anfang des Algorithmus beliebig initialisiert werden kann, beispielsweise als Einheitsmatrix. Am Ende des Algorithmus kann diese Matrix als Klassifikations-Korrelations-Matrix betrachtet werden. Dabei ergeben sich schrittweise auf der Hauptdiagonalen die Korrelationen bezüglich der Klassifikation der einzelnen Dimensionen. Weiterhin muss $\boldsymbol{\Lambda}$ die Eigenschaften der Symmetrie und der positiven Definitheit erfüllen. Dies kann erreicht werden durch eine Zerlegung der Matrix in

$$\boldsymbol{\Lambda} = \boldsymbol{\Omega}^T \boldsymbol{\Omega}. \quad (3.9)$$

Daraus folgt, dass

$$\mathbf{y}^T \boldsymbol{\Lambda} \mathbf{y} = \mathbf{y}^T \boldsymbol{\Omega}^T \boldsymbol{\Omega} \mathbf{y} = (\boldsymbol{\Omega}^T \mathbf{y})^2 \geq 0$$

für alle \mathbf{y} erfüllt ist, wobei $\boldsymbol{\Lambda}$ eine beliebige reellwertige $m \times n$ Matrix ist mit $m \in \mathbb{N}$ und $1 \leq m \leq n$. Für die positive Definitheit wird weiterhin gefordert, dass $\det \boldsymbol{\Lambda} \neq 0$ ist, für den Fall $m = n$. In der Praxis hat sich jedoch gezeigt, dass positive Semidefinitheit ausreichend ist [Sch09].

Für das Ähnlichkeitsmaß aus (3.8) ergibt sich durch Einsetzen von (3.9) folgendes:

$$\begin{aligned}
 d_{\Lambda}(\mathbf{x}, \mathbf{w}) &= (\mathbf{x} - \mathbf{w})^T \boldsymbol{\Lambda} (\mathbf{x} - \mathbf{w}) \\
 &= (\mathbf{x} - \mathbf{w})^T \boldsymbol{\Omega}^T \boldsymbol{\Omega} (\mathbf{x} - \mathbf{w}) \\
 &= (\boldsymbol{\Omega}(\mathbf{x} - \mathbf{w}))^T (\boldsymbol{\Omega}(\mathbf{x} - \mathbf{w})) \\
 &= (\boldsymbol{\Omega}(\mathbf{x} - \mathbf{w}))^2
 \end{aligned} \tag{3.10}$$

Zu jedem zufällig ausgewählten Datenvektor $\mathbf{x} \in \mathcal{T}$ wird der Gewinnerprototyp \mathbf{w}^+ ermittelt, d.h. der Prototyp mit dem geringsten Abstand und der selben Klasse wie \mathbf{x} , $\kappa(\mathbf{x}) = \kappa(\mathbf{w}^+)$. Zusätzlich wird der Verliererprototyp \mathbf{w}^- bestimmt, der am nächsten am ausgewählten Datenvektor \mathbf{x} liegt, aber einer anderen Klasse zugehörig ist, also $\kappa(\mathbf{x}) \neq \kappa(\mathbf{w}^+)$. Danach wird der Gewinnerprototyp an den Datenvektor \mathbf{x} herangezogen und \mathbf{w}^- wird von \mathbf{x} weggestoßen. Darauf basierend lässt sich die classifier function, die Funktion des relativen Fehlers, darstellen wie in Gleichung 3.7 zu sehen. Wobei $d_{\Lambda}^+(\mathbf{x}) := d_{\Lambda}(\mathbf{x}, \mathbf{w}^+)$ die Distanz zum Gewinnerprototyp und $d_{\Lambda}^-(\mathbf{x}) := d_{\Lambda}(\mathbf{x}, \mathbf{w}^-)$ die Distanz zum Verliererprototyp ist. Der Wertebereich der Funktion $\mu(\mathbf{x})$ liegt im Intervall $[-1, 1]$, bei einer korrekten Klassifizierung des Vektors $\mathbf{x} \in \mathcal{T}$ ist der Funktionswert negativ und bei einer Falschklassifikation positiv. Die Kostenfunktion

$$E^{GMLVQ} = \sum_{\mathbf{x} \in \mathcal{T}} f(\mu_{\Lambda}(\mathbf{x})) \tag{3.11}$$

approximiert dabei den Klassifikationsfehler, wobei f eine monoton wachsende Funktion ist und meist als Sigmoidfunktion

$$f(\mu_{\Lambda}(\mathbf{x})) = \frac{1}{1 + e^{-\sigma \cdot \mu_{\Lambda}(\mathbf{x})}}$$

mit entsprechendem σ gewählt wird. Die Energiefunktion E^{GMLVQ} wird nun durch einen stochastischen Gradientenabstieg minimiert.

Bemerkung 3.2 Es sei noch einmal darauf hingewiesen, dass es sich hierbei um einen stochastischen Gradientenabstieg handelt. Dabei wird zufällig ein Datenpunkt \mathbf{x} herausgesucht und danach abgeleitet. Das Lernen der Prototypen \mathbf{w}^{\pm} wird mittels dem stochastischen Gradient realisiert, folgende Notation wird hierfür verwendet:

$$\frac{\partial E^{GMLVQ}}{\partial \mathbf{w}^{\pm}} = \left. \frac{\partial_s E^{GMLVQ}}{\partial \mathbf{w}^{\pm}} \right|_{\mathbf{x}}$$

Die vorher berechneten Gewinner- und Verliererprototypen werden folgendermaßen adaptiert:

$$\mathbf{w}^{\pm} \leftarrow \mathbf{w}^{\pm} - \varepsilon_r \frac{\partial E^{GMLVQ}}{\partial \mathbf{w}^{\pm}}, \tag{3.12}$$

wobei

$$\frac{\partial E^{GMLVQ}}{\partial \mathbf{w}^\pm} = \frac{\partial f}{\partial \mu_\Lambda} \cdot \frac{\partial \mu_\Lambda}{\partial d_\Lambda^\pm(\mathbf{x})} \cdot \frac{\partial d_\Lambda^\pm(\mathbf{x})}{\partial \mathbf{w}^\pm}, \quad (3.13)$$

und

$$\frac{\partial d_\Lambda^\pm(\mathbf{x})}{\partial \mathbf{w}^\pm} = -2\Omega(\mathbf{x} - \mathbf{w}^\pm). \quad (3.14)$$

ε_r aus (3.12) ist die Lernrate im r -ten Trainingsschritt, mit den drei Bedingungen (3.4), (3.5) und (3.6). Die Lernrate ε_r muss mit größer werdender Anzahl der Lernschritte kleiner werden, zum Beispiel $\varepsilon = \frac{1}{r}$. Da jedoch $r \rightarrow \infty$ praktisch nicht realisierbar ist wird der Lernprozess nach endlich vielen Schritten abgebrochen, was zu Folge hat, dass möglicherweise nur ein lokales Minimum der Kostenfunktion gefunden worden ist.

Neben der Energiefunktion kann auch die Matrix Ω in jedem Lernschritt r adaptiert werden:

$$\Omega \leftarrow \Omega - \varepsilon_r^\Omega \frac{\partial E^{GMLVQ}}{\partial \Omega}, \quad (3.15)$$

wobei

$$\frac{\partial E^{GMLVQ}}{\partial \Omega} = \frac{\partial f}{\partial \mu_\Lambda} \left(\frac{\partial \mu_\Lambda}{\partial d_\Lambda^+(\mathbf{x})} \cdot \frac{\partial d_\Lambda^+(\mathbf{x})}{\partial \Omega} + \frac{\partial \mu_\Lambda}{\partial d_\Lambda^-(\mathbf{x})} \cdot \frac{\partial d_\Lambda^-(\mathbf{x})}{\partial \Omega} \right) \quad (3.16)$$

und

$$\frac{\partial d_\Lambda^+}{\partial \Omega} = 2\Omega(\mathbf{x} - \mathbf{w}^+)(\mathbf{x} - \mathbf{w}^+)^T \quad (3.17)$$

$$\frac{\partial d_\Lambda^-}{\partial \Omega} = 2\Omega(\mathbf{x} - \mathbf{w}^-)(\mathbf{x} - \mathbf{w}^-)^T \quad (3.18)$$

Die Lernrate für die Metrik ε_r^Ω kann dabei unabhängig von der Lernrate ε_r der Prototypen gewählt werden. Meist ist es aber sinnvoll $\varepsilon_r^\Omega \ll \varepsilon_r$ zu wählen, um die Metrik langsamer lernen zu lassen [Kae12]. Andernfalls wenn sich Ω zu schnell ändert, würde dies bedeuten, dass die Prototypen immer nach einer neuen Metrik adaptiert werden, was zu einer schlechten Konvergenz der Prototypen führen kann. Die Matrix Ω ist eine lineare Abbildung $\Omega : \mathbb{R}^n \rightarrow \mathbb{R}^m$, d.h. der GMLVQ lernt eine Abbildung der Datenvektoren in den Raum \mathbb{R}^m in dem die Daten besser getrennt werden können. Für eine Visualisierung bietet es sich an, $m \in \{2, 3\}$ zu wählen. Um den Algorithmus vor der Degeneration zu schützen und eine höhere Stabilität zu gewährleisten [Bie09], wird Ω nach jedem Updateschritt normiert, mit

$$\Omega_{(i,j)} = \frac{\Omega_{(i,j)}}{\sqrt{\sum_{k=1}^n \Lambda_{(k,k)}}}, \quad (3.19)$$

wobei

$$\Lambda_{(i,i)} = \sum_{j=1}^m (\Omega_{(j,i)})^2. \quad (3.20)$$

Folgend sind die wichtigsten Schritte des GMLVG zusammengefasst.

Algorithmus 1 GMLVQ

Input: Lernraten ε und ε^Ω Trainingsdatensatz \mathcal{T} Anzahl der Iterationen r_{max}

Anzahl der Prototypen pro Klasse

Output: Prototypen \mathbf{w} Matrix Λ Initialisierung von Ω (z.B.: $\Omega = \mathbb{E}$)Zufällige Initialisierung der Prototypen \mathbf{w} $r := 0$ **while** $r < r_{max}$ **do**Wähle zufällig ein $\mathbf{x} \in \mathcal{T}$ Berechne Abstand zwischen Datenpunkt \mathbf{x} und Prototypen \mathbf{w} mittels (3.10)

Bestimme Gewinner- und Verliererprototyp

Adaptiere Gewinner- und Verliererprototyp mittels (3.12)

Adaptiere Ω mittels (3.15)Normiere Ω mittels (3.19) $r = r + 1$ **end**Berechne Λ mittels (3.9)

3.3.4 Support Vector Machine

Im Gegensatz zu den Varianten der LVQ Algorithmen, lassen sich mit der Support Vector Machine (SVM) nur binäre, d.h. 2-Klassen Probleme, lösen. Abbildung 3.3 zeigt ein solches modellhaftes Problem. Der größte Unterschied hierbei ist, dass die SVM keine klassentypischen Prototypen verwendet, wie es zum Beispiel oft beim LVQ der Fall ist [Neb14], sondern Support-Vektoren, die am jeweiligen Klassenrand liegen. Die Beschreibung der SVM orientiert sich an [Vil12].

Gegeben sei eine Lernaufgabe $\mathcal{L} = (y_i, \mathbf{x}_i)$ mit $\mathbf{x}_i \in \mathbb{R}^n$ und einer endlichen Trainingsmenge $i = 1, \dots, M$. Unter der Annahme, dass für die zwei Klassen jeweils positive und negative Instanzen existieren, ergeben sich die Label $y_i \in \{+1, -1\}$. Ziel der SVM ist es, eine optimale Hyperebene

$$H(\mathbf{w}, b) = \{\mathbf{x} \in \mathbb{R}^n \mid \mathbf{w}^T \mathbf{x} + b = 0\} \quad (3.21)$$

zu finden, die die beiden Klassen voneinander trennt, wobei \mathbf{w} der definierende Vektor und b das Bias, beziehungsweise die Verschiebung, ist. H trennt also die linear separablen Klassen voneinander, d.h. es gilt für die positiven Instanzen $y_i = +1$ und für die negativen $y_i = -1$:

$$\mathbf{w}^T \mathbf{x}_i + b = +1 \quad \text{und} \quad \mathbf{w}^T \mathbf{x}_i + b = -1.$$

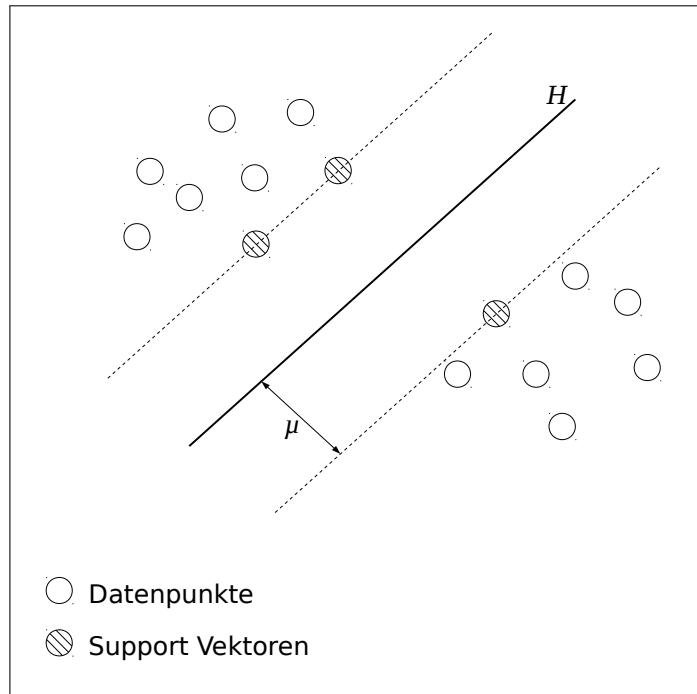


Abbildung 3.3: Klassifizierung mittels Support Vector Machine

Der Abstand r eines Punktes \mathbf{x} zu H kann dabei folgendermaßen berechnet werden:

$$r_H(\mathbf{x}) = d(H, \mathbf{x}) = \frac{\mathbf{w}^T \mathbf{x} + b}{\|\mathbf{w}\|} \quad (3.22)$$

Die Datenpunkte mit minimalem Abstand zur Trennebene H werden Support-Vektoren genannt, dabei kann es vorkommen, dass es pro Klasse mehrere solcher Vektoren gibt. Die Trennbreite (separation margin) $\mu_{\mathcal{L}}$ gibt den Abstand zwischen den Support-Vektoren und der Hyperebene H an:

$$\mu_{\mathcal{L}}(\mathbf{w}, b) = \min |r(\mathbf{x}_k)| \quad (3.23)$$

mit $k = 1, \dots, M$. Die optimale Hyperebene H für die Lernmenge \mathcal{L} ist eine trennende Hyperebene $H^* = H(\mathbf{w}^*, b^*)$ mit

$$\mu_{\mathcal{L}}(\mathbf{w}^*, b^*) \geq \mu_{\mathcal{L}}(\mathbf{w}, b) \quad \forall \mathbf{w}, b. \quad (3.24)$$

Der Abstand der Support-Vektoren zur optimalen Hyperebene H^* beträgt

$$\begin{aligned} \frac{1}{\|\mathbf{w}\|}, & \text{ falls } y_i = +1 \text{ und} \\ \frac{-1}{\|\mathbf{w}\|}, & \text{ falls } y_i = -1. \end{aligned}$$

Bemerkung 3.3 Dass das Bias b nicht mehr enthalten ist, liegt an einer geeignet ge-

wählten Normierung und es existiert für jede Klasse immer mindestens ein Support-Vektor.

Das Finden der optimalen Hyperebene H^* kann als Optimierungsproblem mit Randbedingungen formuliert werden, unter Eingabe der Lernmenge $\mathcal{L} = (y_i, \mathbf{x}_i)$ wird dabei $\mathbf{w} \in \mathbb{R}^n$ und $b \in \mathbb{R}$ gesucht. Minimiert wird die Funktion $E = \frac{1}{2}\mathbf{w}^T\mathbf{w}$ unter Verwendung der Randbedingung $y_i(\mathbf{w}^T\mathbf{x}_i + b) - 1 \geq 0$. Die Berechnung des Minimums wird mittels Lagrange Multiplikatoren α_m und der Zusammenfassung der Optimierungsaufgabe in der Lagrange Funktion $J(\mathbf{w}, b, \alpha)$ realisiert:

$$\begin{aligned} J(\mathbf{w}, b, \alpha) &= \frac{1}{2}\mathbf{w}^T\mathbf{w} \\ &= -\sum_{m=1}^M \alpha_m(y_m(\mathbf{w}^T\mathbf{x}_m + b) - 1) \end{aligned}$$

Die Einzelheiten für die Lösung dieses Problems und das daraus folgende duale Problem werden in [Ste08, S. 412 ff] genauer erklärt. Dieser beschriebene Algorithmus eignet sich jedoch nur für linear trennbare Lernaufgaben. Sollte das vorliegende Klassifikationsproblem nicht linear separierbar sein, ist es sinnvoll den sogenannten *Kernel Trick* anzuwenden. Das Ziel dabei ist es, die Daten in einem höher-dimensionalen Raum abzubilden und die Trennung dort durchzuführen.

Definition 3.4 Sei $\kappa : \mathbb{R}^n \times \mathbb{R}^n \rightarrow \mathbb{R}$ eine Funktion, so dass ein Hilbertraum H existiert, mit $\kappa(\mathbf{x}, \mathbf{y}) = \langle \Phi(\mathbf{x}), \Phi(\mathbf{y}) \rangle_H$ und $\mathbf{x} \mapsto \Phi(\mathbf{x}) \in H$. Dann heißt κ Kernel zur Abbildung Φ .

Theorem 3.5 (Mercer, [Sch02]) Sei $\kappa : [a, b]^n \times [a, b]^n \rightarrow \mathbb{R}$ symmetrisch und stetig. Dann sind folgende Aussagen äquivalent

- κ ist positiv definiter Kernel
- für alle Funktionen $\Psi : [a, b]^n \rightarrow \mathbb{R}$ mit $\int_{[a,b]^n} |\Psi(\mathbf{x})|^2 d\mathbf{x} < \infty$

so gilt:

$$\int_{[a,b]^n} \int_{[a,b]^n} \Psi(\mathbf{x}) \kappa(\mathbf{x}, \mathbf{y}) \Psi(\mathbf{y}) d\mathbf{x} d\mathbf{y} \geq 0.$$

Solche Kernel werden Mercer-Kernel genannt.

Bemerkung 3.6 Eine typische Mercer-Kernel-Funktion ist die Radial Basis Function (RBF) und ist definiert als $\kappa_\sigma(\mathbf{x}, \mathbf{y}) = \exp\left(-\frac{\|\mathbf{x}-\mathbf{y}\|_E^2}{\sigma}\right)$.

Die folgende Erklärung bezieht sich auf [Vil14]. In dieser Veröffentlichung konnte gezeigt werden, dass Gradient-basierendes Lernen in Prototyp-basierender Vektor Quantifizierung möglich ist, durch das Verwenden von Kernel-Metriken anstelle der euklidischen Distanz.

Sei (V, d_V) ein kompakter Vektorraum der gegebenen Daten mit dem Distanzmaß d_V . Von Steinwart konnte in [Ste01] gezeigt werden, dass der Kernel stetig und universal (z.B. RBF-Kernel) sein muss, um sicherzustellen, dass das Bild von Φ , bezeichnet als $I_k \subseteq H$, ein Vektorraum ist, unter der Voraussetzung, dass der Eingaberaum V auch ein Vektorraum ist. Sei $\kappa : V \times V \rightarrow \mathbb{R}$ ein positiv definiter, stetiger und universaler Kernel mit der Abbildung $\Phi : V \rightarrow H$ und der in H gegebenen Metrik $d_H = d_\kappa = \sqrt{\kappa(\mathbf{x}, \mathbf{x}) - 2\kappa(\mathbf{x}, \mathbf{y}) + \kappa(\mathbf{y}, \mathbf{y})}$. Der Übergang der Metrik d_V zur Kernel Metrik d_κ kann als Abbildung $\Psi : (V, d_V) \rightarrow (V, d_\kappa)$ zwischen den metrischen Räumen (V, d_V) und (V, d_κ) interpretiert werden. Durch diese metrische Änderungen kann es dazu kommen, dass sich die Daten deformieren und die topologischen Beziehungen ändern. Wenn das Bild $I_\kappa = \Phi(V)$ dicht im Raum der stetigen Funktionen $C(V)$ ist, dann ist der metrische Raum (V, d_κ) topologisch äquivalent zu dem induzierten Raum $I_\kappa \subseteq H$ mit der Metrik $d_H = d_\kappa$. Beide Räume sind außerdem isometrisch und daher ist (V, d_H) auch ein Hilbertraum. Daraus folgt, dass die Abbildung Ψ bijektiv, separabel und stetig ist. In Abbildung 3.4 ist dieser Zusammenhang visualisiert.

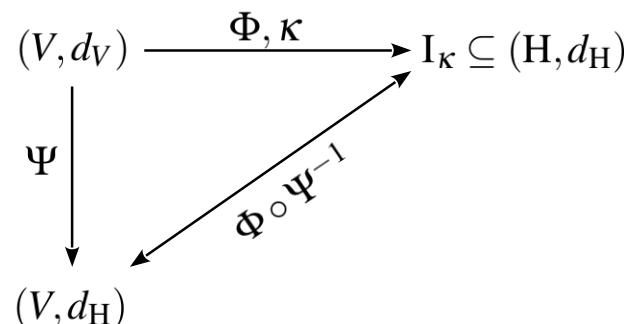


Abbildung 3.4: Zusammenhang der metrischen Räume unter Verwendung eines Kernels [Vil14]

4 Datenverarbeitung und -analyse

Nachdem die mathematischen und bahntechnischen Grundlagen in den vorherigen beiden Kapiteln beschrieben wurden, stellt dieses Kapitel die Verbindung der beiden Bereiche dar. Betrachtet werden die Rohdaten und die darauf aufbauenden Möglichkeiten Weichen innerhalb dieser Daten zu erkennen.

4.1 Datenursprung

Die vorliegenden Daten wurden von der DB AG mittels Continuous Track Monitoring (CTM) an einem ICE 2 aufgezeichnet und sowohl im Rahmen des RIVAS (Railway Induced Vibration Abatement Solutions) Projektes [Riv13], als auch im AUTOMAIN Projekt verwendet. Neben den bereits erwähnten vertikalen Beschleunigungsdaten der Achsen, welche für die kommende Analyse verwendet wurden, werden noch weitere Parameter gemessen, wie in Abbildung 4.1 dargestellt. Durch die Kombination mehrerer Sensoren können somit neben der Gleisgeometrie auch das Fahrverhalten und der Fahrkomfort, gemäß der Standards der DB AG, gemessen werden.

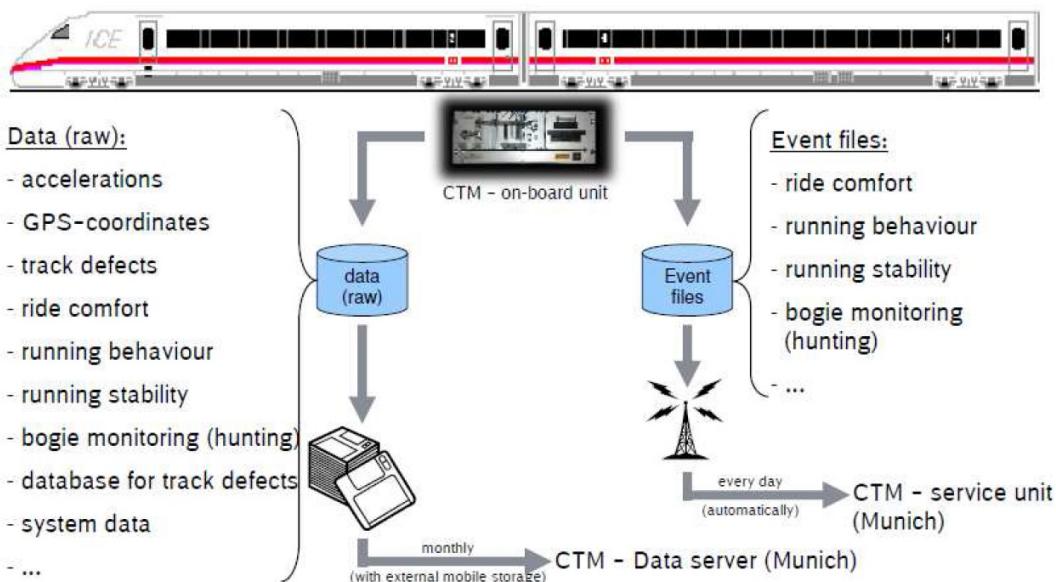


Abbildung 4.1: Datenverarbeitung der CTM Installation an einem ICE 2 [Riv13]

Bei der Messung mit CTM Systemen werden Sensorsysteme an Zügen installiert, die sich im Regelbetrieb befinden. Somit können, parallel zum Transport von Personen oder Gütern, Daten über die Gleisqualität aufgezeichnet werden. Hochpräzise Messfahrzeuge (z.B. Railab) hingegen, sind speziell für die sicherheitsrelevante Inspektion ausgelegt und durch das Eisenbahnministerium genehmigt, wodurch die Messungen

gerichts- und haftungsrelevant sind. Ein großer Nachteil besteht jedoch darin, dass für eine Messfahrt die Strecke für den Regelbetrieb gesperrt werden muss. Die CTM Messungen bieten durch das Monitoring eine wirtschaftliche Optimierung, sind aber noch nicht für Sicherheitsbetrachtungen heranzuziehen. In [Riv13] konnte exemplarisch für einen Streckenabschnitt gezeigt werden, dass die Messreihen eines CTM Systems mit denen des Messfahrzeuges Railab sehr gut korrelieren. Da sich die Fahrzeuge mit CTM Systemen mit unterschiedlicher Geschwindigkeit bewegen, ist eine entsprechende Datenvorverarbeitung zwingend notwendig, um eine Datenkonsistenz für die nachfolgende Bearbeitung zu gewährleisten.

4.2 Datenvorverarbeitung

Vor allem zwei Unregelmäßigkeiten fallen bei näherem Betrachten der Messdaten auf: Nach dem Extrahieren des gleichen Streckenintervalls aus allen 13 Messreihen, zeigt sich, dass es eine unregelmäßige Verschiebung der Daten in x-Richtung gibt und das jede Messreihe dabei aus unterschiedlich vielen Datenpunkten besteht.

Die unterschiedliche Anzahl der Messdaten pro Streckenintervall resultiert aus der von Aufzeichnung zu Aufzeichnung variierenden Fahrtgeschwindigkeit des Zuges. Die Frequenz, mit der die vertikale Beschleunigung des Rades gemessen wird, ist dabei unabhängig von der Geschwindigkeit des Messfahrzeugs. Fährt der Messwagen beispielsweise an Tag 1 mit 100 km/h über ein Streckenabschnitt, werden mehr Daten aufgezeichnet, als an einem anderen Tag, wenn das Fahrzeug schneller über genau den gleichen Abschnitt fährt. Für die weitere Verarbeitung ist es jedoch vorteilhaft, mit Datenvektoren zu arbeiten, die die gleiche Anzahl von Daten enthalten. Eine Möglichkeit dieses Problem zu beheben, ist das Interpolieren einzelner Datenvektoren wodurch zusätzlich Daten erzeugt werden um alle Intervalle auf die gleiche Länge zu strecken. Eine zweite Variante besteht darin, eine Reduzierung der Datenreihen auf eine einheitliche Anzahl von Datenpunkten vorzunehmen. Somit werden keine neuen Daten erzeugt und das in den Messreihen vorhandene Rauschen kann entfernt werden. Außerdem besteht die Option, vorausschauend auf weitere Verarbeitungsschritte, die konkrete Anzahl von Datenpunkten pro Streckenkilometer anzugeben, was zum Beispiel für die schnelle Fourier-Transformation eine Zweierpotenz sein sollte.

Das Problem der unregelmäßigen Verschiebung der Daten entlang der x-Achse ist auf die Genauigkeit der GPS Messung zurückzuführen. Aufgrund der Ortung des Messfahrzeugs mit einer Genauigkeit von +/- 5 Metern, kann es zu einer Verschiebung der Messreihen an den unterschiedlichen Tagen von bis zu 10 Metern kommen. Um dieser Abweichung entgegenzuwirken, lassen sich die einzelnen Datenreihen entsprechender Streckenintervalle mittels Korrelation ausrichten. Die meist in der Signalverarbeitung genutzte Kreuzkorrelation beschreibt dabei die Korrelation von zwei Signalen bei unterschiedlichen Zeit- bzw. Ortsverschiebungen. Als Referenzsignal kann die Messreihe der ersten Überfahrt genutzt werden. Das Ergebnis ist in Abbildung 4.2 dargestellt. Dabei ist gut zu erkennen, dass der Verlauf der einzelnen Messreihen sehr ähnlich ist,

es jedoch erkennbare Unterschiede gibt bei dem jeweiligen Maximalwert, was auf eine Entwicklung eines gefundenen Einzelfehlers hindeuten kann.

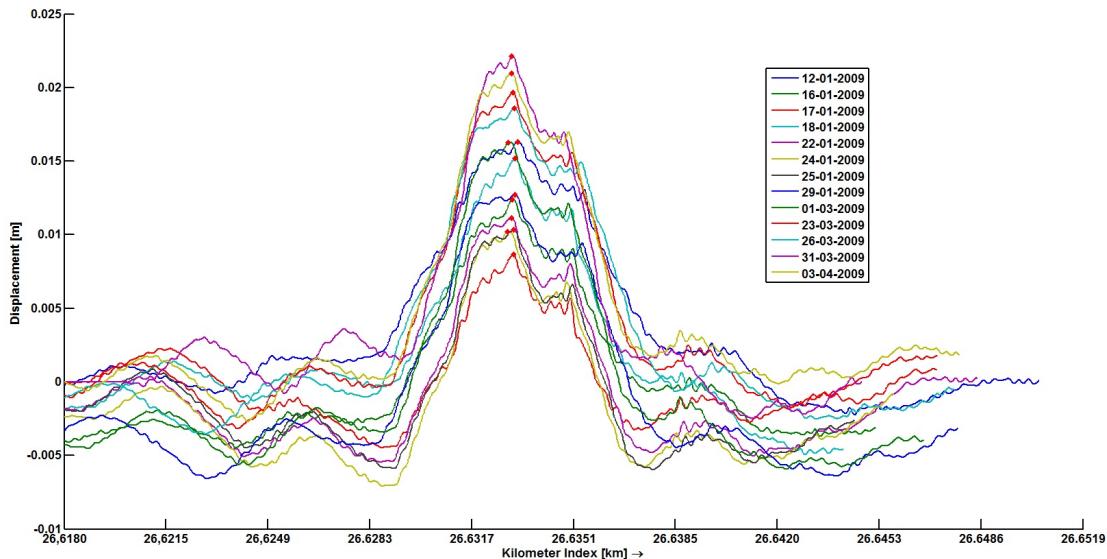


Abbildung 4.2: Übereinandergeschobene Messdaten [Lin14]

Für die weitere Verarbeitung der Daten wurden aus allen Messreihen 300 Datenexemplare für Weichen extrahiert, deren Position aus dem Weichenverzeichnis entnommen wurde. Es wurde nicht unterschieden zwischen verschiedenen Weichtypen beziehungsweise der Befahrrichtung. Da die Länge der bekannten Weichen sehr unterschiedlich ist, wurde eine durchschnittliche Weichenlänge von 25 Metern festgelegt, hinzu kommt noch ein kleiner Puffer jeweils links und rechts der Weiche, so dass die Gesamtlänge 32 Meter entspricht. Diese Datenvektoren repräsentieren die Klasse der Weichen. Die zweite Klasse beinhaltet ebenfalls 300 Datenvektoren gleicher Länge, die jedoch zufällig aus den gesamten Messreihen ausgewählt wurden. Diese Daten sind Vertreter der Klasse Nicht-Weichen. Es wird somit ein Zwei-Klassen Problem betrachtet, bei dem das Erkennen von Weichen innerhalb der gegebenen Messreihen im Vordergrund steht.

4.3 Beschleunigungsdaten

Die Beschleunigungsdaten (Rohdaten) sind die unveränderten Originaldaten, die direkt am Radsatz des Messfahrzeuges aufgezeichnet wurden. Dabei wird die vertikale Beschleunigung des Rades gemessen während sich der Messzug mit einer bestimmten Geschwindigkeit über die Schienen bewegt. Wie bereits im vorherigen Abschnitt beschrieben, werden umso mehr Daten pro Kilometer aufgezeichnet, je langsamer sich das Messfahrzeug bewegt. Die Sensorik am Rad reagiert auf vertikale Fehler im Gleis, wie beispielsweise bei einer Hohllage. Bei der Überfahrt drückt es die Schiene in die Hohllage, wodurch sich der Radsatz nach unten absenkt. Die Messgeräte erfassen somit eine nach unten gerichtete Beschleunigung des Rades. Abbildung 4.3 zeigt den

Verlauf der aufgezeichneten Beschleunigungsdaten bei der Überfahrt einer Weiche bei Kilometer 14,796. Die dargestellten 32 Meter entsprechen dabei ca. 2000 Messwerten.

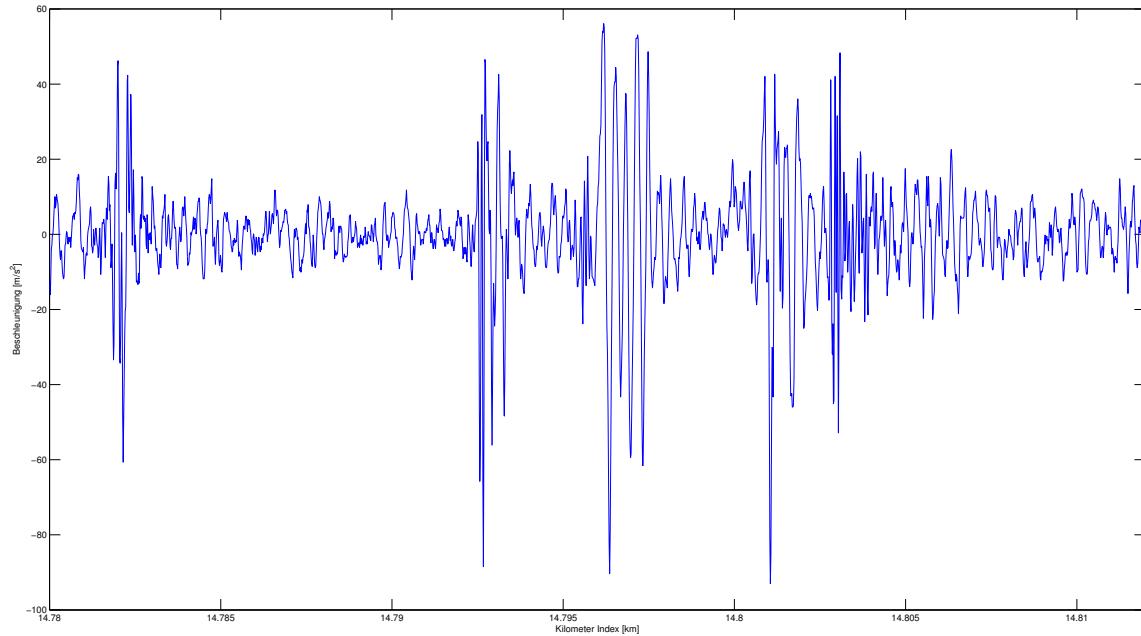


Abbildung 4.3: Ausschnitt einer Weiche (Beschleunigungsdaten)

Zu erkennen sind einige sehr große negative und positive Ausschläge, welche darauf deuten lassen, dass an diesen Stellen vertikale Unregelmäßigkeiten im Gleis vorhanden sind. Umso betragsmäßig größer ein solcher Ausschlag ist, desto größer ist auch die vertikale Abweichung der Schiene von der Norm. Messwerte zwischen 20 und -20 m/s² können als normales Fahrverhalten gedeutet werden, da sich die Radsätze und das komplette Messfahrzeug durch die ständig wirkenden Kräfte stets in minimaler vertikaler Bewegung befinden. Grundsätzlich lässt sich feststellen, dass die Beschleunigungsdaten stark schwankend sind. Unter Betrachtung aller 300 Datenvektoren der Weichen, lassen sich auf den ersten Blick keine Zusammenhänge oder typischen Muster erkennen. Da alle extrahierten Datenvektoren der beiden Klassen Weichen und Nicht-Weichen aus unterschiedlich vielen Datenpunkten (1600 - 3000) bestehen, sollten diese für die weitere Bearbeitung auf eine einheitliche Länge gebracht werden. Unter Rücksichtnahme des Rechenaufwandes und der damit verbundenen Rechenzeit, empfiehlt es sich die Anzahl der Daten zu reduzieren, bestenfalls auf eine Zweierpotenz um die weitere Anwendung der schnellen Fourier-Transformation zu optimieren. In Abbildung 4.4 sind beispielhaft drei Dimensionsreduzierungen der oben abgebildeten Weiche auf 128, 256 und 512 Datenpunkte zu sehen. Zu erkennen ist, dass 128 Datenpunkte nicht ausreichend sind um den originalen Verlauf korrekt abzubilden. Vor allem betragsmäßig große Ausschläge werden teilweise nicht erfasst wodurch ein Großteil der Informationen verloren geht.

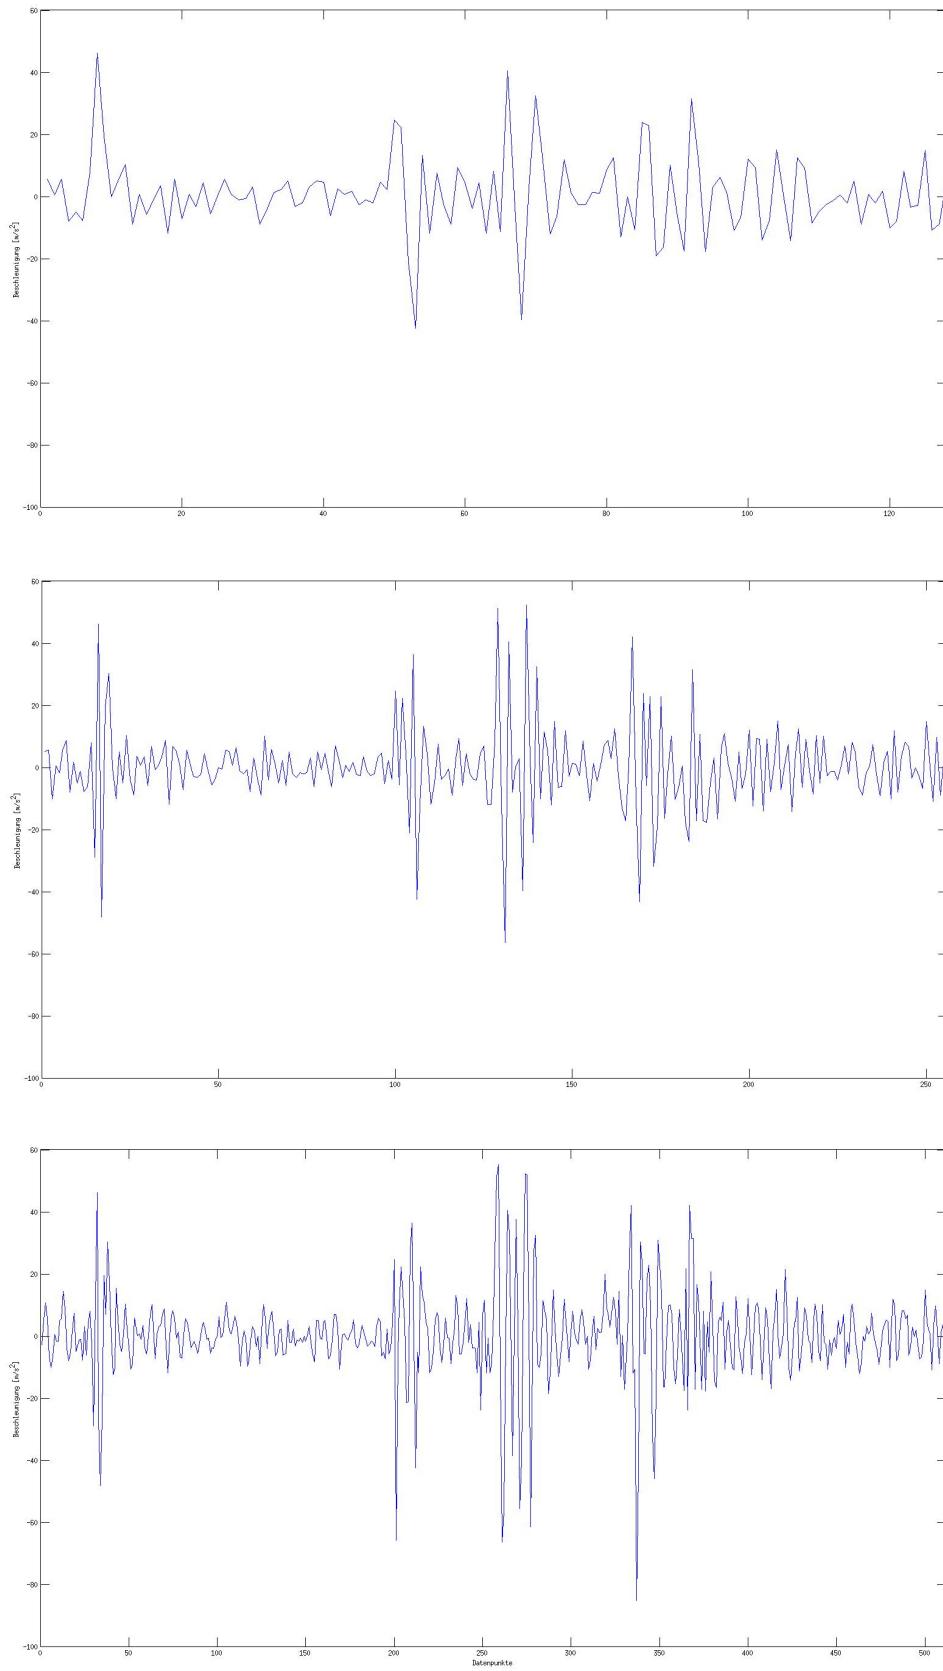


Abbildung 4.4: Reduzierung der Dimensionen auf 128, 256 und 512 Datenpunkte

Eine bessere Abbildungsmöglichkeit besteht bei der Anwendung von 256 bzw. 512 Datenpunkten. In diesem Fall können auch größere positive und negative Schwankungen gut dargestellt werden und das bei vertretbarem Rechenaufwand bei den weiteren Berechnungen. 512 Datenpunkte auf 32 Metern entsprachen einer Abtastrate von 6,25 Zentimetern, 256 Datenpunkte entsprechen 12,5 Zentimetern.

Da die oben abgebildeten Beschleunigungsdaten auch als aufgezeichnete Signale interpretiert werden können, werden im folgenden auch Methoden der Signalverarbeitung angewendet. Neben der Schnellen Fourier-Transformation ist auch die Nutzung von Wavelets eine zielführende Transformationsmöglichkeit um Informationen über enthaltende Frequenzen zu extrahieren. Abbildung 4.5 bildet das Frequenzspektrum ab, welches zu dem mittleren Signal mit 256 Datenpunkten aus Abbildung 4.4 gehört. Aufgrund der Symmetrie des Spektrums wurden nur 128 Koeffizienten dargestellt.

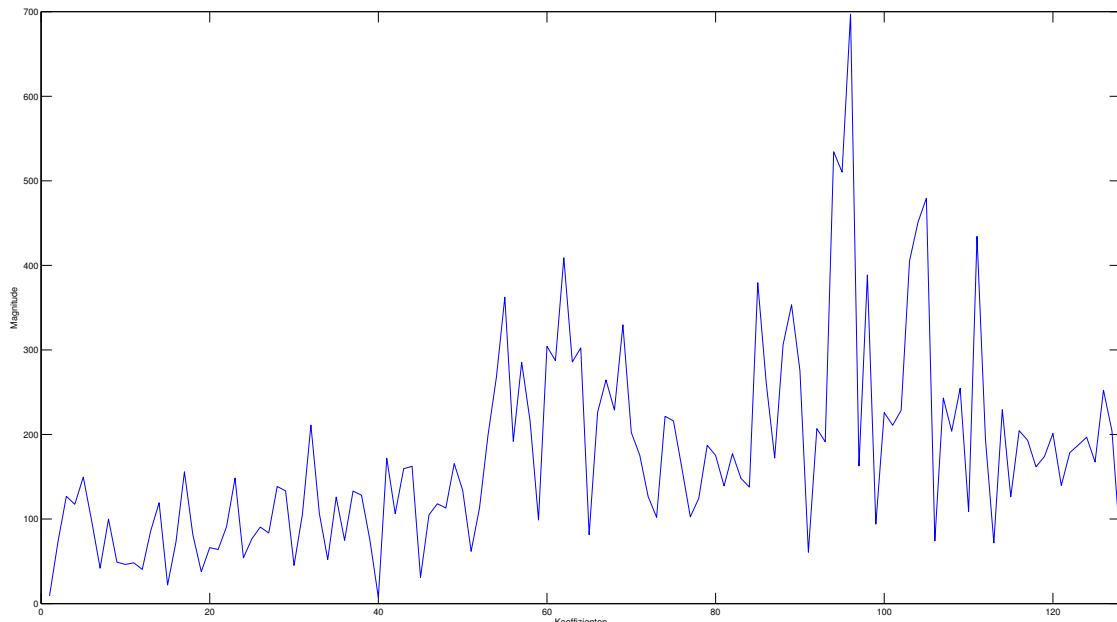


Abbildung 4.5: Frequenzspektrum mit 128 Koeffizienten

Da der bei der Transformation entstehende imaginäre Teil betragsmäßig viel kleiner ist als der Realteil, wurden beide Teile verrechnet mit $\sqrt{\text{real}(x)^2 + \text{imag}(x)^2}$, wobei x einen aus der Fourier-Transformation entstandenen Koeffizienten darstellt. Dies hat den Vorteil, dass die Informationen aus Real- und Imaginärteil für die Klassifizierungsalgorithmen zur Verfügung stehen. In der Abbildung ist zu erkennen, dass das Frequenzspektrum sowohl niedrige als auch hohe Frequenzen enthält, wobei die Koeffizienten 50 bis 115 die größten Werte haben.

Die berechneten Fourierkoeffizienten bilden die Grundlage für die Klassifiziereralgorithmen, denn wie bereits im Abschnitt über die Fehlertypen beschrieben, kann die Überfahrt eines Gleisfehlers als eine Art Schwingung beschrieben werden und die Fourier-Transformation bildet dafür eine sehr gute Analysemöglichkeit. Mit Hilfe der GLVQ Tool-

box³ können die Fourierkoeffizienten für die Klassifizierung mittels dem GMLVQ Algorithmus verwendet werden. Das Ergebnis, welches nach 2000 Schritten erreicht wurde, ist in Abbildung 4.6 dargestellt.

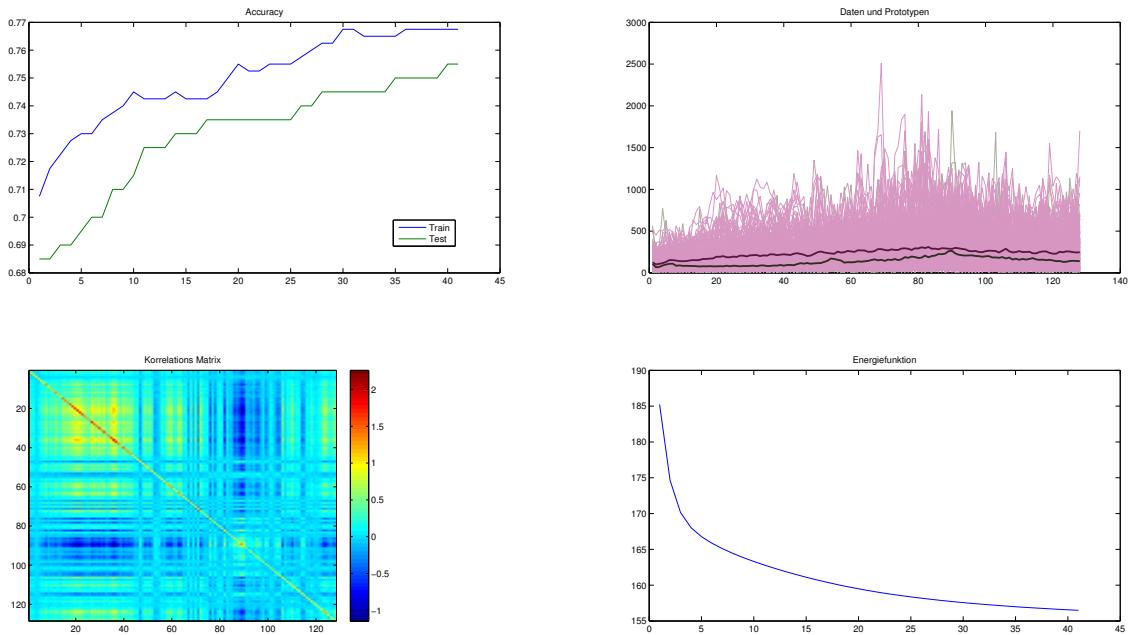


Abbildung 4.6: Ergebnis des GMLVQ mit Fourierkoeffizienten

Das Klassifikationsresultat der Testdaten liegt bei ca. 75,5%, wie es in der linken oberen Darstellung zu erkennen ist. Die mittels dem stochastischen Gradientenabstieg minimierte Energiefunktion ist in der unteren rechten Ecke abgebildet, die Daten und Prototypen in der Abbildung darüber. Unten links ist die Klassifikations-Korrelationsmatrix und deren Einträge dargestellt. Die Hauptdiagonale dieser Matrix liefert Informationen über die Relevanz der einzelnen 128 Dimensionen für die Klassifikation. Zu sehen ist, dass vor allem die ersten 40 Dimensionen einen hohen Wert und somit eine hohe Relevanz haben. Je höher ein Wert ist, desto mehr Einfluss hat diese Dimension auf die Klassifikation. Umgekehrt gilt jedoch nicht zwingend, dass kleinere Werte auch immer weniger relevant sind. Es kann jedoch keine Aussage getroffen werden über die vermutlich weniger relevanten Dimensionen. Da unter anderen Bedingungen, zum Beispiel das Hinzufügen neuer Dimensionen, sich die Bedeutung der einzelnen Dimensionen für eine erfolgreiche Klassifikation komplett ändern kann.

Für das Klassifizieren mit der Support Vector Machine wurde das MATLAB Tool LIBSVM [Lib11] verwendet. Das Ergebnis liegt hier ebenfalls bei ca. 76%, wobei von den 600 Eingabevektoren 451 Support-Vektoren sind bei der Verwendung einer linearen Kernel Funktion. Die hohe Anzahl an Support Vektoren deutet darauf hin, dass die beiden Datenklassen nicht linear trennbar sind und in diesem Fall ein Auswendiglernen stattfindet,

³ Von Marika Kaden, Mitarbeiterin der Computational Intelligence Forschungsgruppe der Hochschule Mittweida, zur Verfügung gestellt.

was für die weitere Mustererkennung nicht von Vorteil ist. Das Ersetzen der linearen Funktion durch eine Radiale Basisfunktion erhöht zwar die Klassifikationsgenauigkeit, hat aber auch zur Folge, dass alle 600 Vektoren zu Support Vektoren werden.

Die einfache diskrete eindimensionale Wavelet-Transformation in MATLAB ist gleich zusetzen mit der einfachen eindimensionalen Wavelet Dekomposition. Dabei wird das Eingabesignal in zwei Vektoren aufgeteilt: die approximierten Koeffizienten (Tiefpass Filter) und die detaillierten Koeffizienten (Hochpass Filter). Der Vektor der approximierten Koeffizienten ähnelt dem Ausgangssignal, ist demnach eine Art Mittelwertsverlauf des gegebenen Signals. Die detaillierten Koeffizienten hingegen liefern Informationen über das Verhalten des Signals. Dieser Vektor entspricht den Koeffizienten der diskreten Wavelet-Transformation unter Verwendung des ausgewählten Mother Wavelets [Sto13]. Da die Dekomposition mehrfach auf die approximierten Koeffizienten angewendet werden kann, halbiert sich mit jedem Schritt die Auflösung des approximierten Signals. Mit jedem Schritt verringert sich somit das Zeit- bzw. Ortsfenster, das Frequenzfenster vergrößert sich jedoch [Mal89]. In Abbildung 4.7 ist eine solche Dekomposition dargestellt, die eine Zerlegung des Eingangssignals X in die approximierten (A) und die detaillierten (D) Koeffizienten darstellt. Das approximierte Signal kann dabei schrittweise weiter zerlegt und analysiert werden, dies entspricht dann dem Level der Dekomposition.

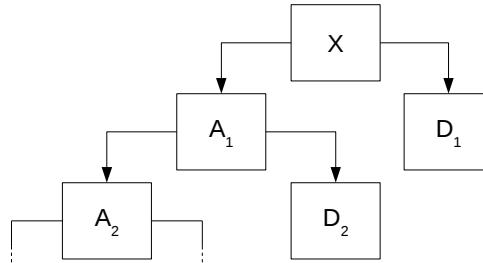


Abbildung 4.7: 2-Level Wavelet Dekomposition

Die Klassifizierung anhand der Wavelet Koeffizienten (vgl. Abbildung 4.7: D_1) unter Verwendung eines db6 Wavelets (Anhang A, Abbildung A.1) lieferte bei der SVM und dem GMLVQ lediglich Werte um die 50%, was darauf schließen lässt, dass die Koeffizienten, für sich betrachtet, für das Klassifizieren ungeeignet sind und keine verwendbaren Informationen enthalten. Wird jedoch eine 2-fache Dekomposition angewendet, wird das Zeitfenster kleiner und die Frequenzauflösung höher. Die Klassifikation kann mit den berechneten approximierten und detaillierten Koeffizienten durchgeführt werden (vgl. Abbildung 4.7: A_2). Das Testresultat des GMLVQ liegt bei 65,5% bei einer Intervalllänge von 32 Metern, das Ergebnis der SVM ist 51%.

4.4 Versatzdaten

Im Rahmen des AUTOMAIN Projektes wurden am Deutschen Zentrum für Luft- und Raumfahrt e.V. (DLR) die von der Sensorik gewonnenen Rohdaten analysiert und ausgewertet und für die Entwicklung eines Prognoseverfahrens zur Gleislageabweichung bei Einzelfehlern verwendet. Die folgende Auswertung bezieht sich dabei auf den Artikel von C. Linder [Lin14].

Die in dem vorherigen Abschnitt verwendeten Beschleunigungsdaten haben einen Nachteil. Es ist nicht möglich die zu untersuchende Längshöhe direkt in einer metrischen Messgröße abzulesen. Da die Richtlinien EN 13848 und auch die KoRil der DB AG diese Abweichung in Millimetern angeben, ist es sinnvoll die Originaldaten mittels zweifachem Integrieren in entsprechende Versatzdaten zu transferieren. Es hat sich gezeigt, dass die Beschleunigungsdaten sowohl durch niederfrequente Effekte, wie Sensordrift, als auch durch hochfrequente Rauschanteile beeinflusst werden. Abbildung 4.8 stellt die Spektralanalyse des Beschleunigungssignals dar. Diese Abbildung zeigt auf, dass das Signal einen sehr ausgeprägten niederfrequenten Anteil besitzt, welcher als Sensordrift, eine Art langwellige Fehlmessung des Sensors, interpretiert werden kann. Der Sensordrift tritt vor allem bei Inertialsensoren, die Beschleunigungen und Drehraten messen, auf.

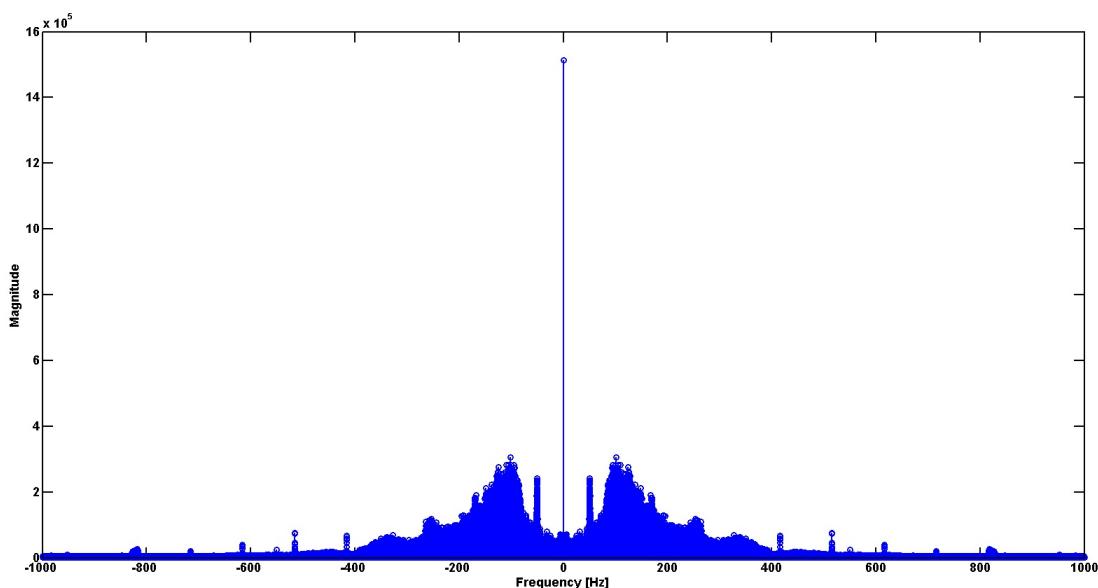


Abbildung 4.8: Spektralanalyse des Beschleunigungssignals [Lin14]

Da bereits geringfügige Fehler in den Rohdaten einen großen Einfluss auf die Qualität der Versatzdaten haben können, ist es wichtig die Rohdaten geeignet vor zuverarbeiten. Der Fehler, der durch den Sensordrift entsteht, summiert sich beim Integrieren zu einem deutlichen Fehlerterm auf und macht damit die Versatzdaten unbrauchbar. Das Deutsche Zentrum für Luft- und Raumfahrt stellt dafür einen Lösungsansatz vor, bei dem vor jedem Integrationsschritt die statischen Frequenzanteile herausgefiltert

werden. Die niederfrequenten Signalanteile können durch die Anwendung passender Hochpass-Filtermethoden kompensiert und das daraus resultierende Signal integriert werden. Hochfrequente Störanteile des Signals werden mittels numerischer Integration gedämpft bzw. gefiltert. Die aus der zweifachen Integration entstandenen Versatzdaten sind nun gemäß KoRil.821 und EN 13848 auswertbar.

Die transformierten Versatzdaten bieten die Möglichkeit den gemessenen Ausschlag als metrischen Wert abzulesen. In Abbildung 4.9 ist der Verlauf der Versatzdaten zu den entsprechenden Beschleunigungsdaten der Weiche aus Abbildung 4.3 abgebildet. Es lässt sich direkt erkennen, dass bei der Überfahrt dieser Weiche der Versatz auf bis zu 6 Millimeter ansteigt.

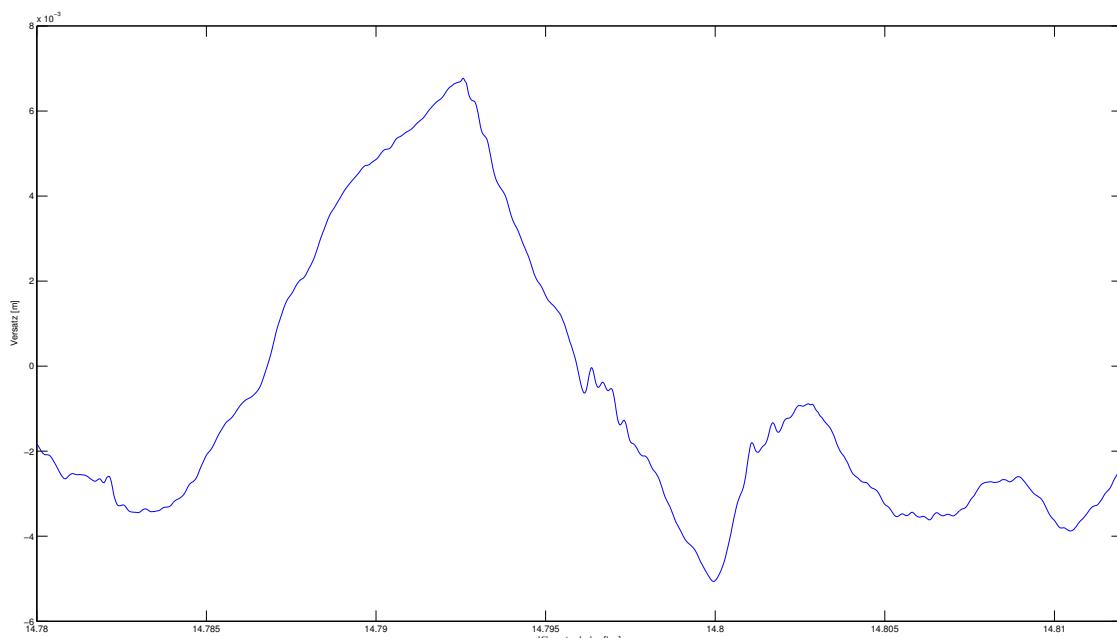


Abbildung 4.9: Ausschnitt einer Weiche (Versatzdaten)

Weiterhin lässt dieses Beispiel erkennen, dass das Signal bei den Versatzdaten nicht so sehr oszillierend ist wie bei den Beschleunigungsdaten, was sich in diesem Fall auch positiv auf das Klassifizierungsergebnis auswirkt. Ein weiterer Vorteil besteht darin, dass bereits eine Dimensionsreduzierung von ca. 2000 Datenpunkten pro 32 Meter Abschnitt auf 128 Dimensionen sehr gut abbildet, wodurch die Rechenzeit der Klassifizierungsalgorithmen verringert werden kann.

In Abbildung 4.10 ist die Dimensionsreduzierung auf 128 Datenpunkte, was einem Datenpunkt je 25 Zentimeter entspricht, dargestellt. Eine solche Reduzierung kann erfolgen durch das Ermitteln der Werte bei der Einteilung des Ausschnitts in 128 äquidistante Unterabschnitte. Die erhaltenen Funktionswerte repräsentieren den neuen Verlauf der Überfahrt. Positive und Negative Ausschläge werden sehr gut abgebildet und ungewolltes Rauschen, welches durch minimale Schwankungen der Sensorik entsteht, wird entfernt.

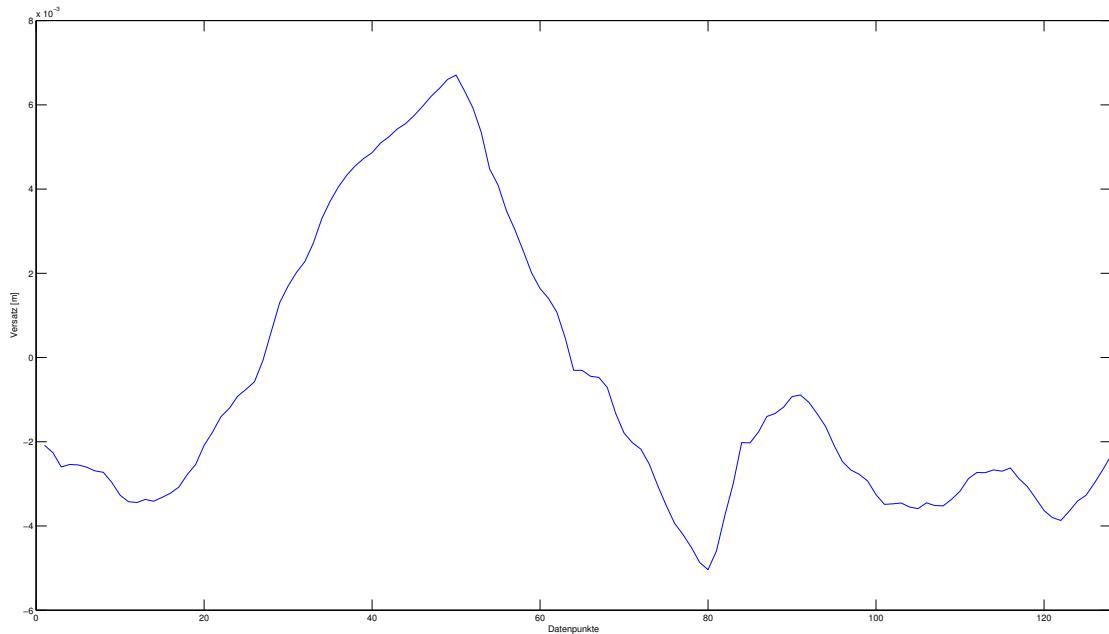


Abbildung 4.10: Reduzierung der Dimension auf 128 Datenpunkte

Zusätzlich wurden in Abbildung 4.11 die Mittelwertsverläufe der 300 Weichen (blau) und die per Zufall ausgesuchten 300 Nicht-Weichen Abschnitte (rot) dargestellt. Vor allem im Verlauf der ersten 64 Datenpunkte sind große Abweichungen zu erkennen. Die zweite Hälfte der beiden gemittelten Versatzdaten verläuft etwas ähnlicher, wobei auch hier kleinere Unterschiede zu erkennen sind. Der Verlauf der Nicht-Weichen ist dabei nicht zwingend repräsentativ, da 300 andere, per Zufall ausgewählte Streckenintervalle, einen abweichenden gemittelten Verlauf haben können.

Da die Versatzdaten wesentlich 'ruhiger' sind als die Rohdaten wird auch deutlich bei der Betrachtung des Frequenzspektrums. Die ersten 40 Fourierkoeffizienten der gemittelten Versatzdaten sind in Abbildung 4.12 dargestellt, wobei zu beachten ist, dass in dieser Darstellung die Frequenzen von links nach rechts niederfrequenter werden. Es ist nicht zwingend notwendig alle transformierten 64 Koeffizienten zu betrachten, da die Werte der nachfolgenden Koeffizienten, also die niedrigen Frequenzen, verschwindend gering sind und keinen großen Einfluss haben. Bereits ab dem 20. Fourierkoeffizienten sind kaum noch Unterschiede der beiden Frequenzspektren zu erkennen. Beide Spektren haben jedoch gemeinsam, dass vor allem hohe Frequenzen große Anteile haben und somit den Verlauf des Ausgangssignals bestimmen, niederfrequente Anteile tragen dazu nicht viel bei. Interessant ist der kleine Ausschlag bei dem 5. Fourierkoeffizienten der Nicht-Weichen, wodurch sich das Spektrum von dem der Weichen abhebt.

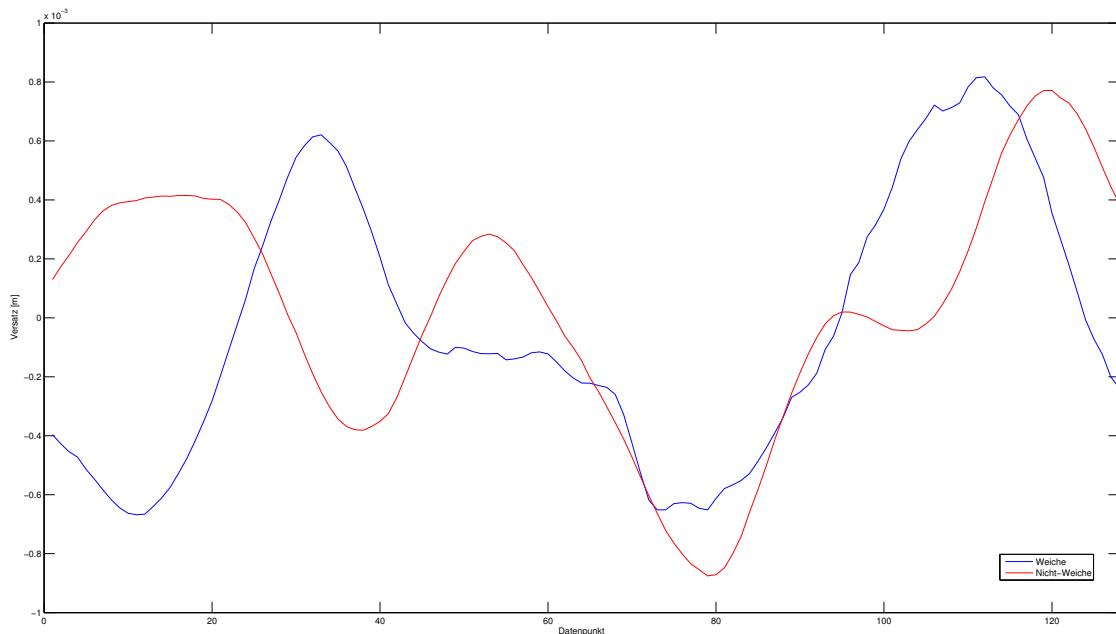


Abbildung 4.11: Gemittelte Versatzdaten der Weichen und Nicht-Weichen

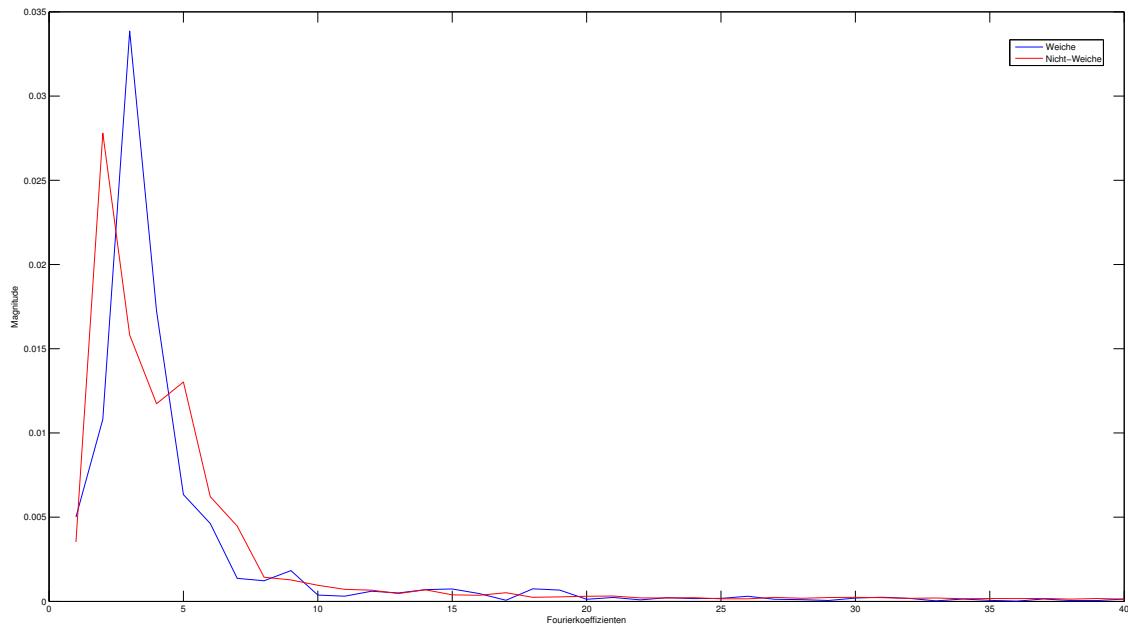


Abbildung 4.12: Frequenzspektrum der Weichen und Nicht-Weichen

Auch die Klassifikations-Korrelations Matrix des GMLVQ zeigt, dass vor allem die ersten Fourierkoeffizienten für die Klassifizierung eine hohe Relevanz haben. In Abbildung 4.13 ist zu erkennen, dass die Koeffizienten 7 bis 17 die relevanten Koeffizienten sind, was jedoch nicht zwingend bedeutet, dass die anderen absolut irrelevant sind. Das Klassifikationsergebnis des GMLVQ liegt bei ca. 82% nach 2000 Schritten und einem Prototyp pro Klasse. Anhand der Energiefunktion und dem Verlauf der Klassifikationsgenauigkeit (Accuracy) ist zu sehen, dass ein akzeptables Ergebnis bereits nach 500 Schritten erreicht ist.

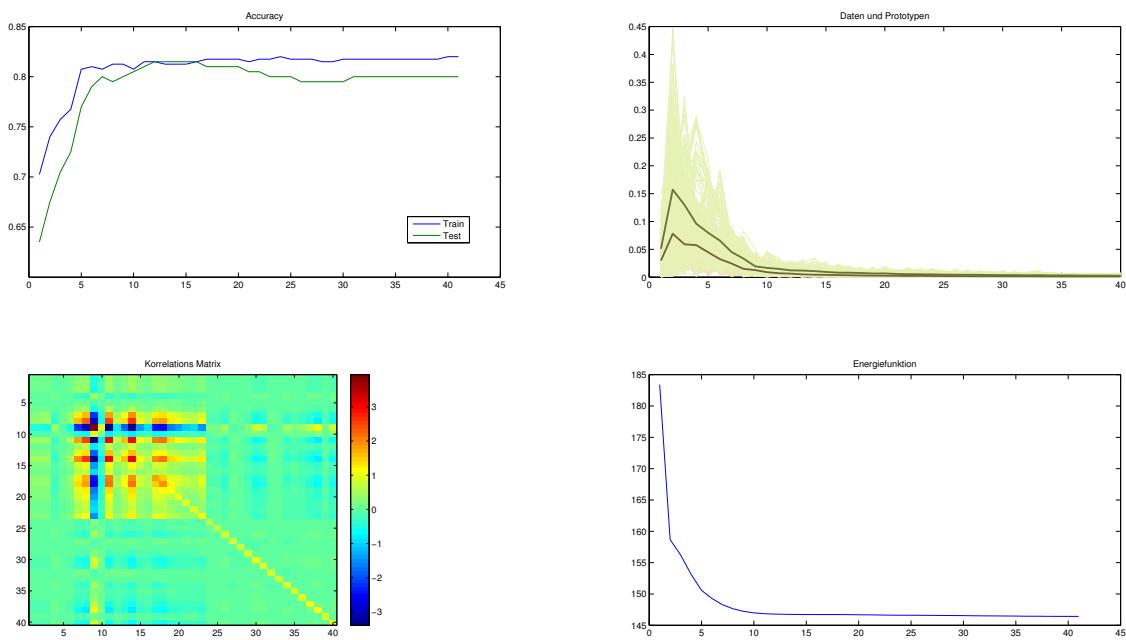


Abbildung 4.13: Ergebnis des GMLVQ mit 40 Fourierkoeffizienten

Die Support Vector Machine liefert ein annähernd gleiches Klassifikationsergebnis von ca. 80%. Bei der Verwendung der Radial Basis Function sind dabei etwas mehr als die Hälfte der Vektoren Support-Vektoren. Das Ersetzen durch eine lineare Kernel Funktion endet in gleichbleibenden Resultaten bezüglich Klassifikation und Support Vektoren. Im Vergleich dazu steht eine Klassifikationsgenauigkeit von nur 41% bei dem Versuch die Versatzdaten ohne Fourier-Transformation zu clustern. Dies zeigt, dass Transformationen aus der Signalverarbeitung durchaus ein sehr gutes Mittel sind um die vorliegenden Daten zu bearbeiten.

Die einfache (Level 1) Wavelet-Transformation zeigt bei den Versatzdaten bessere Klassifikationseigenschaften als bei den Beschleunigungsdaten. Der GMLVQ Algorithmus erreicht eine Genauigkeit von 60%, die Support Vector Machine 52,5%. Bessere Resultate werden, wie auch bei den Beschleunigungsdaten, bei der Anwendung eines weiteren Wavelet Dekompositionsschrittes erreicht. Diese Koeffizienten, basierend auf der in diesem Abschnitt betrachteten Weiche, sind in Abbildung 4.14 dargestellt.

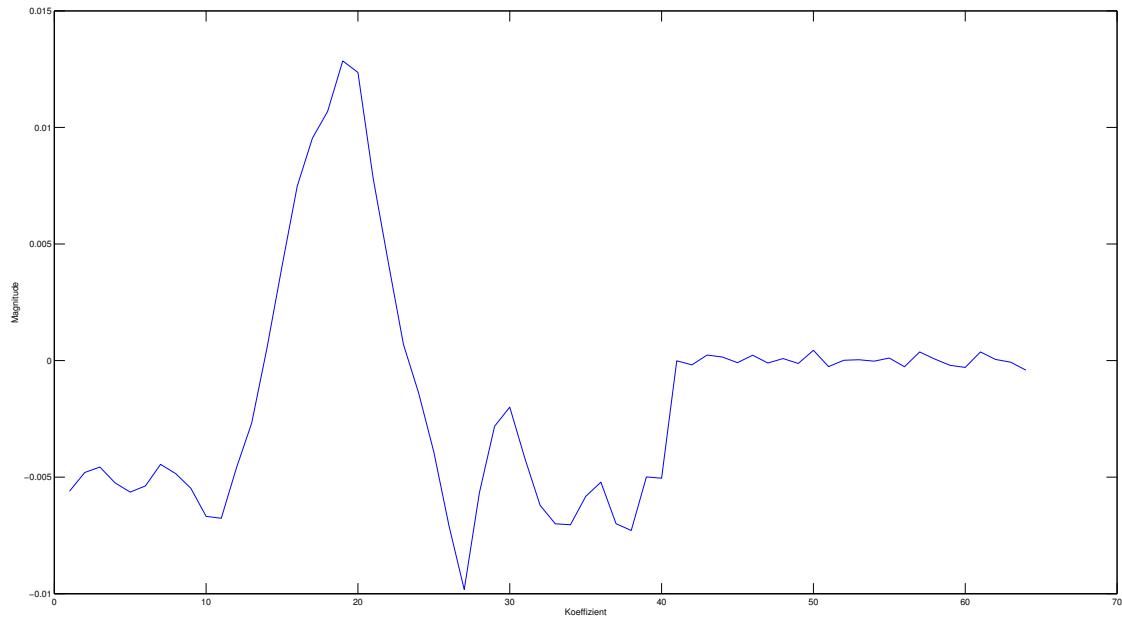


Abbildung 4.14: Level 2 Wavelet Dekomposition einer Weiche

Die approximierten Koeffizienten, die eine grobe Darstellung des ursprünglichen Signals widerspiegeln, sind in den ersten 40 Datenpunkten dargestellt. Die nachfolgenden Daten repräsentieren die detaillierten Koeffizienten. Die SVM erreicht unter Verwendung dieser Daten 65% Klassifikationsgenauigkeit, der GMLVQ erreicht 73% und liegt damit zwischen den Ergebnissen der nicht vorverarbeiteten Versatzdaten und den fourier-transformierten Daten.

4.5 Statistische Auswertung

Nach dem Antrainieren der Klassifikationsalgorithmen müssen die Daten getestet werden. Dieser Abschnitt bezieht sich dabei auf die Ergebnisse des GMLVQ bezüglich der Versatzdaten. Prinzipiell gibt es für die vorliegende Art der Daten zwei Möglichkeiten auf der ca. 80 Kilometer langen Strecke die Weichen anhand der angelernten Prototypen zu finden: Die Anwendung äquidistante Intervalle oder gleitende Intervalle. In beiden Fällen müssen beim Einteilen der Strecke in Intervalle die gleichen Vorverarbeitungsschritte mit den selben Parametern wie bei dem gewählten Klassifikationsalgorismus durchgeführt werden. Das heißt, dass die Länge des Intervalls gleich lang und die Anzahl der Datenpunkte in diesem Abschnitt gleich groß sein muss. Bei der Fourier- und Wavelet-Transformation sollte die Anzahl der Koeffizienten übereinstimmen und gegebenenfalls das Mother Wavelet das gleiche sein. Die äquidistanten Intervalle, die Zerlegung der gesamten Strecke in gleichgroße Teile, sind nicht sehr rechenintensiv, haben aber einen großen Nachteil. Befindet sich eine Weiche genau zwischen den Intervallen,

beziehungsweise eine Stück der Weiche im ersten und das andere Stück der Weiche in dem zweiten Intervall, kann diese Weiche möglicherweise nicht als solche erkannt werden. Um dieses Problem zu umgehen, können gleitende Intervalle genutzt werden, wo das Intervall gleitend von einem Datenpunkt zum Nächsten geschoben wird. Diese Variante ist verhältnismäßig rechenintensiv, umgeht aber die Problematik, dass ein zu erkennender Einzelfehler bzw. eine Weiche auf zwei Intervalle aufgeteilt ist. Für jedes Intervall muss letztendlich geprüft werden zu welcher Klasse es gehört. Es wird der Abstand zum nächsten Prototypen, der die jeweilige Klasse repräsentiert, bestimmt.

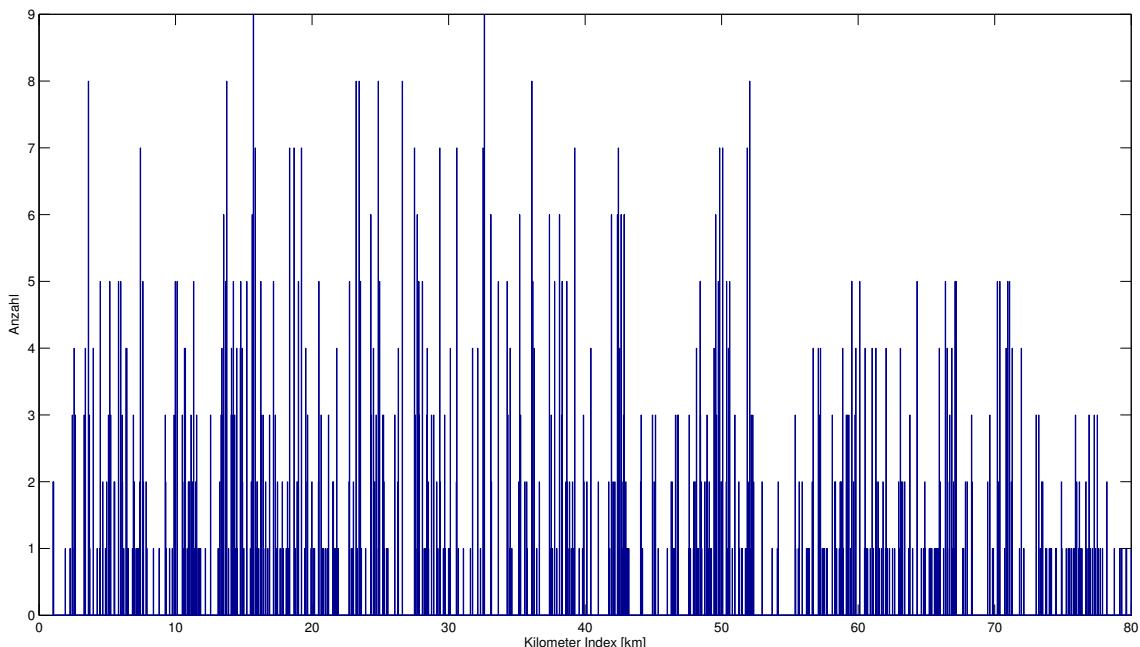


Abbildung 4.15: Häufigkeiten gefundener Weichen bei 9 Messreihen

Abbildung 4.15 zeigt ein Histogramm in dem die gefundenen Weichen auf der 80 Kilometer langen Strecke dargestellt sind. Grundlage sind äquidistante Intervalle mit einer Länge von 32 Metern und die Klassifikation der Fourierkoeffizienten mittels GMLVQ. Zusätzlich wurde die Klassifikation an 9 unterschiedlichen Tagen durchgeführt. Jeder Balken repräsentiert die Häufigkeit, wie oft eine Weiche in einem Streckenabschnitt über 9 Messreihen hinweg gefunden wurde. Eine Auswertung mittels Histogramm bietet zusätzlich die Möglichkeit, gefundene Weichen über mehrere Datenreihen, falls vorhanden, zu beobachten und anhand der Häufigkeit des Auftretens zu verifizieren. Es lässt sich allgemein feststellen, dass je mehr Daten vorhanden sind, desto besser sind auch die Klassifikationsbedingungen. Dies resultiert daher, dass neben den zusätzlichen Daten für die Überfahrten der Weichen, die für das Antrainieren der Lernalgorithmen hilfreich sind, die Option genutzt werden kann, mehrere Messreihen für statistische Auswertungen zu nutzen.

4.6 Vergleich und Auswertung der Ergebnisse

In diesem Abschnitt werden die Ergebnisse einiger durchgeföhrter Tests aufgezeigt. Das Klassifikationsergebnis ist dabei stark abhängig von der Datenvorverarbeitung. Einfluss haben die Fourier- und Wavelet-Transformation sowie die Wahl, ob mit den Beschleunigungsdaten (BD) oder den Versatzdaten (VD) gearbeitet werden soll. Die unterschiedlichen Resultate unter der Verwendung von GMLVQ und SVM sind in den nachfolgenden Tabellen dargestellt. Die Klassifikationsgenauigkeit bezieht sich dabei auf das jeweilige Ergebnis der Klassifikation mittels der Testdaten. Die Resultate der Trainingsdaten sind nicht aussagekräftig und wurden deshalb auch nicht verwendet. Bei der Support Vector Machine wurde als Kernel Funktion die Radial Basis Funktion verwendet.

In Tabelle 4.1 sind die Klassifikationsergebnisse in Abhängigkeit der Intervalllänge der Weichen bzw. der Nicht-Weichen Ausschnitte dargestellt. Die durchschnittliche Weichenlänge wurde auf 32 Meter festgelegt, es wurden jedoch auch kürzere und längere Intervalle getestet, um zu sehen wie die Algorithmen mit unterschiedlich langen Gleisabschnitten funktionieren. Außerdem wurden die verwendeten Daten für diesen Test nicht mit Methoden der Signalverarbeitung bearbeitet, es wurde an dieser Stelle mit den originalen Beschleunigungs- bzw. Versatzdaten gearbeitet. Grundsätzlich lässt sich erkennen, dass die Klassifizierung der Beschleunigungsdaten nicht sehr erfolgreich ist, unabhängig der Intervalllänge. Unterschiede gibt es jedoch bei den Versatzdaten, da wurden die besten Resultate, bei GMLVQ und SVM, bei einer Länge von 64 Metern mit 78% bzw. 75,5% erreicht. Auch für 128 Meter lange Abschnitte liefern die zwei Algorithmen noch annehmbare Ergebnisse, für kürzere Intervalle sind die unverarbeiteten Daten eher unbrauchbar.

Länge [m]	GMLVQ		SVM	
	BD	VD	BD	VD
8	44,5%	46%	50,5%	55%
16	48%	61%	51%	58,5%
32	55%	63%	50,5%	68%
64	44%	78%	50%	75,5%
128	57%	76,5%	51%	69,5%

Tabelle 4.1: Klassifikationsergebnisse der unverarbeiteten Beschleunigungsdaten (BD) und Versatzdaten (VD) in Abhängigkeit der Intervalllänge

Dass die Anwendung der Fourier-Transformation und die Klassifikation anhand des Fourierspektrums sinnvoll ist, zeigt sich in Tabelle 4.2. Hier wurde mit dem GMLVQ eine sehr gute Klassifikationsgenauigkeit von 92,5% erreicht. Dabei wurden 128 Fourierkoeffizienten der Beschleunigungsdaten bei Gleisabschnitten von 64 Meter Länge verwendet.

Für die betrachteten Beispiele liefert der GMLVQ für fouriertransformierte Koeffizienten bessere Resultate. Die Ergebnisse der SVM liegen weit hinter den Werten des GMLVQ zurück.

Länge [m]	GMLVQ		SVM	
	BD	VD	BD	VD
8	65,5%	55,5%	51%	52%
16	64%	77%	50,5%	68%
32	71,5%	80%	50%	64,5%
64	92,5%	79%	50%	67%
128	60,5%	80,5%	50,5%	62%

Tabelle 4.2: Klassifikationsergebnisse des Frequenzspektrums der Beschleunigungsdaten (BD) und Versatzdaten (VD) in Abhängigkeit der Intervalllänge

Die erreichten Resultate mittels der Wavelet-Transformation mit einer zweifachen Wavelet Dekomposition liegen zwischen den Ergebnissen der unverarbeiteten Daten und der fouriertransformierten Daten. Es hat sich gezeigt, dass die Versatzdaten besser geeignet sind für das Klassifizieren. Tabelle 4.3 kann entnommen werden, dass die besten Ergebnisse beim GMLVQ und SVM jeweils bei einer Intervalllänge von 64 Metern liegen. Der GMLVQ liefert auch bei diesen Berechnungen bessere Klassifikationsgenauigkeiten als die SVM.

Länge [m]	GMLVQ		SVM	
	BD	VD	BD	VD
8	45%	56,5%	45,5%	56%
16	55,5%	61,5%	48,5%	58,5%
32	65,5%	73%	51%	65%
64	52,5%	77%	65%	72%
128	55%	76,5%	49,5%	57,5%

Tabelle 4.3: Klassifikationsergebnisse der Waveletkoeffizienten der Beschleunigungsdaten (BD) und Versatzdaten (VD) in Abhängigkeit der Intervalllänge

Grundlage der oben abgebildeten Ergebnisse der Wavelet-Transformation war jeweils ein db6 Wavelet. In Tabelle 4.4 ist zu erkennen, dass die Qualität der Klassifikation auch von der Wahl des Mother Wavelets abhängig ist. Dafür wurden die Versatzdaten mit einer Intervalllänge von 64 Metern getestet. Eine Übersicht der verwendeten Wavelets ist in Anhang A abgebildet, es ist eine Auswahl von Daubechies Wavelets (db) und Symlets (sym). Die Schwierigkeit der Wavelet-Transformation liegt darin, ein passendes Mother Wavelet zu finden. Wenn es gelingt ein Wavelet zu erstellen, welches bestmöglich auf die Daten passt, könnten die Klassifikationsergebnisse bessere Werte annehmen. Ein ähnlicher Ansatz wurden bereits in [Wol13] vorgestellt, bei dem die

Gleislageabweichungen mit Hilfe von Fehlerreferenzfunktionen beurteilt werden.

Mother Wavelet	GMLVQ	SVM
db3	74,5%	74%
db6	77%	72%
db12	78,5%	69,5%
db20	75%	71%
sym2	71,5%	74%
sym4	74,5%	66,5%
sym10	74,5%	69,5%
sym15	71%	66%

Tabelle 4.4: Klassifikationsergebnisse in Abhängigkeit des gewählten Mother Wavelets bei einer Intervalllänge von 64 Metern mit Versatzdaten

Alle in diesem Abschnitt berechneten Ergebnisse des GMLVQ wurden mit jeweils einem Prototypen pro Klasse durchgeführt. Da mehrere Prototypen auch zu besseren Klassifikationsresultaten führen können, wurde noch der Einfluss der Anzahl der Prototypen auf das Ergebnis getestet (Tabelle 4.5). Grundlage war das bisher beste Resultat von 92,5% bei den fouriertransformierten Beschleunigungsdaten. Das Ergebnis zeigt, dass die Anzahl der Prototypen keinen Einfluss auf die Genauigkeit der Klassifikation bei diesen Daten hat. Demnach ist es ausreichend mit einem Prototypen pro Klasse den GMLVQ in der Lernphase anzutrainieren.

# Prototypen	GMLVQ
1	92,5%
2	92%
3	92,5%
5	92%

Tabelle 4.5: Klassifikationsergebnisse des GMLVQ in Abhängigkeit der Anzahl der Prototypen pro Klasse

Zusammenfassend zeigt sich, dass sich die Daten der Deutsche Bahn AG gut bis sehr gut bezüglich des Findens von Weichen klassifizieren lassen. Die Grundlage bilden die ersten Verarbeitungsschritte, wie das Korrigieren der GPS Ungenauigkeiten und das Reduzieren der Dimensionen. Die Tests zeigen, dass es sehr nützlich ist, die Daten mit einer passenden Methode der Signalverarbeitung zu bearbeiten um die Frequenzen zu extrahieren. Dabei ist es aber nicht zwingend notwendig die Beschleunigungsdaten durch zweimaliges Integrieren zu Versatzdaten zu transformieren, da das mit Abstand beste Klassifikationsresultat (92,5%) aus den Beschleunigungsdaten und deren fouriertransformierten Koeffizienten hervor ging. Die Support Vector Machine lieferte meist schlechtere Ergebnisse als der GMLVQ Algorithmus, ist aber dafür in der Lernphase

wesentlich schneller. Generell ist für diese Art von Daten der GMLVQ zu bevorzugen. Einerseits liefert er bessere Klassifikationsgenauigkeiten und andererseits besteht die Möglichkeit das betrachtete 2-Klassenproblem auf ein Problem mit mehreren Klassen auszuweiten. So können beispielsweise verschiedene Fehlertypen oder bekannte Abweichungen als jeweils einzelne Klasse definiert werden. Die Verwendung der Fourier-Transformation liefert gegenüber der Wavelet-Transformation ebenfalls bessere Ergebnisse. Jedoch ist die Wavelet-Transformation nicht zu vernachlässigen, denn durch die Verwendung eines passenden Mother Wavelets könnten noch bessere Klassifikationsergebnisse erreicht werden. Dieses Wavelet ist für die Daten jedoch nicht bekannt. Für die zu betrachtende Intervalllänge bieten sich Werte zwischen 32 und 128 Metern an, in diesen Bereichen konnten die besten Resultate erreicht werden, für andere Fehlertypen können jedoch andere Intervalllängen besser geeignet sein. Wenn die Möglichkeit besteht die Datenverläufe von mehreren Streckenüberfahrten zu verarbeiten, so sollte das genutzt werden um zusätzlich durch die Auswertung eines Histogramms die Häufigkeiten der identifizierten Weichen zu zählen und zu analysieren.

4.7 Zusammenfassung der Methode

Folgend wird der komplette Ablauf der Methode, beginnend mit der Eingabe der Daten bis hin zum Ergebnis, zusammengefasst. In Abbildung 4.16 ist dieser Ablauf zusätzlich schematisch dargestellt und veranschaulicht die wichtigsten Schritte. Ausgangspunkt für das Erkennen von Einzelfehlern im Gleisoberbau sind die Daten über die Qualität des Gleises, in diesem Fall die vertikalen Beschleunigungsdaten gemessen am Radsatz. Bei Nutzung der Beschleunigungsdaten wurden die besten Resultate für das Erkennen von Weichen erzielt. Es kann aber auch mit den Versatzdaten gearbeitet werden, mit denen letztendlich auch gute Ergebnisse erreicht wurden. Bevor die Datenvorverarbeitung begonnen werden kann, sollte die zu untersuchende Intervalllänge für Weichen bzw. die Nicht-Weichen Abschnitte festgelegt werden. Werte zwischen 32 und 128 Metern haben sich als sehr brauchbar erwiesen. Anschließend sollten die GPS Ungenauigkeiten der einzelnen Überfahrten korrigiert und die extrahierten Intervalle auf eine gleiche Anzahl von Datenpunkten, wenn möglich auf eine Zweierpotenz, minimiert werden. Als sehr effektiv haben sich die Methoden der Signalverarbeitung gezeigt, wobei sich die Fourier-Transformation bei den ersten Tests als besser geeigneter darstellt als die Wavelet-Transformation. Sollte jedoch ein passendes Mother Wavelet für die Wavelet-Transformation gefunden werden, kann sich dies auch ändern. Die fouriertransformierten Koeffizienten bzw. das Fourierspektrum mit den in dem Ausgangssignal enthaltenen Frequenzen, bildet somit die Grundlage für die Klassifikationsalgorithmen. Das vorliegende 2-Klassen Problem kann mit passenden Methoden analysiert werden. Gewählt wurden hier die Support Vector Machine (SVM) und der Generalized Matrix Learning Vector Quantization (GMLVQ) Algorithmus. Für die untersuchten Daten hat sich gezeigt, dass der GMLVQ bessere Resultate liefert als die SVM. Außerdem bietet der GMLVQ die Möglichkeit das 2-Klassen Problem um weitere Klassen zu erweitern, dies ist bei der

SVM nicht möglich. Jedoch existieren einige Varianten von Support Vector Machines, die mit mehreren Klassen arbeiten können [Chi02]. Nachdem der Algorithmus antrainiert wurde, kann das eigentliche Testen der Daten beginnen. Dazu wird eine komplette Messreihe in Abschnitte zerlegt und exakt die gleichen Vorverarbeitungsschritte (Datendimension, Transformation) wie bei den Trainingsdaten angewendet. Jeder Abschnitt wird nun einer Klasse des angelernten Algorithmus zugeteilt. Weiterhin können die letzten beiden Schritte auf die Messreihen mehrerer Tage angewandt werden, wodurch sich das Ergebnis zusätzlich durch eine statistische Auswertung verifizieren lässt. Das Resultat ist eine Aussage darüber, ob sich auf einem zu untersuchendem Gleisabschnitt Weichen befinden oder nicht.

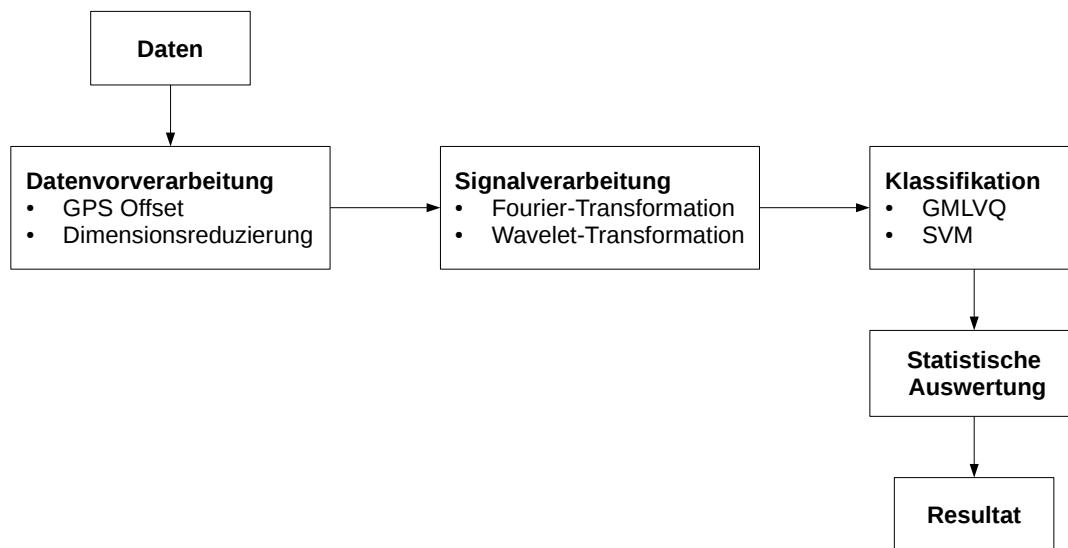


Abbildung 4.16: Schematischer Ablauf der Methode

Das endgültige Resultat ist dabei abhängig von allen beschriebenen Schritten dieser vorgestellten Methode. Wie bereits im vorherigen Abschnitt anhand der unterschiedlichen Berechnung gezeigt werden konnte, haben die Parameter unterschiedlich hohen Einfluss auf das Ergebnis der Klassifikation. Die beste Klassifikationsgenauigkeit von 92,5% konnte unter folgenden Bedingungen erreicht werden: Beschleunigungsdaten, 64 Meter Intervall mit 256 Datenpunkten, Frequenzspektrum mit 128 Koeffizienten und GMLVQ mit einem Prototyp pro Klasse.

5 Schlussbetrachtung

5.1 Ausblick und Limitierung der Arbeit

Die in dieser Arbeit vorgestellte Methode für das Erkennen von Einzelfehlern im Gleisoberbau mittels mathematischer Verfahren auf Basis gemessener vertikaler Beschleunigungsdaten liefert gute bis sehr gute Ergebnisse. Die Berechnungen wurden dabei exemplarisch anhand von Weichen durchgeführt. Das langfristige Ziel wird es jedoch sein, Einzelfehler wie zum Beispiel abgesenkte Schwellen oder starke vertikale Abweichungen an Bahnübergängen zu identifizieren. Das betrachtete 2-Klassen Problem kann somit um weitere Klassen erweitert werden, wodurch unterschiedliche Fehler separat gefunden werden können. In Kombination mit dem bereits erwähnten Prognosemodell [Lin14] besteht die Möglichkeit Fehler frühzeitig zu erkennen und zu klassifizieren und über eine gewisse Zeitspanne hinweg zu beobachten. Durch die resultierende Prognose für die weitere Entwicklung des Fehlers, lassen sich Instandhaltungsmaßnahmen frühzeitig planen und durchführen, was letztendlich zu Kosteneinsparungen führt. Wirtschaftlich gesehen bietet der Einsatz einer solchen Methode sehr hohes Potential für zukünftiges effektiveres Vorgehen bei Wartung und Instandhaltung.

Im Rahmen dieser Arbeit konnten nur einige ausgewählte mathematische Verfahren untersucht und die Anwendbarkeit auf die vorliegenden Daten ausgewertet werden. So existieren neben der Fourier- und Wavelet- Transformation noch andere signalanalytische Verfahren wie beispielsweise das Anwenden verschiedener Hoch- und Tiefpassfilter. Weiterhin konnten für die Wavelet-Transformation nur einige Standard Mother Wavelets getestet werden. Das Finden eines passenden Wavelets ist ein sehr komplexes Problem und wurde in dieser Arbeit nicht weiter betrachtet. Das ein solches Wavelet jedoch sehr hilfreich sein könnte, ist in [Wol13] beschrieben. Für das Klassifizieren wurden zwei Algorithmen, der GMLVQ und die SVM, näher beschrieben und angewendet. Es existieren viele weitere Versionen der Learning Vector Quantization, die, abhängig von den zu untersuchenden Daten, unterschiedliche Vor- und Nachteile haben. Ein interessanter Ansatz ist in [Bun12] beschrieben, bei dem der GMLVQ für komplexe Daten angepasst wurde, was sich gegebenenfalls positiv auf die fouriertransformierten Koeffizienten auswirken könnte. Dies konnte jedoch im Rahmen dieser Arbeit nicht verifiziert werden. Auch die begrenzte Anzahl an vorhandenen und brauchbaren Daten schränkte die Arbeit ein. Mit insgesamt ca. 300 Überfahrten von Weichen, fällt die Anzahl der Vektoren in dieser Klasse verhältnismäßig gering aus.

Dass die Methode Erfolg hat, konnte mittels Weichen gezeigt werden, welche in einem Wellenlängenbereich von ca. 30 bis 100 Metern liegen. Einzelfehler aber liegen im Wellenlängenbereich von ca. 3 bis 10 Metern. Das heißt, dass für solche kurzweligen Fehler die entwickelte Methode unter Umständen abweichende Klassifikationsergebnisse liefert und die entsprechenden Datenverarbeitungsschritte angepasst werden müssen.

5.2 Fazit

Die im Rahmen dieser Arbeit entwickelte Methode liefert einen ersten Ansatz für die Analyse von Messdaten bezüglich der Qualität des Gleises. Eine Klassifikation, ob ein Streckenabschnitt ein bestimmtes Muster aufweist oder nicht, und somit einem Fehlertyp entspricht, konnte erfolgreich durchgeführt werden. Es wurden unter anderem Methoden aus der Signalverarbeitung verwendet, die sich als sehr zielführend erwiesen haben. Die Klassifikation selber wurde mittels Prototyp-basierenden Lernalgorithmen durchgeführt. Die durch die Deutsche Bahn AG mittels Beschleunigungssensorik aufgezeichneten Daten eignen sich unter bestimmten Umständen sehr gut um potentielle Einzelfehler zu klassifizieren. Dies konnte am Beispiel von Weichen gezeigt werden, wobei das beste erreichte Klassifikationsergebnis bei über 90 Prozent lag. Das Resultat ist dabei vor allem von der zu untersuchenden Intervalllänge und der gewählten Datenvorverarbeitung abhängig. Durch eine weitere Optimierung der Methode, beispielsweise durch verbesserte Datenvorverarbeitungsschritte oder angepasste Klassifikationsalgorithmen, sind Ergebnisse von über 95 Prozent sehr realistisch. Auch das Erkennen und Finden von unterschiedlichen Einzelfehlern bzw. Fehlerarten sollte mit mehreren Klassen realisierbar sein. Um dies zu verifizieren ist es notwendig mehr Daten zu sammeln und in entsprechende Kategorien aufzuteilen. Weitere Informationen wie die Außentemperatur oder das Wetter bei der Überfahrt wären außerdem sehr hilfreich, da das Gleisverhalten und die Messsensorik auch von diesen Parametern abhängig sind.

Neben einer Verbesserung der Sicherheit und Erhöhung des Fahrkomforts, können auch wirtschaftliche Faktoren wie Instandhaltungs- und Reparaturkosten des Gleises angepasst werden. In Kombination mit mittel- bis langfristiger Instandhaltungsplanung ergeben sich neue Möglichkeiten der kosteneffektiven Fehlerbehebung. Eine Installation der Messsensorik an im Regelbetrieb befindlichen Schienenfahrzeugen, die auf viel befahrenen Strecken verkehren, könnte außerdem die Anzahl von speziellen Messzügen beeinflussen und verringern. Die Option, an jedem Tag Qualitätsdaten des Gleises aufzuzeichnen und mittels geeigneter Methoden zu verarbeiten, könnte sich in Zukunft durchsetzen und so zum Standard werden. Grundlage dafür ist jedoch die Validierung dieser hier vorgestellten oder ähnlicher Methoden, die über einen langen Zeitraum hinweg fehlerfreie Ergebnisse liefern müssen. Zukünftige Herausforderungen werden darin bestehen, eine Akzeptanz der neuen Methoden zu schaffen und schrittweise die Integration in bestehende operative Unternehmensprozesse zu ermöglichen, wodurch letztendlich eine Anpassung der momentan gültigen Normen und Richtlinien notwendig sein wird.

Anhang A: Beispiel Wavelets

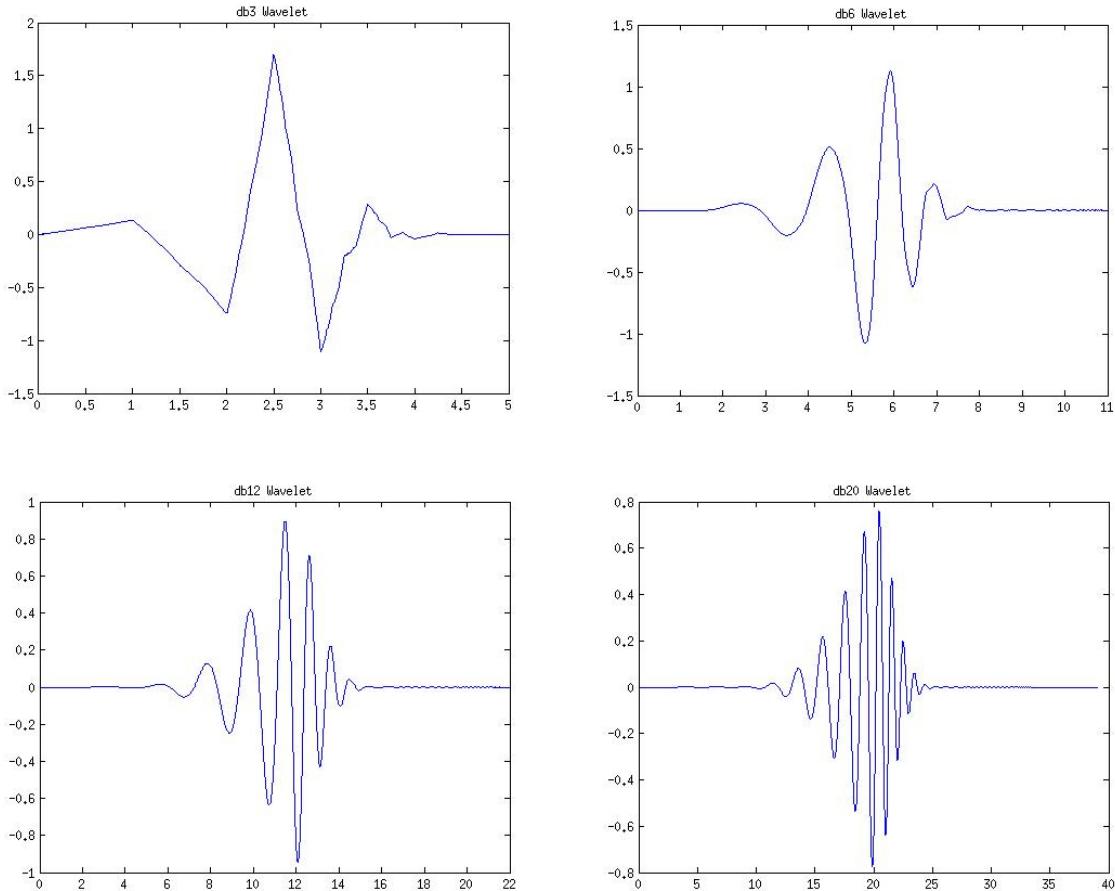


Abbildung A.1: Daubechies Wavelets

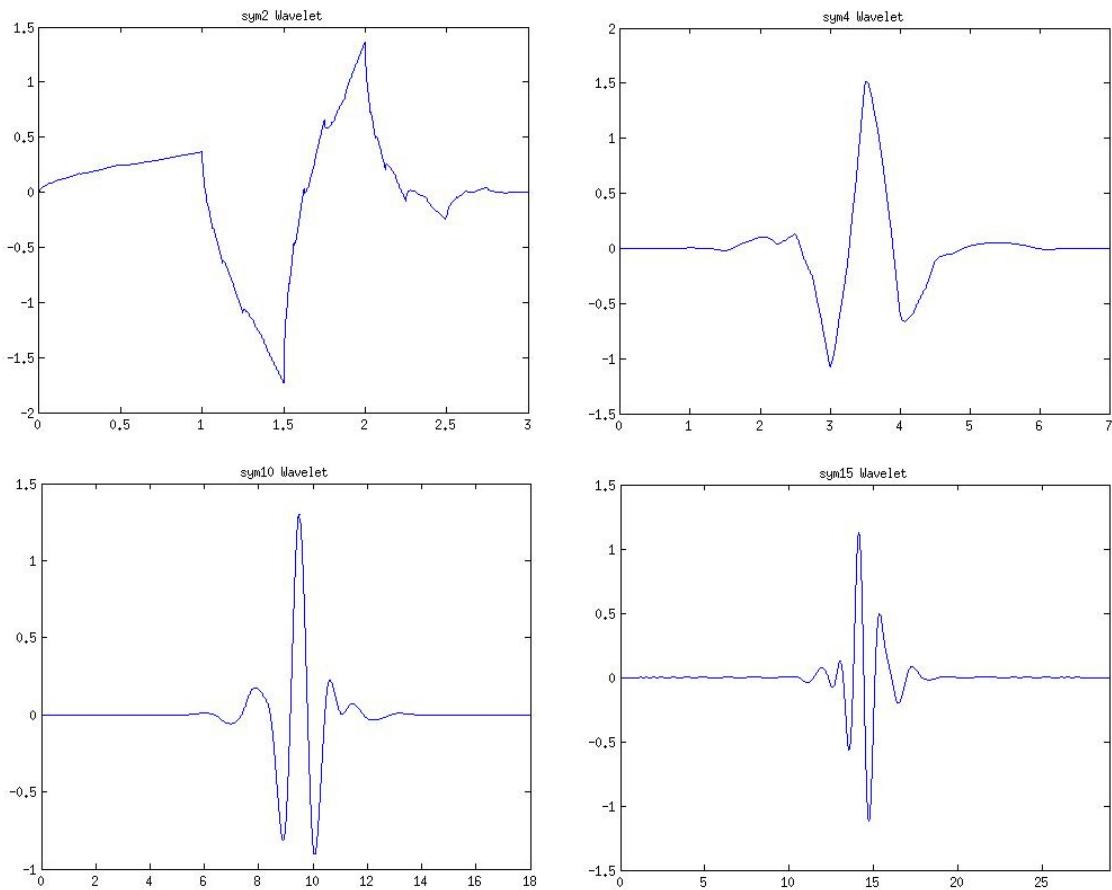


Abbildung A.2: Symlets Wavelets

Literaturverzeichnis

[Aut01] http://www.automain.eu/IMG/pdf/automain_flyer-2.pdf, Stand: 28.02.2014

[Bae08] Baeßler, M.: *Lageveränderungen des Schottergleises durch zyklische und dynamische Beanspruchungen*, Dissertation, TU Berlin, Fakultät VI – Planen Bauen Umwelt, 2008.

[Bie08] Biehl, M.; Hammer, B.; Schneider, P.: *Matrix Learning in Learning Vector Quantization*, Machine Learning Reports, 2008.

[Bie09] Biehl, M.; Hammer, B.; Schleif, F.-M.; Schneider, P.; Villmann, T.: *Stationarity of Matrix Relevance Learning Vector Quantization*, Machine Learning Reports, Vol 3, MLR-01-2009, 1-17, 2009.

[Bla03] Blatter C.: *Wavelets - Eine Einführung*, 2. Auflage, Vieweg, 2003.

[Bun12] Bunte, K.; Schleif, F.-M.; Biehl, M.: *Adaptive Learning for complex-valued data*
In: Proceedings of ESANN 2012, 387–392, 2012.

[But11] Butz, T.: *Fouriertransformation für Fußgänger*, 7. aktualisierte Auflage, Vieweg + Teubner, 2011.

[Bri97] Brigham, E. O.: *FFT-Anwendungen*, R. Oldenbourg Verlag, 1997.

[Chi02] Chih-Wei, H.; Chih-Jen, L.: *A Comparison of Methods for Multiclass Support Vector Machines*, IEEE Transactions on Neural Networks, 2002.

[Coo65] Cooley, J. W., Tukey J. W.: *An Algorithm for the Machine Computation of the Complex Fourier Series*, Mathematics of Computation, Vol. 19, pp. 297-301, April 1965.

[Eur10] Europäische Norm, EN 13848-5:2008+A1, *Bahnanwendungen - Oberbau - Qualität der Gleisgeometrie - Teil 5: Geometrische Qualitätsstufen - Gleise*, Apr. 2010.

[Har12] Harth, C.: *Erweiterung von Generalized [Relevance|Matrix] Learning Vector Quantization zur Anwendung auf funktionale Daten*, Masterarbeit, Hochschule Mittweida, 2012.

[Hof05] Hoffmann R.: *Grundlagen der Frequenzanalyse*, 2. Auflage, expert Verlag, 2005.

- [Kae12] Kästner, M.; Hammer, B.; Biehl, M.; Villmann, T.: *Functional relevance learning in generalized learning vector quantization*, Neurocomputing 90: 85-95, 2012.
- [Koh90] Kohonen, T.: *The Self-Organizing Map*, In: Proceedings of the IEEE, Vol. 78, No. 9, pp. 1470 - 1472, 1990.
- [Kon04] Konzernrichtlinie der Deutschen Bahn AG, *Grundlagen der Oberbauinspektion 821.1000*, Mai 2004.
- [Kru02] Krüger, K.: *Transformationen - Grundlagen und Anwendungen in der Nachrichtentechnik*, Vieweg, 2002.
- [Kus78] Kushner, H.; Clark, D.: *Stochastic Approximation Methods for Constrained and Unconstrained Systems*, Springer Verlag, 1978.
- [Lib11] Chang, Chih-Chung and Lin, Chih-Jen: *LIBSVM: A library for support vector machines*, ACM Transactions on Intelligent Systems and Technology, Volume 2, 2011. (Download: <http://www.csie.ntu.edu.tw/~cjlin/libsvm>)
- [Lic07] Lichtberger, B.: *Das System Gleis und seine Instandhaltung*, Eisenbahningenieur (EI), Jan. 2007.
- [Lic09] Lichtberger, B.: *Das System Gleis - Optimierungspotenziale aus Sicht des Instandhalters*, Eisenbahn-Kurier, 2009.
- [Lic10] Lichtberger, B.: *Handbuch Gleis : Unterbau, Oberbau, Instandhaltung, Wirtschaftlichkeit*. 3. überarbeitete Neuauflage. Ro: Eurailpress, 2010.
- [Lin14] Linder, C.: *Prognoseverfahren zur Gleislageabweichung bei Einzelfehlern*, Eisenbahningenieur (EI), Feb. 2014.
- [Mal89] Mallat, S.: *A theory for multiresolution signal decomposition: the wavelet representation*, IEEE Pattern Anal. and Machine Intell., vol. 11, no. 7, pp 674–693, 1989.
- [Neb14] Nebel, D.; Hammer, B.; Villmann, T.: *Supervised Generative Models for Learning Dissimilarity Data*, Proc. of European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning (ESANN'2014), publisher i6doc.com, 2014.
- [Pic01] http://www.atsb.gov.au/media/4182419/ri-2011-015_fig4.jpg, Stand: 23.01.2014

- [Pek05] Pekalska, E.; Duin, R. P. W.: *The Dissimilarity Representation for Pattern Recognition*, World Scientific Publishing Co. Pte. Ltd., 2005.
- [Riv13] RIVAS - Railway Induced Vibration Abatement Solutions: *Overview of Methods for Measurement of Track Irregularities Important for Ground-Borne Vibration*, Deliverable D2.5, 02.07.2013.
- [Sat95] Sato, A.; Yamada, K.: *Generalized Learning Vector Quantization*, In: Advances in Neural Information Processing Systems 8: Proceedings of the 1995 Conference, pp. 423 -429, MIT Press, 1995.
- [Sch02] Schölkopf B.; Smola A. J.: *Learning with Kernels: Support Vector Machines, Regularization, Optimization, and Beyond*, MIT Press, 2002.
- [Sch09] Schneider, P.; Biehl, M.; Hammer, B.: *Adaptive Relevance Matrices in Learning Vector Quantization*, MIT Press, 2009.
- [Ste01] Steinwart, I.: *On the Influence of the Kernel on the Consistency of Support Vector Machines*, Journal of Machine Learning Research, 2001.
- [Ste08] Steinwart, I.; Christmann A.: *Support Vector Machines*, Springer, 2008.
- [Sto13] Stoffel, A.: *Wavelets und Filterbänke*, Fachhochschule Köln, 2013.
- [Vei06] Veit, P.: *Qualität im Gleis - Luxus oder Notwendigkeit?*, Eisenbahningenieur (EI), Dez. 2006.
- [Vil12] Villmann, T.: *Vorlesungsmitschriften Computational Intelligence II WS12/13*, 2012.
- [Vil14] Villmann, T.; Haase, S.; Kaden M.: *Kernelized Vector Quantization in Gradient-Descent Learning*, 2014.
- [Wol13] Wolter, K. U., Erhard F.: *Beurteilung von Gleislageabweichungen mit Hilfe von Fehlerreferenzfunktionen*, Eisenbahntechnische Rundschau (ETR), Sep. 2013.

Erklärung

Hiermit erkläre ich, dass ich meine Arbeit selbstständig verfasst, keine anderen als die angegebenen Quellen und Hilfsmittel benutzt und die Arbeit noch nicht anderweitig für Prüfungszwecke vorgelegt habe.

Stellen, die wörtlich oder sinngemäß aus Quellen entnommen wurden, sind als solche kenntlich gemacht.

Mittweida, 15.04.2014