

Lehrstuhl für Fluidmechanik und Prozessautomation
Technische Universität München

Automatische Schadenserkennung an Getränkekästen mittels Neuronumerik

Jörg Bernd Zacharias

Vollständiger Abdruck der von der Fakultät Wissenschaftszentrum Weihenstephan für Ernährung, Landnutzung und Umwelt der Technischen Universität München zur Erlangung des akademischen Grades eines

Doktor-Ingenieurs (Dr.-Ing.)

genehmigten Dissertation.

Vorsitzender: Univ.-Prof. Dr.agr., Dr.agr.habil. Klaus Guthy

Prüfer der Dissertation: 1. Univ.-Prof. Dr.-Ing.habil. Antonio Delgado
2. Univ.-Prof. Dr.-Ing. Horst Weisser
3. Univ.-Prof. Dr.rer.nat. Ernst Rank (Fakultät BV)

Die Dissertation wurde am 19.02.2003 bei der Technischen Universität München eingereicht und durch die Fakultät Wissenschaftszentrum Weihenstephan für Ernährung, Landnutzung und Umwelt am 03.06.2003 angenommen.

Diese Arbeit wurde unter dem gleichen Titel in der
Reihe 20 Nr. 371 (2003) als Fortschritt-Bericht VDI veröffentlicht.
(VDI Verlag GmbH, Düsseldorf)

ISBN 3-18-337120-0

Danksagung

Die vorliegende Arbeit entstand in der Zeit von 1998 bis 2003 am Lehrstuhl für Fluidmechanik und Prozessautomation (LFP) der TU München unter der Leitung von Prof. Dr.-Ing. A. Delgado. Finanzielle Förderung erfolgte, neben Drittmitteln und dem Fleischmann-Fond, vor allem durch das Dr. H. Kronseder-Stipendium.

Mein Dank gilt allen, die mich in dieser Zeit unterstützt haben.

Besonderer Dank gebührt meinem Doktorvater Prof. Dr.-Ing. Antonio Delgado, der mir immer mit Vertrauen und Fachwissen unterstützend zur Seite stand und mir dabei viele akademische Freiheiten einräumte.

Auch Dr.-Ing. Christoph Hartmann möchte ich an dieser Stelle besonders für seine fachliche Unterstützung und seine Geduld danken, die er in vielen Diskussionen mit mir bewies und so maßgeblich zum Erfolg der Arbeit beitrug.

Ebenso danke ich allen Mitarbeiterinnen und Mitarbeitern des LFP, dem Sekretariat, insbesondere H. Gerzer, sowie der Werkstatt, W. Seidel und J. Rohrer, für das kollegiale Arbeitsklima und ihre Hilfsbereitschaft. Dazu zählen auch alle studentischen Hilfskräfte, Praktikanten, Semestranden und Diplomanden, die mit viel Fleiß zum Gelingen meiner Arbeit beigetragen haben, vor allem A. Remptke, C. Sauter, M. Schütz, Y. Baumgärtner, C. Schober, A.C.P. Simões und C.O. Ferreira.

Prof. Dr.-Ing. H. Weisser sowie Prof. Dr.rer.nat. E. Rank (Vizepräsident der TUM) danke ich für die Übernahme der Korreferate und manch guten Ratschlag. Auch danke ich Prof. Dr.agr. K. Guthy, der mich als Diplomand bereits an den LFP vermittelte und den Prüfungsvorsitz übernahm.

Mein besonderer Dank gilt natürlich auch meiner Partnerin Katja Fischer sowie meinen Freunden Tina Haidl und Hein Hafner, die mir bei der Korrektur sehr behilflich waren.

Nicht zuletzt möchte ich meinen Eltern danken, die durch ihre langjährige und geduldige Unterstützung diese Arbeit erst ermöglicht haben.

Meinen Eltern gewidmet.

Inhaltsverzeichnis

FORMELZEICHEN UND SYMBOLE	VIII
1	EINLEITUNG..... 1
1.1	AUSGANGSSITUATION..... 1
1.1.1	<i>Hintergrund..... 1</i>
1.1.2	<i>Stand der Forschung..... 3</i>
1.2	ZIELSETZUNGEN..... 5
2	GRUNDLAGEN..... 8
2.1	NUMERISCHE MODAL-FREQUENCY-RESPONSE ANALYSE MIT HILFE DER FINITE-ELEMENTE-METHODE..... 9
2.1.1	<i>Zustandsgrößen..... 10</i>
2.1.2	<i>Grundgleichungen..... 11</i>
2.1.3	<i>Aspekte zur Verwendung der FEM..... 14</i>
2.2	AUSGEWÄHLTE ASPEKTE DER SCHWINGUNGSLEHRE..... 15
2.2.1	<i>Bewegungsgleichung..... 16</i>
2.2.2	<i>Eigenschwingung..... 17</i>
2.2.3	<i>Erzwungene Schwingung..... 19</i>
2.3	MUSTERERKENNUNG MIT KÜNSTLICHEN NEURONALEN NETZEN..... 25
2.3.1	<i>Neuronen..... 27</i>
2.3.2	<i>Topologie..... 28</i>
2.3.3	<i>Trainingsalgorithmen..... 32</i>
2.3.4	<i>Auswahl geeigneter Eingangsdaten..... 37</i>
3	MATERIAL UND METHODEN..... 43
3.1	KOMBINATION DER EINGESETZTEN METHODEN ZUR NEURONUMERIK..... 43
3.2	GETRÄNKEKÄSTEN..... 45

3.3	VERSUCHSSTAND.....	49
3.3.1	<i>Aufbau</i>	50
3.3.2	<i>Steuerung und Automation</i>	54
3.3.3	<i>Besprechung der Testspezifikation</i>	57
3.4	DATEN-VORVERARBEITUNG FÜR DAS KNN.....	60
3.5	WEITERENTWICKLUNG VORHANDENER KNN-CODES	64
3.6	FEM-SOFTWARE (MSC/PATRAN-NASTRAN)	69
4	ERGEBNISSE UND DISKUSSION	74
4.1	NUMERISCHE SIMULATION DER SCHWINGUNGEN EINES GETRÄNKEKASTENS .	74
4.1.1	<i>Eigenmoden</i>	75
4.1.2	<i>Frequenzspektren</i>	79
4.1.3	<i>Validierung - Vergleiche der numerischen mit experimentellen Ergebnissen</i>	83
4.1.4	<i>Folgerungen zur Konstruktion eines Versuchsstandes</i>	86
4.2	EXPERIMENTELLE ERGEBNISSE DER SCHWINGUNGSTESTS	88
4.2.1	<i>Reproduzierbarkeit</i>	89
4.2.2	<i>Modell-Schadensfälle</i>	90
4.3	KLASSIFIZIERUNGSMÖGLICHKEITEN DER SCHWINGUNGSSPEKTREN MIT DEM KNN.....	95
4.3.1	<i>Klassifizierung der Spektren experimenteller Datenpools</i>	96
4.3.2	<i>Auswirkung der Netzwerkgröße</i>	102
4.3.3	<i>Auswirkung der Daten-Vorverarbeitung auf die Qualität der KNN-Ausgabe</i>	105
4.3.4	<i>Klassifizierung einzelner spezieller Schadensfälle experimenteller Datenpools</i>	107
4.4	NEURONUMERIK.....	110
4.4.1	<i>Das Uni-Sensorsystem</i>	110
4.4.1.1	KNN trainiert mit Kombinationen experimenteller und numerischer Datenpools.....	111

4.4.1.2	KNN trainiert mit rein numerischem Datenpool, Prädiktion mit rein experimentellem Datenpool - vice versa.....	116
4.4.2	<i>Das Dual-Sensorsystem</i>	120
4.4.2.1	Zusammenführung zweier 10x5x2-KNN mittels zusätzlicher verdeckter Neuronenschichten	122
4.4.2.2	Modifizierung des zweisträngigen Dual-Sensor-KNN zu einem einsträngigen 20x10x2-KNN	126
4.5	FOLGERUNGEN ZUM EINSATZ DER NEURONUMERIK ZUR SCHADENSERKENNUNG AN GETRÄNKEKÄSTEN	129
5	ZUSAMMENFASSUNG	134
6	AUSBLICK	137
7	ANHANG	139
7.1	NASTRAN SOLUTION-FILES ZUR MODAL-ANALYSE SOL103 UND ZUR FREQUENCY-RESPONSE-ANALYSE SOL111	139
7.2	TABELLARISCHE AUFSTELLUNGEN ZU POSITIONEN EINGESETZTER SCHADENSFÄLLE, KNN-DATENPOOLS UND DEREN ZUSAMMENSETZUNG	146
8	LITERATUR	157
8.1	PUBLIKATIONEN	157
8.2	LITERATURVERZEICHNIS	158

Formelzeichen und Symbole

Lateinische Buchstaben

\bar{a}	Vektor der Beschleunigung
a_i	Aktivität von Neuron i
A	Amplitude
A_S	Schnittfläche
c	Federkonstante
$[C]$	Verzerrungs-Verschiebungs-Transformationsmatrix
d	Dämpfungskonstante
D	Dämpfungsmaß
$[D]$	Dämpfungsmatrix
E	E-Modul
E_{ges}	Netzfehler über alle Trainingsmuster
E_P	Netzfehler für ein Trainingsmuster P
$\bar{\nabla}E$	Gradient der Fehlerfunktion
$[E]$	Elastizitätsmatrix
$[E_M]$	Einheitsmatrix
f	Kraft
f_i	äußere Knotenlast
f_{FRi}	Eigenfrequenz
F	Kraftamplitude
\bar{F}	Vektor der Kraft
F^C, F^S	Fourier-Koeffizienten
G	Gleitmodul
G_N	Strukturdämpfung
h	Zwischenschicht eines KNN
$[H]$	dynamische Nachgiebigkeitsmatrix
i	imaginäre Einheit
I_{Ai}	Fläche des Abschnitts i
$\text{Im } \underline{x}$	Imaginärteil einer komplexen Zahl
k	Steifigkeit
k_j	verallgemeinerte Steifigkeit
$[K]$	Steifigkeitsmatrix
m	Masse
m_j	verallgemeinerte Masse
$[M]$	Massenmatrix
n	Anzahl
N	Ansatz- bzw. Formfunktion

$[N]$	Matrix der Formfunktionen
o_i	Ausgabe von Neuron i , geschachtelt aus $o_i = h(g(n(x_1, x_2, \dots, x_i)))$
p	innere Volumenkraft
$\{p\}$	Vektor der Volumenkräfte
P	Trainingsdatenmenge
$\operatorname{Re} \underline{x}$	Realteil einer komplexen Zahl
s	Dicke
$s(x)$	Funktion des Messsignals
$S(t)$	Funktion der Steigung des Fehlergradienten
t	Zeit
t_i	Sollausgang eines Neurons i
Δt	Zeitschritt
T	Periodendauer
u	Verschiebung
$u_h(t)$	homogene Lösung
u_i	Verschiebung in den Knoten
$u_p(t)$	partikuläre Lösung
$\{u\}$	Verschiebungsvektor
\dot{u}	Geschwindigkeit
$\{\dot{u}\}$	Geschwindigkeitsvektor
\ddot{u}	Beschleunigung
$\{\ddot{u}\}$	Beschleunigungsvektor
u_i, v_i, w_i	Komponenten des Verschiebungsfeldes
V	Volumen
$V(\eta)$	Vergrößerungsfunktion
w_{ij}	Gewicht der Verbindung der Neuronen i und j
W	Matrix aller Gewichte
\underline{x}	komplexe Zahl
x_i	Eingabe von Neuron i
x_m	Anzahl der Neuronen der Eingabeschicht eines KNN
y_n	Anzahl der Neuronen der Ausgabeschicht eines KNN
x, y, z	kartesische Koordinaten

Griechische Buchstaben und Symbole

α	Phasenwinkel
β	Verformungswinkel
γ	Schubdehnung
δ	Abklingkoeffizient
δ_i	Fehlersignal von Neuron i
$\delta\{u\}$	virtueller Verschiebungsvektor
δW_a	virtuelle äußere Arbeit

δW_i	virtuelle innere Arbeit
$\delta\{\varepsilon\}$	virtueller Verzerrungsvektor
$[\Delta]$	Differentialoperatorenmatrix
ε	Dehnung bzw. Verzerrung
ε_K	Klassifizierungsfehler
$\{\varepsilon\}$	Verzerrungsvektor
η	Frequenzverhältnis
η_L	Lernrate
θ	Schwellenwert eines Neurons
λ	Eigenwert
$[A]$	genormte generalisierte Steifigkeitsmatrix
μ	Mittelwert
ν	Querdehnungszahl (Poissonzahl)
$\xi_i(\omega)$	i -te modale Verschiebungsamplitude
π	Kreiszahl
ρ	Dichte
σ	Längs- bzw. Normalspannung
σ_S	Standardabweichung
$\{\sigma\}$	Spannungsvektor
Σ	Summe
τ	Schubspannung
$\{\phi\}$	Eigenvektor
$[\Phi]$	Modalmatrix
φ	Phasenverschiebung zur Erregung
ω	Eigenkreisfrequenz
Ω	Erregerfrequenz

Abkürzungen

akt	Aktivierung eines Neurons
A/D	Analog-Digital
A-1, A-2, B-1, B-2	Datenvorverarbeitung gemäß Tabelle 3-4
CAD	Computer Aided Design
CCD	Charge-Coupled-Device
DAP	Data Acquisition Processor
DMS	Dehnungsmessstreifen
D1 bis D8	Datensätze für KNN-Training und Prädiktion gemäß Tabelle 7-5
DVV	Daten-Vorverarbeitungs-Verfahren
EXP	experimenteller Herkunft
E1 bis E17	experimentelle Schadensfälle gemäß Tabelle 7-1

EP1 bis EP9	experimentelle Schadensfallpaare gemäß Tabelle 7-2
FE	Finite-Elemente
FEM	Finite-Elemente-Methode
FFT	Fast-Fourier-Transformation
Gl.	Gleichung
KNN	künstliches neuronales Netz
LFP	Lehrstuhl für Fluidmechanik und Prozessautomation
LRZ	Leibniz-Rechenzentrum
LS	linke Seite
Mess.	Messung
MLP	Multi-Layer-Perzeptron (Mehrschichtennetz)
MSE	Mean Square Error (mittlerer quadratischer Fehler)
net	Netzeingang eines Neurons
NUM	numerischer Herkunft
nzg	nicht zeitgleich
N1 bis N22	numerische Schadensfälle gemäß Tabelle 7-3
PCA	Principal Component Analysis (Hauptkomponentenanalyse)
PLS	Partial Least Square
Pos.	Position
RAE	Relative Absolute Error (relativer absoluter Fehler)
RPROP	Resilient Propagation
RS	rechte Seite
SOL103	MSC/NASTRAN Lösungssequenz: modal Analysis
SOL111	MSC/NASTRAN Lösungssequenz: modal Frequency-Response-Analysis
SPCD	MSC/NASTRAN: Verfahren zur direkten erzwungenen Bewegung
TET4, TET10	MSC/NASTRAN: Tetraederelemente mit 4 und 10 Knoten
Konstanten	
$g = 9,81 \text{ ms}^{-2}$	mittlere Erdbeschleunigung

1 Einleitung

Schäden können in Natur und Technik durch natürlichen Verschleiß oder Überbeanspruchungen physikalischer und chemischer Art entstehen. Bereits vorhandene Materialmängel begünstigen das Auftreten von Defekten. Diese können neben Aussehen und Funktionsfähigkeit auch die Gebrauchssicherheit von Produkten beeinträchtigen. Zusammen mit der Produkthaftung des Herstellers folgt die Notwendigkeit, effektive Methoden der Schadenserkennung zu entwickeln und einzusetzen. Die klassischen Gebiete des Ingenieurwesens, wie Maschinenbau, Bauingenieurwesen und Flugzeugbau, entwickeln bereits seit geraumer Zeit zahlreiche Verfahren für die frühzeitige Erkennung von Schäden aller Art. Neben Methoden aus den Gebieten Optik und Akustik kommt auch die mechanische Schwingungsanalyse zum Einsatz zur Schadenserkennung.

Die Bedeutung effizienter Sortierung von Mehrweggütern für die Getränkeindustrie erschließt sich bereits aus dem mengenmäßigen Umsatz von Stapelkästen (Flaschenkästen, Getränkekästen), der zur Zeit bei einer ca. 70 %igen Mehrwegquote aller CO₂-haltigen Getränke bei 400-500 Mio. Kästen liegt, die jeweils bis zu 100 Umläufe absolvieren. Im Hinblick auf die Akzeptanz des Kunden erlangen neben einer Gefährdung bei der Handhabung auch ästhetische Defizite besondere Beachtung. In der vorliegenden Arbeit wird eine neue Methode für die Schadenserkennung vorgestellt. Diese soll nicht nur den Qualitätsansprüchen an Pfandsysteme und Flaschenabfüllanlagen in der Getränkeindustrie gerecht werden, sondern diese auch weiter entwickeln [1, 2, 3, 4].

1.1 Ausgangssituation

1.1.1 Hintergrund

In der Praxis erschwert die steigende Anzahl unterschiedlicher Getränkekastenmodelle, darunter zunehmend auch halbierbare Kästen, die Sortierung. Daher wird ein fehlerfrei arbeitendes Sortiersystem benötigt, das es ermöglicht, den Zustand rücklaufender Getränkekästen hinsichtlich ihrer Wiederverwendbarkeit zu prüfen [5, 6, 7].

Beschädigungen an Getränkekästen entstehen beim Transport, durch Materialermüdung oder durch unsachgemäße Handhabung oder Erwärmung. Die Schäden treten im wesentlichen als Risse, Deformationen oder als abgetrennte Teile des

Tragekörpers auf. Schadhafte Kästen gilt es, zusätzlich zu Fremdfabrikaten, in voll-automatisch arbeitenden Flaschenabfüllanlagen aus dem Verpackungskreislauf zu entfernen, da sie Störfälle im Betrieb verursachen oder später eine Gefährdung des Endkunden darstellen können [8, 9, 10, 11, 12, 13].

Nach dem heutigen Stand der Technik werden derzeit in den meisten Brauereien, Brunnenbetrieben und Softdrinkbetrieben optische Kasten-Sortiersysteme (verschiedener Hersteller) im Rahmen der Leergutkontrolle in Abfüllanlagen verwendet [14, 15]. Diese Systeme basieren auf einer elektronischen Auswertung von CCD-Aufnahmen (Charge-Coupled-Device) [16, 17, 18, 19]. Üblicherweise geschieht die Erkennung eines Schadens dadurch, dass ein aufgenommenes Bild mit Hilfe eines digitalen Bildverarbeitungssystems in kleine Raster unterteilt wird. Unterschiede in der Helligkeit, den Grautönen, der Lichtreflexion oder den Farben dieser Raster liefern ein Muster, das beurteilt wird. Im Einsatz befinden sich Detektorsysteme sowohl für Stapelkästen als auch für Flaschen, wobei sowohl leere als auch volle Kästen geprüft werden. Diese werden teilweise durch Ultraschall oder holographische Systeme ergänzt [20], welche die Vollzähligkeit und Lage von Flaschen beurteilen oder einzelne, jedoch lokal begrenzte, Regionen genauer optisch abtasten. Andere Systeme kartografieren die Umrisse der Kästen oder sortieren den Kastentyp lediglich durch Identifizierung eines Barcodes an der Seitenwand [21]. Zudem werden auch akustische Systeme eingesetzt, die z. B. Füllstände in einzelnen Flaschen messen [22, 23].

Bei allen Systemen erfolgt eine Klassifizierung bezüglich der Übereinstimmung mit dem System bekannten und unbekannt Mustern [24, 25, 26]. Somit werden die von vorab definierten Eigenschaften abweichenden Kästen aussortiert. Je nach Aufbau der Systeme unterscheiden sie bei Getränkekästen nach folgenden Kriterien [10, 27, 28, 29]:

- nur Kastenfarben, Fremdkasten
- zusätzlich Logo, Schriftzug, Kastengeometrie (nach falscher Länge, Breite bzw. Höhe) und Griffleisten
- zusätzlich stark verbogene und ausgebrochene Gefache, falsche Gefachegeometrie (lineare, wabenförmige Anordnung), abstehende Griffe, Deformationen, kopfstehende Flaschen, Fremdmaterial auf und zwischen den Flaschen

Zusammenfassend beruhen alle diese Systeme auf optischen oder akustischen Verfahren. Sie eignen sich durchaus für eine äußere Beurteilung der Getränkekästen, doch erlauben sie es nur schwer, verdeckte und kleinere Schäden, Kästen hohen Alters oder Schäden an halbierbaren Gebinden aufzudecken.

1.1.2 Stand der Forschung

Die Forschung in der Verpackungsindustrie befasst sich bis heute lediglich in Randgebieten mit Schwingungstests, beispielsweise mit der Beurteilung von Transportpaletten [30, 31]. Des Weiteren beschreibt [32] ein Patent die Schadenserkennung an Weithalsbehältern aus Glas mittels eines oszillierenden Wasserstrahls, welches jedoch nicht zur Produktreife weiterentwickelt wurde. Numerische Verfahren finden ebenfalls nur selten Anwendung. Die Simulation von plastischem Verhalten bei PET-Flaschen unter mechanischer Belastung bildet die Ausnahme [33]. Diese beispielhafte Auflistung der wenigen im Sektor der Verpackungsforschung vorhandenen Beispiele verdeutlicht, dass die Problematik und die wissenschaftliche Motivation der vorliegenden Arbeit zur Schadenserkennung an Getränkekästen durch Schwingungsanalyse und den Einsatz neuronumerischer Methoden fachübergreifend erläutert werden muss.

Die Schadenserkennung mechanischer Systeme durch Schwingungsanalyse wird in zahlreichen Literaturstellen aus der Luftfahrt, dem Bauingenieurwesen, der Erdbebenforschung und einigen grundlegenden mechanischen Problematiken des Ingenieurwesens beschrieben. Zur Detektion von Schäden und Fehlern wird dabei das Resonanzverhalten des Prüflings beurteilt. Hierzu geben beispielsweise [34, 35, 36] einen Überblick. Auch in der Praxis werden diese Erkenntnisse eingesetzt. Dabei handelt es sich um die Beobachtung von Bauwerk-, Brücken- und Tragwerkschwingungen sowie um die Beurteilung von Maschinen [37, 38, 39, 40, 41]. An Maschinen wird die Schadensdetektion normalerweise direkt am Gehäuse oder an der Antriebswelle vorgenommen. Üblicherweise wird dadurch der Zustand der Produktionsanlagen kontrolliert, nicht jedoch der des Produktes als Prüfling [42, 43]. Grundlage zur Detektion eines Schadens ist meist eine Veränderung eines definierten Signals, das in seine Frequenzbestandteile zerlegt wird. Die Klassifizierung geschieht sowohl mit bewährten Algorithmen [44, 45, 46], als auch mit Ansätzen, welche die Möglichkeiten moderner Algorithmen, wie künstlicher neuronaler Netze (KNN), nutzen [47, 48, 49, 50, 51].

Seit Jahren wird zudem, in der Wissenschaft intensiv und zunehmend auch in der Industrie, die numerische Simulation dynamischer Systeme betrieben. Dazu zählt auch die Simulation von Eigenschwingungen von Festkörpern und deren Frequenzantwort, sowohl bei „intakten“ als auch „defekten“ Strukturen [52, 53, 54]. Die Validierung der numerischen Simulation dieser Systeme ist meist stark abhängig von deren Komplexität. Auch Vereinfachungen bei der Diskretisierung sowie den

Materialparametern aufgrund von Inhomogenitäten, Nichtlinearitäten und Plastizitäten erschweren diese. In den letzten Jahren wurden jedoch große Fortschritte in der Forschung erzielt, die mittlerweile auch in kommerziell verfügbare Finite-Elemente-Codes eingeflossen sind. Dennoch erweist es sich immer noch als problematisch, komplexere Systeme entsprechend zu diskretisieren und über größere Frequenzbereiche mit experimentellen Modellsystemen zu validieren. Gerade diese Systeme zeigen oft deutliche Abweichungen im Vergleich von experimentell ermittelten und numerisch berechneten Frequenz-Antwort-Spektren [55, 56]. Aufbauend auf Erfolgen mit einfachen Modellsystemen, wie Platten, Stäben, Balken, einfachen Tragwerken und Gestellen, werden jedoch immer größere Genauigkeiten erreicht. Durch solche Erfolge bestätigt, wird versucht, die so gewonnenen Erkenntnisse in die Mustererkennung von Schadensdetektionen einfließen zu lassen [57, 58, 59]. Gerade bei der Bauwerksbeurteilung sind so erhebliche Fortschritte in der Schadensdetektion, bedingt durch Überalterung und Überlastung, aber auch bei Schäden durch seismische Schwingungen (Erdbeben) zu erwarten [60, 61]. Das Problem in diesem Bereich besteht vor allem darin, dass jedes Bauwerk als Unikat vorliegt, dessen Verhalten im Schadensfall nur vermutet oder abgeschätzt werden kann.

Einen Vorteil diesbezüglich bieten Anwendungen auf dem Sektor des Maschinenbaus. Hier liegen üblicherweise die Prüflinge (z. B. Produktionsanlagen, -güter, Werkzeuge, etc.) in größerer Anzahl vor. Sie sind also keine Unikate. Dies ermöglicht, deren Verhalten im Schadensfall wiederholt zu messen und somit numerische Simulationen zu validieren und auch Mustererkennungssysteme gezielt zu konfigurieren. In zunehmendem Maße werden intelligente, kognitive Algorithmen, wie beispielsweise künstliche neuronale Netze, dazu eingesetzt. Wie oben bereits angesprochen, sind hier grundlegende erste Forschungsarbeiten ausgeführt worden, wie auch die Beispiele aus der Literatur an Balken- oder Plattenmodellen zeigen [62, 63].

Die konsequente Weiterführung der geschilderten Verfahren führt zum Einsatz von Daten numerischen Ursprungs zur Konfiguration der gesamten Mustererkennungen. Gerade hierzu stellt jedoch die zu erzielende Übereinstimmung von Frequenz-Antwort-Spektren aus experimenteller und numerischer Herkunft die Hauptschwierigkeit dar. So sind bis her nur wenige Arbeiten bekannt, die auf diesem Gebiet Erfolge aufweisen. Auch lassen sich diese bisher lediglich auf Modellsysteme anwenden [64, 65, 66, 67]. Applikationen, die komplexe Geometrien beinhalten oder die auf den Einsatz in der industriellen Produktion abzielen, fehlen bisher.

Dies führt zum generellen Grundgedanken neuronumerischer Systeme. Dieser Begriff wurde am Lehrstuhl für Fluidmechanik und Prozessautomation (LFP) geprägt [68, 69, 70, 71, 72]. Neuronumerik, oder auch neuronumerische Systeme, umfassen prinzipiell alle Verfahren, bei denen die konventionellen Methoden der numerischen Simulation ein wichtiger Bestandteil sind. Kognitive Algorithmen, im Besonderen KNN, übernehmen dabei zentrale Aufgaben. Allen diesen Aufgaben ist gemein, dass KNN in der Lage sind, Rechenschritte zu substituieren, die besonders aufwändig, zeitintensiv oder nur näherungsweise berechenbar sind. Überdies lassen sich im Rahmen einer Modellierung auch experimentelle Daten direkt ohne aufwendige Vorverarbeitung einsetzen. Aufgrund ihrer Fähigkeit, Funktionen abzubilden und zu generalisieren, liefern entsprechend konfigurierte KNN dabei weiterverwertbare Ausgaben. Zu den vielversprechenden hybriden Modellen zählen also alle Systeme, die aufwändige numerische Prozesse übernehmen. Anwendungen finden sich in der Literatur nur vereinzelt. Einige Forschungsarbeiten diskutieren den Einsatz an grundlegenden Beispielen zur Unterstützung der Funktionalität einzelner finiter Elemente [73], aber auch, um ein CAD-Modell und dessen Vernetzungsprozess zu verbessern oder strukturelle Parameter abzuschätzen [74, 75]. Eine weitere Arbeit erläutert Forschungen zur Charakterisierung von Rissen in Aluminiumbauteilen mit Hilfe von Ultraschall und einem mit FE-Daten trainierten KNN [76]. Der Einsatz von Neuronumerik ist nicht auf die Festkörpermechanik beschränkt. Auf dem Gebiet der numerischen Fluidmechanik wird beispielsweise mit KNN an der Vorhersage zweidimensionaler Strömungsfelder gearbeitet [68, 72].

1.2 Zielsetzungen

Aufbauend auf diese Grundlage zielt die vorliegende Arbeit auf die Erarbeitung und Erprobung eines Sensorsystems, das eine Aufnahme von Mustern (Frequenzspektren mechanischer Schwingungsantworten) auf einem robusten mechanischen Weg erlaubt. Robustheit bedeutet in diesem Kontext Zuverlässigkeit und Unempfindlichkeit gegen äußere Einflüsse. Dabei stützt sich die Entwicklung des Mustererkennungssystems für beschädigte Polyethylen-Getränkekästen auf die Grundlagen der mechanischen Schwingungserregung und entsprechender Frequenz-Antworten, die es ermöglichen, kleinere und verdeckte Schäden zu detektieren. Zur Entscheidungsfindung dient eine Mustererkennung mittels künstlicher neuronaler Netze (KNN). Ein wesentliches Ziel des Systems besteht darin, die Vorteile dieser zuverlässigen mechanischen Methoden mit der schnellen, adaptiven Mustererkennung der KNN zu verbinden, um ein flexibles automatisches Sortieren zu ermöglichen. Die Systemoptimierung erfolgt mit Hilfe numerischer Simulation des

mechanischen Systems auf Basis der Finite-Elemente-Methode (FEM). Diese liefert Informationen zum Verhalten der Struktur, die einerseits zum Aufbau der experimentellen Anlage genutzt werden und andererseits im Netzwerktraining der Mustererkennung zum weiteren Einsatz kommen. Das führt zur Einführung und Anwendung der Neuronumerik auf praxisnahe Probleme, wie sie am Lehrstuhl für Fluidmechanik und Prozessautomation erstmals untersucht werden [68, 69, 71, 72, 77, 78]. Neuronumerik basiert in der hier verfolgten Ausprägung auf der Grundüberlegung, Trainingsdaten für die zur Mustererkennung eingesetzten KNN numerisch zu errechnen. Eine Aufnahme von Trainingsdaten vor Ort entfällt somit, das System wird ohne Anlagenstillstand update-fähig.

Die vorliegende Arbeit wendet diese Methoden auf die komplexe Struktur eines Getränkekastens an. Risse, Deformationen und abgetrennte Teile des Tragekörpers bilden die studierten, typischen Modellschäden. Zusammengefasst ergeben sich dabei folgende Fragestellungen:

- Können Eigenschwingungen an Getränkekästen mit Hilfe der FEM simuliert und anhand von experimentellen Versuchen validiert werden?
- Eignen sich die Ergebnisse dieser Simulationen zur Unterstützung des Aufbaus einer Pilotanlage?
- Ist an der Pilotanlage eine Aufnahme von Frequenzmustern möglich, die eine Unterscheidung von intakten und defekten Getränkekästen ermöglicht?
- Erlauben diese Frequenzmuster eine automatische Schadensklassifizierung der Kästen mittels KNN?
- Welche Art von Datenreduzierung eignet sich dafür?
- Wie muss das KNN konfiguriert sein?
- Erzielt ein neuronumerisch parametrisiertes KNN ausreichende Ergebnisse?
- Wie muss dieses KNN konfiguriert sein, damit es Schäden detektieren kann?
- Welche Auswirkung haben dabei vorgenommene Vereinfachungen, Ungenauigkeiten und der Einsatz von Grenzfällen der Klassifikationsklassen?

Für die Konfiguration eines geeigneten KNN-Systems bedeutet dies, dass hierbei neben der Topologie des KNN auch die Datenvorverarbeitung und der Trainingsdatenpool beurteilt werden müssen. Die Frage, inwieweit diese Faktoren die KNN-

Ausgabe bezüglich einer „objektiven“ oder einer „subjektiven“ Genauigkeit beeinflussen, muss beantwortet werden. Dabei ergibt sich „objektive Genauigkeit“, wenn das KNN nach den Regeln von Abschnitt 2.3.4 trainiert wird und dabei die Fähigkeit zu generalisieren, d. h. zu verallgemeinern, erlangt. „Subjektive Genauigkeit“ ergibt die KNN-Ausgabe, die erzielt wird, wenn beispielsweise aufgrund visueller Kriterien Trainingsdaten oder Netzwerktopologien den Vorzug erhalten, die vordergründig einem „Expertenwissen“ entsprechen.

Diese Entwicklung stellt die Grundlage für weiterführende Arbeiten dar, die auf ein praxistaugliches Verfahren für den Online-Betrieb in einer Flaschenabfüllanlage abzielen, in der beschädigte Getränkekästen bei der erforderlichen Ausbringung vollautomatisch erkannt werden und deren Aussortierung eingeleitet wird. Dieses Verfahren detektiert auch fremde (abweichender Geometrie) und teilbare Kastensysteme sowie gealterte, versprödete Kästen und Recyclate in ähnlicher Weise.

2 Grundlagen

Wie bereits in Kapitel 1 dargestellt, gliedert sich der in dieser Arbeit gewählte neuronumerische Ansatz in drei Teilschritte:

- experimentelle Schwingungsanalyse,
- numerische Simulation und
- Mustererkennung mit Hilfe künstlicher neuronaler Netze (KNN).

Die nachfolgenden Erörterungen dienen der Einführung in diese Teilgebiete.

Die verwendete Neuronumerik nutzt die Eigenschaft mechanischer Systeme, dass sich Signale in Festkörpern mehr oder weniger gedämpft ausbreiten. Die Schwingungsantworten von Festkörpern unterschiedlicher Geometrie, also auch die von beschädigten Festkörpern, weichen von der eines unbeschädigten Festkörpers ab. Dies bietet einen Ansatzpunkt zur Selektierung einzelner Körper. In der vorliegenden Arbeit tritt an die Stelle eines Festkörpers ein Getränkekasten.

Beim Teilgebiet der numerischen Simulation wird im Folgenden auf die Grundlagen der Finite-Elemente-Methode (FEM) eingegangen. Dabei erfolgt die Beschreibung lediglich im Zusammenhang mit den Grundlagen des zum Einsatz kommenden kommerziellen FEM-Codes „MSC-PATRAN/NASTRAN“ (vgl. dazu [79, 80, 81, 82, 83]). Gleiches gilt für die anschließende Erläuterung der grundlegenden Gleichungen von frei bzw. erzwungen schwingenden Systemen. Für die ausführliche Herleitung und eine über den Anwendungsbereich hinausgehende Diskussion der Schwingungsmechanik wird auf die Literatur verwiesen (z. B. [84, 85, 86, 87]).

Zur Mustererkennung mit KNN wird ein bewährter Netzwerktyp auf Basis eines am Lehrstuhl für Fluidmechanik und Prozessautomation (LFP) entwickelten KNN-Codes eingesetzt, dessen theoretische Grundlagen in Abschnitt 2.3 ebenfalls erläutert werden.

Zur Konfiguration der eingesetzten Methoden und deren Verbindung untereinander folgt in Kapitel 3 eine ausführliche Beschreibung.

2.1 Numerische Modal-Frequency-Response Analyse mit Hilfe der Finite-Elemente-Methode

Die FEM beruht auf der Unterteilung einer kontinuierlichen Struktur in einzelne, diskrete Elemente. Dazu wird das entsprechende Modell vernetzt, indem Knotenpunkte festgelegt werden, die durch die Elemente verbunden sind. Dabei wird davon ausgegangen, dass die verwendeten Gleichungen für jedes Element lösbar sind und somit die gewünschte Lösung für das Gesamtsystem gefunden werden kann [83]. Außerdem werden bei der Berechnung des Verhaltens einer Struktur folgende Eigenschaften vorausgesetzt:

- elastisches Verhalten (nach Entfernung der Belastung kehrt der Körper wieder in seinen ursprünglichen, unverformten Zustand zurück),
- lineares Verhalten (die Verformungen sind direkt proportional zur angreifenden Kraft),
- das Material ist homogen (die Materialeigenschaften sind ortsunabhängig) und isotrop (die Materialeigenschaften ändern sich nicht mit der Richtung des Materials),
- es treten nur kleine Verschiebungen auf.

Der Lösungsvorgang mit Hilfe der FEM erfordert somit im allgemeinen folgende zusammengefasste Vorgehensweise:

- Diskretisierung des Festkörpers bzw. seiner Struktur durch Festlegung der Knotenpunkte und der durch diese verbundenen Elemente.
- Aufstellung der Ansätze für die Verschiebungsfelder der Elemente. Die Verschiebungen in den finiten Elementen werden durch entsprechend gewählte Formfunktionen angenähert. Die Element-Knotenverschiebungen stellen die zu bestimmenden Ansatzparameter dar.
- Die Lösung des Energie- und Variationsansatzes auf Elementebene führt zu den Elementmatrizen und den lokalen Verschiebungen.
- Die Integration über das Festkörpervolumen entspricht durch die FE-Diskretisierung der „Aufsummierung“ der Elementmatrizen zu den Gesamtmatrizen.
- Nach Berechnung des Verschiebungsvektors folgt die Bestimmung der Verzerrungen und Spannungen.

Die folgenden Abschnitte erläutern einige wichtige Zustandsgrößen und Grund-

gleichungen, die während dem Lösungsvorgang Verwendung finden.

2.1.1 Zustandsgrößen

Verschiebungen

Um die Lageänderung eines Punktes zu beschreiben, werden dessen Anfangskordinaten und die Verschiebung u verwendet. Als Verschiebung wird die gesamte Bewegung bezeichnet, die die Summe aus Translation, Rotation und Deformation (Streckung oder Stauchung) eines Elementes ist. Somit lässt sich jeder beliebige verformte oder verlagerte Zustand beschreiben. Nur bei einem ideal starren Körper findet keine Deformation statt. Im Folgenden wird der Verschiebungsvektor

$$\{u\}^T = (u \ v \ w) \quad (2-1)$$

mit u , v und w als den Komponenten des Verschiebungsfeldes verwendet [80, 81].

Verformungen

Die Dehnungen ε drücken einen „relativen“ Verformungsanteil aus. Mittels eines unverformten ds_0 und eines verformten Längsstücks ds ist in der technischen Darstellung die Längsdehnung $\varepsilon = (ds - ds_0) / ds_0$ definiert. Analog dazu beschreibt $\gamma = \beta_0 - \beta$ die Schubdehnung γ als Winkeländerung (mit β_0 als Winkel vor und β als Winkel nach der Verformung). Somit erhält man für den dreidimensionalen Raum mit

$$\{\varepsilon\}^T = (\varepsilon_{xx} \ \varepsilon_{yy} \ \varepsilon_{zz} \ \gamma_{xy} \ \gamma_{yz} \ \gamma_{zx}) \quad (2-2)$$

den Verzerrungstensor [80, 83].

Spannungen

Spannungen repräsentieren innere Kräfte pro Flächeneinheit. Schneidet man ein Element eines Körpers frei, erhält man die Längs- bzw. Normalspannungen σ und die Schubspannungen τ . Da die inneren Kräfte in der Regel in Richtung und Größe nicht konstant über die Schnittfläche verteilt sind, werden die Grenzwerte

$$\sigma = \lim_{A_S \rightarrow 0} \frac{P_n}{A_S} \quad (2-3)$$

$$\text{und } \tau = \lim_{A_S \rightarrow 0} \frac{P_t}{A_S} \quad (2-4)$$

gebildet. Dabei steht die Kraft p_n senkrecht auf der Schnittfläche A_S , während die Kraft p_t tangential zur Schnittfläche wirkt. Mit den Symmetrieeigenschaften der Schubspannung $\tau_{xz} = \tau_{zx}$, $\tau_{xy} = \tau_{yx}$ und $\tau_{yz} = \tau_{zy}$ ergibt sich mit

$$\{\sigma\}^T = (\sigma_{xx} \sigma_{yy} \sigma_{zz} \tau_{xy} \tau_{yz} \tau_{zx}) \quad (2-5)$$

der Spannungstensor [80, 81].

2.1.2 Grundgleichungen

Für die Betrachtung eines elastischen Körpers unter Einwirkung von Kräften gelten folgende Gleichungen:

Verschiebungs-Verzerrungsgleichungen

Zwischen den Verschiebungen und Verzerrungen ist folgender Zusammenhang gegeben:

$$\begin{aligned} \varepsilon_{xx} &= \frac{\partial u}{\partial x}, & \varepsilon_{yy} &= \frac{\partial v}{\partial y}, & \varepsilon_{zz} &= \frac{\partial w}{\partial z}. \\ \gamma_{xy} &= \frac{\partial v}{\partial x} + \frac{\partial u}{\partial y}, & \gamma_{yx} &= \frac{\partial w}{\partial y} + \frac{\partial v}{\partial z}, & \gamma_{zx} &= \frac{\partial u}{\partial z} + \frac{\partial w}{\partial x}. \end{aligned}$$

Dies führt in Matrixschreibweise zu

$$\{\varepsilon\} = [\Delta]\{u\} \quad (2-6)$$

mit $[\Delta]$ als Differentialoperatorenmatrix [82].

Verzerrungs-Spannungsgleichungen

Die Beziehung zwischen Dehnungen und Spannungen ergibt sich mit Hilfe des Hookschen Gesetzes $\sigma = E\varepsilon$ mit dem Elastizitätsmodul E . Dieses Gesetz beschreibt sowohl isotrope als auch anisotrope Werkstoffe. Die isotropen Werkstoffe werden vor allem durch zwei mechanische Kenngrößen, dem E-Modul E und der Querdehnungszahl (auch Poissonsche Zahl) ν beschrieben. Bei einem Zustand reiner Schubspannung ergibt sich

$$\tau = G\gamma, \quad (2-7)$$

wobei der Schubmodul

$$G = \frac{E}{2(1+\nu)} \quad (2-8)$$

durch den E-Modul ausgedrückt werden kann. Für mehrdimensionale Körper ergibt sich mit Hilfe der Hookschen Matrix bzw. der Elastizitätsmatrix $[E]$

$$\{\sigma\} = [E]\{\varepsilon\} \quad (2-9)$$

Zusammen mit Gleichung (2-6) sind aus den Verschiebungen die Spannungen in jedem Punkt eines Körpers berechenbar [81, 82].

Gleichgewichtsgleichungen

Das Kräftegleichgewicht zwischen den inneren Spannungen und der äußeren Belastung muss immer erfüllt sein. Aus dieser Forderung ergeben sich mit Hilfe des Vektors der verteilten inneren Volumenkräfte $\{p\}^T = (p_x p_y p_z)$ und unter Ausnutzung der Symmetrien der Schubspannungen $\tau_{xy} = \tau_{yx}$, $\tau_{yz} = \tau_{zy}$ und $\tau_{zx} = \tau_{xz}$ folgende Gleichgewichtsgleichungen:

$$\left(\frac{\partial \sigma_{xx}}{\partial x}\right) + \left(\frac{\partial \tau_{xy}}{\partial y}\right) + \left(\frac{\partial \tau_{xz}}{\partial z}\right) + p_x = 0, \quad (2-10)$$

$$\left(\frac{\partial \tau_{xy}}{\partial x}\right) + \left(\frac{\partial \sigma_{yy}}{\partial y}\right) + \left(\frac{\partial \tau_{yz}}{\partial z}\right) + p_y = 0, \quad (2-11)$$

$$\left(\frac{\partial \tau_{xz}}{\partial x}\right) + \left(\frac{\partial \tau_{yz}}{\partial y}\right) + \left(\frac{\partial \sigma_{zz}}{\partial z}\right) + p_z = 0 \quad (2-12)$$

bzw.

$$[\Delta]^T \{\sigma\} + \{p\} = 0 \quad (2-13)$$

mit der transformierten Differentialoperatorenmatrix $[\Delta]^T$ [82].

Grundgleichung der Elastodynamik

Bei dynamischen Systemen muss die Gleichgewichtsgleichung gegenüber dem vorstehend betrachteten statischen Fall erweitert werden, da die Verschiebungen u , die Verzerrungen ε und die Spannungen σ weg- und zeitabhängig sind.

Nach dem d'Alembertschen Prinzip werden die beschleunigungsproportionalen Trägheitskräfte mit dem Term $(-\rho\{\ddot{u}\})$ berücksichtigt. Oft treten auch dissipative

Kräfte auf, welche die Schwingungsauslenkungen dämpfen. Diese wirken der Bewegung entgegen und können geschwindigkeitsproportional mit $(-c\{\dot{u}\})$ angesetzt werden. Damit wird Gleichung (2-13) zu

$$[\Delta]^T \{\sigma\} + \{p\} + \rho\{\ddot{u}\} + c\{\dot{u}\} = 0 \quad (2-14)$$

erweitert [82].

Berechnung der Elementsteifigkeitsmatrix

Zur Berechnung der Elementsteifigkeit wird zuerst das Verschiebungsfeld $u^*(x, y, z)$ in einem finiten Element gebildet (vgl. Abschnitt 2.1.3). Dies geschieht durch Multiplikation der Verschiebungen u_i der Knoten i mit entsprechend gewählten Ansatz- bzw. Formfunktionen $N_i(x, y, z)$. Es ergibt sich somit

$$u^*(x, y, z) = \sum_i u_i N_i(x, y, z) . \quad (2-15)$$

Beispielhaft ergibt sich bei einem Element mit 4 Knoten für die Komponenten des Verschiebungsfeldes $u^*(x, y, z)$

$$u^*(x, y, z) = \begin{bmatrix} u(x, y, z) \\ v(x, y, z) \\ w(x, y, z) \end{bmatrix} = \begin{bmatrix} N_1 u_1 + N_2 u_2 + N_3 u_3 + N_4 u_4 \\ N_1 v_1 + N_2 v_2 + N_3 v_3 + N_4 v_4 \\ N_1 w_1 + N_2 w_2 + N_3 w_3 + N_4 w_4 \end{bmatrix} . \quad (2-16)$$

Wendet man diese Gleichung auf die Verschiebungs-Verzerrungsgleichung (Gleichung (2-6)) an, so erhält man

$$\{\varepsilon\} = [\Delta][N]\{u_i\} = [C]\{u_i\} , \quad (2-17)$$

mit $[C] = [\Delta][N]$ als Verzerrungs-Verschiebungs-Transformationsmatrix. Bei den Verschiebungen u_i handelt es sich um die Verschiebungen in den Knoten i . Um die globale Elementsteifigkeitsmatrix zu erstellen, wird das aus der Technischen Mechanik bekannte Prinzip der virtuellen Verrückung angewendet. Dieses besagt, dass die virtuelle innere Arbeit δW_i gleich der virtuellen äußeren Arbeit δW_a ist. Die virtuellen Verschiebungen δu stellen gedachte, differentiell kleine und mit der geometrischen Konfiguration vereinbare Verschiebungen dar. Mit der gespeicherten inneren Arbeit und der durch die äußeren Kräfte geleisteten spezifischen Formänderungsarbeit als äußere Arbeit ergibt sich

$$\delta W_i = \iiint_V \{\sigma\} \delta \{\varepsilon\} dV = \iiint_V \{p\} \delta \{u\} dV + \{f_i\} \delta \{u_i\} = \delta W_a \quad (2-18)$$

mit dem Vektor der Volumenkräfte $\{p\}$ und dem Vektor der äußeren Knotenlasten $\{f_i\}$. Wird in Gleichung (2-18) $\{\sigma\} = [E][\varepsilon] = [E][C]\{u_i\}$, $\delta\{\varepsilon\} = [C]\delta\{u_i\}$ und $\delta\{u\} = [N]\delta\{u_i\}$ ersetzt, erhält man nach mehrmaligem Umformen

$$\iiint_V [C][E][C] dV \cdot \{u_i\} = \{f_i\}. \quad (2-19)$$

Da $[K]\{u_i\} = \{f_i\}$, ergibt sich schließlich

$$[K] = \iiint_V [C][E][C] dV \quad (2-20)$$

als globale Steifigkeitsmatrix [86].

Unter Berücksichtigung der Strukturparameter des vorliegenden Festkörpers wird damit die Lösung der in Abschnitt 2.2 besprochenen Bewegungsgleichung mit Hilfe des dort behandelten Lösungsansatzes möglich.

2.1.3 Aspekte zur Verwendung der FEM

Die Beschreibung der grundlegenden FE-Theorie erfolgte im vorangegangenen Abschnitt. Dabei wurde dargestellt, dass die grundlegenden Gleichungen aus der Kontinuumsmechanik resultieren. In der beschriebenen Form ermöglichen sie nun die Betrachtung von diskreten Systemen mehrerer Freiheitsgrade. Die Diskretisierung einer Struktur geschieht dabei durch Vernetzen, d. h. eine Struktur wird in Teilbereiche zerlegt. Ein finites Element ist dabei ein durch endlich viele Knoten beschriebener Teilbereich. Jeder Knoten besitzt drei translatorische und drei rotatorische Freiheitsgrade. Die Form eines jeden Elements richtet sich dabei nach Bauteilgeometrie und Belastung oder Berechnungsziel. Dabei kann es ausreichend sein, ein Flächen- oder Volumenmodell zu übernehmen. Ist ein komplettes räumliches Gebilde zu analysieren, so ist in den meisten Fällen ein Volumenmodell erforderlich [82].

Der Einsatz komplexer Geometrien, wie es CAD-Geometrien industriellen Ursprungs sind, führt schnell zu einem unverhältnismäßig großen Vernetzungsaufwand, der bei manueller Eingabe zudem fehleranfällig ist [80]. Daher werden CAD-Geometrien, die in die meisten gängigen FEM-Codes eingelesen werden können, zunehmend mit automatischen Netzgeneratoren diskretisiert [88, 89, 90]. Dabei handelt es sich um Programme, die ausgehend von der Struktur und einigen Bildungsvorschriften, wie Toleranzgrenzen, Elementtypen, Startpunkten und Symmetrien, eine feine Unter-

teilung und entsprechende Koordinaten errechnen. Die Struktur wird dadurch diskretisiert. Es stehen die meisten gängigen Elementtypen zur Auswahl (vgl. auch [79, 82]). Dazu zählen, abgesehen von einzelnen Spezialelementen, Platten- und Strukturelemente in ebenen, hexagonalen und tetraedalen Formen. Auch sind viele Elementtypen in unterschiedlichen Ausführungen hinsichtlich ihrer Knotenanzahl verfügbar. Normalerweise steigt mit der Knotenzahl nicht nur die Genauigkeit der Güte der Verschiebungen und der Spannungen, sondern auch die Größe der Elementsteifigkeitsmatrix und somit der benötigte Rechenaufwand. Zur weiteren Vertiefung der Vor- und Nachteile der einfachen, auf linearen Ansätzen aufbauenden, Elemente bis hin zu den Elementen der „Serendipity“-Klasse wird auf die Literatur verwiesen (beispielsweise [80]). Begrenzt wird der Einsatz der letztgenannten meist durch den Aufwand der Eingabe, die zur Verfügung stehende Rechnerleistung und die Fähigkeiten des Netzgenerators [79]. Vergleiche mit realen Systemen führen bei den verschiedenen Elementtypen zur Beurteilung ihrer Leistungsfähigkeit in erster Linie in Bezug auf die Güte der Berechnung von Verschiebungen und Spannungen [91, 92].

Zur Vertiefung der speziellen Eigenschaften dieser Elemente wird auf die Literatur verwiesen [79, 80, 81, 82, 83]. In Anbetracht der variablen Positionierungsmöglichkeiten von Tetraederelementen werden diese Elementtypen bevorzugt beim Diskretisieren von Festkörpern mit Netzgeneratoren eingesetzt. Dabei wird deren im Vergleich zu hexagonalen Elementen verringerte Güte in Kauf genommen. Eine Validierung der Ergebnisse ist in jedem Fall zwingend, um Simulationen mit Anwendungen der Praxis zu vergleichen [93].

2.2 Ausgewählte Aspekte der Schwingungslehre

Die mathematische Beschreibung eines schwingungsfähigen diskreten Systems erfolgt im Allgemeinen durch die „Bewegungsgleichung“

$$[M]\{\ddot{u}\} + [D]\{\dot{u}\} + [K]\{u\} = \{f\}(t), \quad (2-21)$$

welche auch die Grundlage für das beschriebene numerische Modell ist. Dabei werden in einem Finite-Elemente-Modell die Massenmatrix $[M]$, die Dämpfung $[D]$ und die Steifigkeit $[K]$ durch seine Geometrie und seine Materialparameter festgelegt. Die Kraft $\{f\}(t)$ beschreibt die Erregung und $\{u\}$ repräsentiert den Verschiebungsvektor aller Freiheitsgrade des diskretisierten Modells.

Nachfolgende Abschnitte beschreiben, ausgehend von Gleichung (2-21), die Berechnung von Eigenformen und –frequenzen sowie deren Lösung bei erzwungener

Schwingung für lineare Systeme. Der Eigenmode oder die Eigenform bezeichnet dabei die Verformung der Struktur bei einer bestimmten Eigenfrequenz. Eigenfrequenzen und Eigenmoden sind somit Funktionen der jeweiligen Strukturparameter (Geometrie- und Materialparameter). Bei Übereinstimmung von Erregungsfrequenz und einer seiner Eigenfrequenzen antwortet das System mit sehr großen Amplituden. Es kommt zur Resonanz.

2.2.1 Bewegungsgleichung

Die Bewegungsgleichung (2-21) für Schwinger mit mehreren Freiheitsgraden geht aus der Grundform für Schwinger mit einem Freiheitsgrad hervor. Ihre maßgebenden mechanischen Eigenschaften stellen Trägheit, Dämpfung und Steifigkeit dar.

Trägheit

Der Term $[M]\{\ddot{u}\}$ der Bewegungsgleichung entspricht der Trägheitskraft der beschleunigten Masse. Zur Aufstellung der Massenmatrix eines diskreten FE-Systems gibt es folgende Möglichkeiten:

- Diskrete (lumped) Matrix: Bei dieser Methode wird die statische Masse des Elements auf die Knoten verteilt. Man erhält eine diskrete Matrix mit ungekoppelten Massenkomponenten.
- Konsistente (coupled) Matrix: Bei diesem Verfahren werden Ansätze für den Verschiebungs- und Beschleunigungsverlauf im Inneren eines finiten Elementes gebildet. Aus Variationsprinzipien folgt die konsistente Matrix, deren Komponenten untereinander gekoppelt sind. Diese Möglichkeit erweist sich bei der Berechnung als langsamer, bietet jedoch eine höhere Genauigkeit [79].

Dämpfung

Die Bewegung einer realen Struktur erfährt beim Schwingungsvorgang stets eine Dämpfung, da sich kinetische Energie in Schallenergie oder thermische Energie umwandelt. Die Dämpfungskraft $[D]\{\dot{u}\}$ wirkt entgegengesetzt der Richtung des Geschwindigkeitsvektors. Dabei werden die *äußere Dämpfung* (Viskose Dämpfung, Coulombsche Dämpfung) und die *innere Dämpfung* (Energiedissipation auch ohne umgebendes oder angrenzendes Medium) unterschieden. In der Praxis wird der Dämpfungskoeffizient mit Hilfe von Experimenten ermittelt [85].

Steifigkeit

In Gleichung (2-21) entspricht $[K]\{u\}$ der Federkraft bzw. der „inneren“ Elastizitätskraft. Diese Rückstellkraft stellt sich infolge der Verformung u des elastischen Systems ein. Der Bestimmung der Steifigkeitsmatrix liegt eine rein elastostatische Aufgabe zugrunde. Zur numerischen Simulation wird die Steifigkeitsmatrix $[K]$ des Gesamtsystems direkt aus den einzelnen Elementsteifigkeitsmatrizen aufgebaut [85]. Prinzipiell stehen zur Lösung von (2-21) zwei Möglichkeiten zur Verfügung:

- Direkte/physikalische Vorgehensweise: Es erfolgt die direkte numerische Integration der Differentialgleichungen des Systems.
- Modale Vorgehensweise: Die Transformation des Differentialgleichungssystems in den modalen Raum entkoppelt die Gleichungen, da dieser durch Eigenvektoren aufgespannt wird. Sie lassen sich dort jeweils wie die Gleichungen eines Schwingers mit einem Freiheitsgrad lösen und wieder in den physikalischen Raum zurücktransformieren.

2.2.2 Eigenschwingung

Die Berechnung der Eigenformen und -frequenzen ist ein zentrales Thema bei der Durchführung dynamischer Analysen. Eigenschwingungen repräsentieren die der Struktur innewohnenden Formen, mit denen sie schwingt, wenn sie in ihrer Ruhelage gestört wird. Sie geben Auskunft darüber, wie das System auf dynamische Anregungen reagiert. Für die Messtechnik erweist sich die Kenntnis der Eigenschwingungen als grundlegend, z. B. um zu vermeiden, dass Schwingungssensoren in Schwingungsknoten charakteristischer Eigenmoden liegen, da dort aufgrund lediglich geringfügiger Bewegung kaum ausreichende Signale zu messen wären.

Die Eigenformen hängen von der Masse, der Steifigkeit und den Rand- bzw. Lagerbedingungen ab. Zur Berechnung geht man bei vorausgesetztem linearem Verhalten von dem anregungsfreien, ungedämpften bzw. homogenen Teil der Bewegungsgleichung (2-21) aus:

$$[M]\{\ddot{u}\} + [K]\{u\} = 0 . \quad (2-22)$$

Als Lösung eignet sich der Ansatz

$$\{u\} = \{\phi\} e^{i\omega t} , \quad (2-23)$$

mit ω als Eigenkreisfrequenz. Zweimaliges Ableiten von Gl. (2-23) und anschließendes Einsetzen in Gl. (2-22) führt zu

$$(-\omega^2[M] + [K])\{\phi\}e^{i\omega t} = 0. \quad (2-24)$$

Ersetzt man ω^2 durch die Eigenwerte λ und kürzt $e^{i\omega t}$ ergibt sich das allgemeine Eigenwertproblem

$$(-\lambda[M] + [K])\{\phi\} = 0. \quad (2-25)$$

Kontinua besitzen unendlich viele Freiheitsgrade. Abgebildet auf ein diskretes System mit n Freiheitsgraden ergeben sich jedoch n Eigenwerte. Neben der trivialen Lösung $\{\phi\} = 0$ löst

$$\det([K] - \lambda[M]) = 0 \quad (2-26)$$

die Gleichung (2-22). Für diskrete Eigenwerte $\lambda_i (i=1, 2, \dots, n)$ verschwindet die Determinante und der Eigenvektor $\{\phi_i\}$ erfüllt die Gleichung (2-26). Jeder dieser Eigenvektoren definiert eine freie Schwingungsform mit der Eigenfrequenz

$$f_{FRi} = \frac{\omega_i}{2\pi} \quad \text{oder} \quad \omega_i = \sqrt{\lambda_i}. \quad (2-27)$$

Die Eigenformen lassen sich bis auf einen Faktor bestimmen, der sich erst aus der Schwingung um die stabile Gleichgewichtslage ergibt. Extrema sind die Koordinaten des Eigenvektors $\{\phi_i\}$. Die Zahl der möglichen Eigenformen folgt dabei aus der Anzahl der Freiheitsgrade des Systems [81]. Die Bewegung einer linearen elastischen Struktur stellt dabei eine Linearkombination aller Normalmoden mit $\xi_i(\omega_i, t)$ als i -te modale Verschiebung

$$\{u\} = \sum \{\phi_i\} \xi_i(\omega_i, t) \quad (2-28)$$

dar.

Werden nur lineare Schwingungen in stabiler Gleichgewichtslage betrachtet, dann sind $[K]$ und $[M]$ symmetrisch und reell [84]. Somit gilt:

$$\begin{aligned} \{\phi_i\}^T [K] \{\phi_j\} &= 0 && \text{für } i \neq j, \\ \{\phi_j\}^T [K] \{\phi_j\} &= k_j && \text{für die } j\text{-te verallgemeinerte Steifigkeit,} \\ \{\phi_i\}^T [M] \{\phi_j\} &= 0 && \text{für } i \neq j, \\ \{\phi_j\}^T [M] \{\phi_j\} &= m_j && \text{für die } j\text{-te verallgemeinerte Masse.} \end{aligned} \quad (2-29)$$

Diese Beziehung nennt man orthogonale Eigenschaft. Sie setzt die Proportionalität der verallgemeinerten Massen- oder Steifigkeitsmatrizen zur Einheitsmatrix voraus. Dies drückt die algebraische Unabhängigkeit einer Eigenschwingung aus. Mit

$k_j = \omega^2 m_j$ erhält man die Rayleigh-Gleichung:

$$\omega_j^2 = \frac{\{\phi_j\}^T [K] \{\phi_j\}}{\{\phi_j\}^T [M] \{\phi_j\}} \quad (2-30)$$

Eine natürliche Schwingungsform drückt sich demgemäß in ihrer verallgemeinerten Masse und Steifigkeit aus. Eigenformen erweisen sich somit als quantitative Darstellungen, die auf relativen Verschiebungen basieren. Demzufolge ist die Skalierung der Amplitude frei wählbar. Eine mögliche häufig verwendete Methode zur Skalierung besteht in der Normierung der generalisierten Masse auf $m_j = 1$. Daraus folgt $k_j = \omega_j^2$ und es gilt

$$[\phi_j]^T [M] [\phi_j] = [E_M] \quad (2-31)$$

$$\text{und } [\phi_j]^T [K] [\phi_j] = [\Lambda] \quad (2-32)$$

mit der Modalmatrix $[\phi]$, der Einheitsmatrix $[E_M]$ und der genormten generalisierten Steifigkeitsmatrix $[\Lambda]$, die bei dieser Normierung die Eigenwerte auf der Hauptdiagonalen enthält.

Zur Lösung des Eigenwertproblems finden numerisch üblicherweise die Givens-, die Householder- oder die Lanczos-Methode Einsatz, wobei für große Modelle Lanczos bevorzugt wird. Zu ihrer ausführlichen Beschreibung wird auf die Literatur verwiesen [79, 84, 85, 86].

2.2.3 Erzwungene Schwingung

Eine erzwungene Schwingung lässt sich mit der bereits erwähnten Bewegungsgleichung (2-21) beschreiben. Für die harmonische Erregung gilt die allgemeine Form

$$\{f\}(t) = \{F\} \cos(\Omega t - \varphi) = \{F^C\} \cos \Omega t + \{F^S\} \sin \Omega t \quad (2-33)$$

mit der Erregerfrequenz Ω , dem Phasenwinkel φ und den Fourier-Koeffizienten F^C und F^S des Cosinus- und Sinus-Anteils der harmonischen äußeren Kraft.

Die allgemeine Lösung der Bewegungsgleichung (2-21) setzt sich aus einer partikulären und einer homogenen Lösung bzw. aus freier und erzwungener Schwingung zusammen.

$$\{u\}(t) = \{u_{\text{partikulär}}\}(t) + \{u_{\text{homogen}}\}(t) \quad (2-34)$$

Im Falle periodischer Anregung wird als partikuläre Lösung des linearen Systems die periodische Lösung gewählt, d. h. die „eingeschwungene“ oder „stationäre“ Lösung.

Die Beschreibung des Abklingverhaltens einer Schwingung, bezogen auf die Periode des ungedämpften Schwingers, ermöglicht das dimensionslose Dämpfungsmaß D . Für $D < 1$ gilt dabei

$$\{u\}(t) = \{A\} \cos(\Omega t - \varphi) + (\{B\} \cos \omega_d t + \{C\} \sin \omega_d t) e^{-\delta t} \quad (2-35)$$

mit dem modalen Abklingkoeffizient δ , der Kreisfrequenz ω_d der gedämpften harmonischen Schwingung und den Integrationskonstanten B und C .

Für $D > 0$ klingt der homogene Teil der Lösung mit der Zeit ab, während die partikuläre Lösung erhalten bleibt. Den Schwingungsvorgang bis zum Abklingen des homogenen Teils nennt man „Einschwingvorgang“. Im eingeschwungenen Zustand ist die Schwingung „stationär“, der Schwinger schwingt dabei harmonisch mit der Erregerfrequenz Ω , die entsprechend seiner viskosen Dämpfung phasenverschoben ist. Aufgrund des Abklingens wird im Folgenden nur die Partikulärlösung bzw. die stationäre Lösung betrachtet [84].

Komplexe Darstellung

Die komplexe Erweiterung bietet die Möglichkeit, die Rechnungen zu vereinfachen und eine anschaulichere Deutung des Rechenganges mit Hilfe des Zeigerdiagramms zu erhalten. Zusätzlich ermöglicht sie Aussagen über die Amplitude und die Phasenverschiebung in einer einzigen Größe, der komplexen Amplitude.

In der komplexen Zahlenebene (Gaußsche Zahlenebene) erfolgt die Beschreibung als Ortsvektor \underline{x} („Zeiger“). Es gilt

$$\underline{x} = \operatorname{Re} \underline{x} + i \operatorname{Im} \underline{x} \quad (2-36)$$

mit $\operatorname{Re} \underline{x} = |\underline{x}| \cos \alpha$, $\operatorname{Im} \underline{x} = |\underline{x}| \sin \alpha$ und $\underline{x} = |\underline{x}| e^{i\alpha}$. Die komplexe harmonische Funktion

$$\underline{f}(t) = F \cos(\Omega t - \alpha) + i F \sin(\Omega t - \alpha) = F e^{i(\Omega t - \alpha)} \quad (2-37)$$

wird somit als komplexe Erweiterung von Gleichung (2-33) bezeichnet. Fasst man deren Betrag F und den Phasenwinkel α zur komplexen Amplitude $\underline{F} = F e^{-i\alpha}$ zusammen, ergibt sich

$$\underline{f}(t) = \underline{F} e^{i\Omega t} \quad (2-38)$$

Die reelle harmonische Funktion $f(t)$ entspricht dem Realteil ihrer komplexen

Erweiterung

$$f(t) = \operatorname{Re} \underline{f}(t) . \quad (2-39)$$

$\underline{f}(t)$ entspricht in der komplexen Ebene einem Zeiger der Länge F , der mit der Winkelgeschwindigkeit Ω gegen den Uhrzeigersinn rotiert [84, 85].

Partikuläre Lösung für Schwinger mit einem Freiheitsgrad

Für die Partikulärlösung von Gl. (2-35) lautet der Ansatz

$$u_p(t) = A \cos(\Omega t - \varphi) . \quad (2-40)$$

Zusammen mit der Bewegungsgleichung (2-21), der harmonischen Anregung $f(t) = F \cos(\Omega t)$ sowie auf einen Freiheitsgrad reduziert, ergibt sich

$$m A \Omega^2 \cos(\Omega t - \varphi) - d A \Omega (\sin \Omega t - \varphi) + k A \cos(\Omega t - \varphi) = F \cos(\Omega t) . \quad (2-41)$$

Abbildung 2-1 stellt Gleichung (2-41) in der komplexen Ebene dar. Die Größe $f(t)$ entspricht dem reellen Anteil des mit der Kreisfrequenz Ω drehenden Zeigers $\underline{f}(t)$.

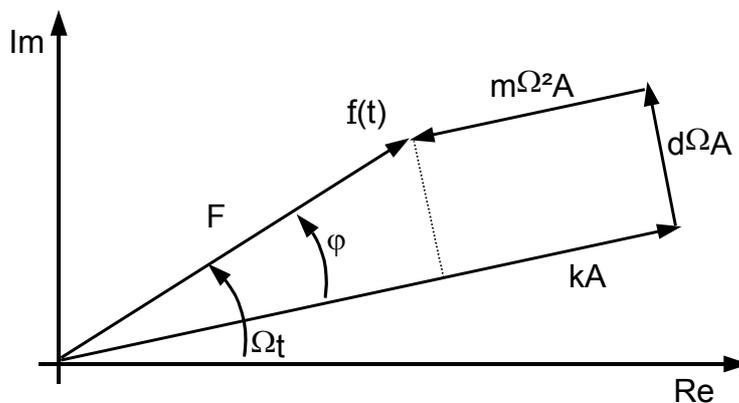


Abbildung 2-1: Darstellung von Gleichung (2-41) in der komplexen Ebene [84]

Hieraus (Abbildung 2-1) kann abgelesen werden, dass

$$F^2 = (kA - m\Omega^2 A)^2 + (d\Omega A)^2 . \quad (2-42)$$

Die Umformung der Gleichung (2-42) unter Verwendung des Dämpfungsmaßes

$D = \frac{d}{2\sqrt{km}}$ und des Frequenzverhältnisses $\eta = \Omega \sqrt{\frac{m}{k}} = \frac{\Omega}{\omega}$ führt zur Amplitude

$$A = \frac{F}{\sqrt{(k - m\Omega^2)^2 + (d\Omega)^2}} = \frac{F}{k} \cdot \frac{1}{\sqrt{(k - \eta^2)^2 + (d\Omega)^2}} \quad (2-43)$$

und zur Phasenverschiebung

$$\tan \varphi = \frac{d\Omega A}{(k - m\Omega^2)A} = \frac{d\Omega}{k - m\Omega^2} = \frac{2D\eta}{1 - \eta^2} \quad (2-44)$$

Sowohl die Amplitude A als auch die Phasenverschiebung φ hängen von dem Frequenzverhältnis η und dem Dämpfungsmaß D ab. Abbildung 2-2 illustriert beispielhaft die deren Abhängigkeit für verschiedene Dämpfungsmaße D als Phasenfunktion $\varphi(\eta)$. $D = 0$ zeigt dabei den Phasensprung eines ungedämpften Systems an der Resonanzstelle [85, 86].

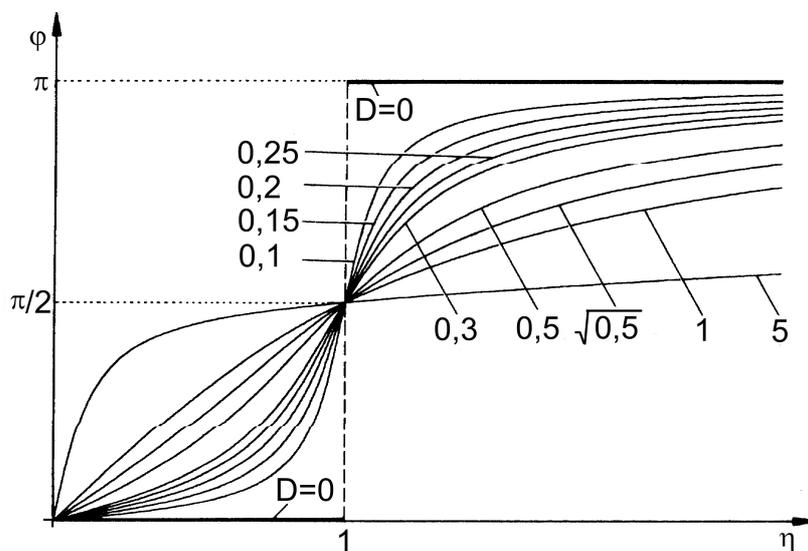


Abbildung 2-2: Phasenfunktion $\varphi(\eta)$ verschiedener Dämpfungsmaße D [86]

Vergrößerungsfunktion $V(\eta)$

Wird die Amplitude A bezogen auf die statische Verschiebung $u_{st} = \frac{F}{k}$ hinsichtlich der Ruhelage des Körpers bezogen, ergibt die Vergrößerungsfunktion $V(\eta)$.

$$\frac{A}{u_{st}} \equiv V(\eta) = \frac{1}{\sqrt{(1 - \eta^2)^2 + (2D\eta)^2}} \quad (2-45)$$

Für die Beschreibung der Amplitude ermöglicht sie die Beurteilung des Verhältnisses der dynamischen zur statischen Antwort. Drei Fälle werden dabei unterschieden:

- unterkritische Erregung: Für $\Omega \ll \omega$ bzw. $\eta \ll 1$ ist die Vergrößerungsfunktion $V(\eta) \approx 1$. Man erhält die statische Lösung mit $A \approx u_{st}$ und $\varphi \approx 0$. Die Kraft $f(t)$ ist in Phase mit der Verschiebung $u(t)$.

- überkritische Erregung: Für $\Omega \gg \omega$ bzw. sehr großes Frequenzverhältnis η wird die Vergrößerungsfunktion $V(\eta) \approx \frac{1}{\eta^2}$ und geht gegen Null. Man erhält sehr kleine Verschiebungen. In diesem Fall antwortet das System nicht auf die Erregerkraft, da sich diese zu schnell für die Struktur ändert.
- Resonanzbereich: Für $\Omega \approx \omega$ bzw. $\eta \approx 1$ ist die Vergrößerungsfunktion $V(\eta)_{\max} = \frac{1}{2D}$.

Abbildung 2-3 zeigt die Abhängigkeit der Vergrößerungsfunktion $V(\eta)$ von dem Frequenzverhältnis η für verschiedene Dämpfungen D [79, 84, 87].

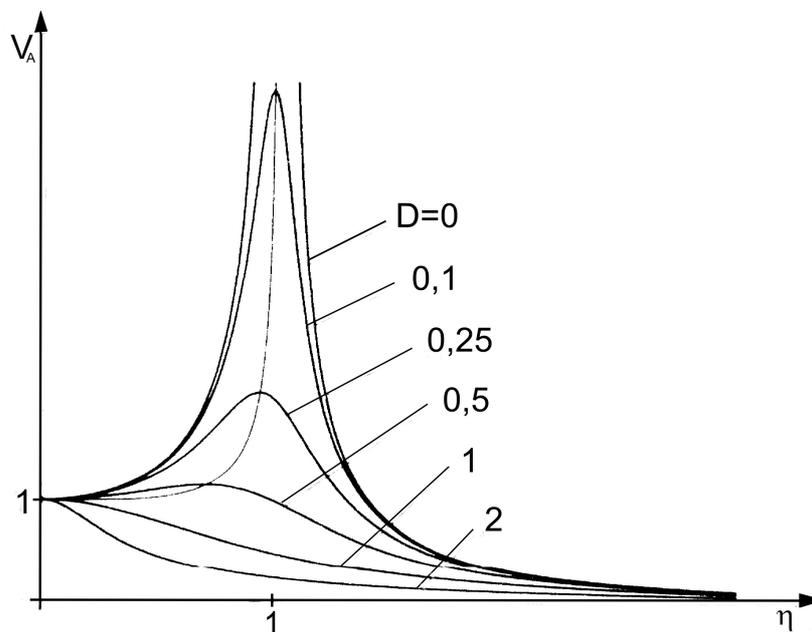


Abbildung 2-3: Vergrößerungsfunktion $V(\eta)$ verschiedener Dämpfungsmaße D [86]

Partikuläre Lösung für Schwinger mit mehreren Freiheitsgraden

Betrachtet man nun einen Schwinger mit n Freiheitsgraden mit einem Erregungsvektor $\{f\}(t)$, bei dem sämtliche Komponenten $f_k(t)$ harmonische Zeitfunktionen der gleichen Frequenz Ω sind, so erhält man folgende Bewegungsgleichung für die komplexe Erweiterung der partikulären Lösung:

$$[M]\{\ddot{u}\} + [D]\{\dot{u}\} + [K]\{u\} = \{f\}e^{i\Omega t} . \quad (2-46)$$

Setzt man $\{u\}(t) = \{A\}e^{i\Omega t}$ und dessen Ableitungen in (2-46) ein und kürzt die Gleichung um $e^{i\Omega t}$, ergibt sich mit dem komplexen Vektor der Amplituden $\{A\}$ die

Beziehung

$$\left(([K] - [M]\Omega^2) + i[D]\Omega \right) \{\underline{A}\} = \{\underline{f}\}. \quad (2-47)$$

Mit der dynamischen Nachgiebigkeitsmatrix

$$[\underline{H}](\Omega) = \left(([K] - [M]\Omega^2) + i[D]\Omega \right)^{-1} \quad (2-48)$$

folgt die Kraft-Verformungsbeziehung für dynamische Lasten bei harmonischer Belastung

$$\{\underline{A}\} = \left(([K] - [M]\Omega^2) + i[D]\Omega \right)^{-1} \{\underline{f}\} = [\underline{H}](\Omega) \{\underline{f}\}. \quad (2-49)$$

Gleichung (2-49) ist ein komplexes, lineares, inhomogenes Gleichungssystem der Ordnung n für die komplexe Amplitude \underline{A}_k . Für wenige Freiheitsgrade kann man die Lösung noch nach der Cramerschen Regel ermitteln:

$$\underline{A}_k(\Omega) = \frac{\underline{Z}_k(\Omega)}{\underline{N}(\Omega)}. \quad (2-50)$$

Der komplexe Nenner $\underline{N}(\Omega)$ errechnet sich als die Determinante der Koeffizientenmatrix $[\underline{K}](\Omega)$

$$\underline{N}(\Omega) = \det[\underline{K}](\Omega) = \det\left(([K] - [M]\Omega^2 + i[D]\Omega) \right). \quad (2-51)$$

Der komplexe Zähler $\underline{Z}_k(\Omega)$ ergibt sich aus der Determinanten der Matrix. Sie errechnet sich, wenn man in der Koeffizientenmatrix $[\underline{K}](\Omega)$ die k -te Spalte durch den Vektor $\{\underline{f}\}$ der komplexen Amplitude der Erregerkraft ersetzt [87]. Aus Betrag und Argument von Zähler und Nenner folgt die Amplitude A_k und der Phasenwinkel φ_k der gesuchten Antwort. Es resultiert

$$u_k(t) = A_k \cos(\Omega t - \varphi_k) \quad (2-52)$$

$$\text{mit } A_k = \left| \frac{\underline{Z}_k(\Omega)}{\underline{N}(\Omega)} \right| \text{ und } \varphi = -[\arg \underline{Z}_k(\Omega) - \arg \underline{N}(\Omega)]. \quad (2-53)$$

Large-Mass-Prinzip – „Enforced Motion“

Erzwungene Bewegung („Enforced Motion“) wird in der numerischen Simulation durch eine Verschiebung, Geschwindigkeit oder Beschleunigung an den betreffenden Knotenpunkten spezifiziert. Sie kommt zusammen mit anderen Randbedingungen und Belastungen zum Einsatz. Das gängigste Beispiel ist die Anregung eines Gebäudes bei einem Erdbeben. Hier wirken keine zusätzlichen Kräfte, nur der Boden

erfährt eine erzwungene zeitabhängige Verschiebung oder Beschleunigung. Diesen Effekt nutzen viele FE-Programme, um Modelle in ihren Eigenschwingungen zu simulieren.

Neben hier nicht weiter besprochenen Verfahren stellt das „Large-Mass-Prinzip“ eine vereinfachte numerische Methode dar, die auch bei der in dieser Arbeit eingesetzten FE-Software MSC/NASTRAN implementiert ist. Dabei wird einer Struktur eine Kraft in Verbindung mit einer konzentrierten Masse aufgezwungen. Üblicherweise wird dabei den betreffenden Bodenknotenpunkten eine Masse $m = 10^6 \cdot m_0$ zugewiesen, wobei m_0 die Masse der Struktur ist. Sie wird exakt den Freiheitsgraden der Knotenpunkte zugewiesen, in deren Richtung auch die Anregung auf die Struktur einwirkt. Durch eine entsprechend dem Faktor 10^6 angepasste Anregung erhält man hieraus die gewünschten Bewegungen mit einer numerischen Genauigkeit von sechs Stellen [79].

Eine Weiterentwicklung ist in der neuesten Version von MSC/NASTRAN [„V2001“] mit der SPCD-Methode implementiert. Dabei erfolgt innerhalb der Methode der „Enforced Motion“ eine Konvertierung der „Large-Mass-Methode“ in ein direktes Verfahren. Dadurch ist eine effektivere und fehlerfreiere Implementierung im Solver des FE-Codes gewährleistet. Außerdem werden Rundungsfehler und „Pseudo-Festkörpermoden“ verringert [94].

2.3 Mustererkennung mit künstlichen neuronalen Netzen

KNN bilden in vereinfachter Form natürliche neuronale Netze ab, wie sie in Säugerhirnen vorkommen. Diese vermögen aus vorgegebenen Daten und Erfahrungen auf Zusammenhänge zu schließen, die sich bei späteren Entscheidungsprozessen anwenden lassen. Obgleich natürliche Netze (noch) nicht modellierbar sind, ermöglichen KNN die Erarbeitung logischer Schlüsse [95].

Der grundlegende Aufbau eines KNN lehnt sich in stark idealisierter Form an das biologische Vorbild an. Dabei werden die Zellen als Neuronen aus drei Komponenten dargestellt: Zellkörper, Dendriten und Axon.

Der Zellkörper addiert die Eingaben der Dendriten des Netzes in der Zelle auf, das Axon (Neurit) leitet die Ausgabe einer Zelle nach außen weiter, verzweigt sich und tritt mit den Dendriten nachfolgender Neuronen über Synapsen in Kontakt. Die Stärke der Synapsen wird dabei meist durch einen numerischen Wert, der die Verbindung gewichtet, dargestellt. Ausgehend davon werden die Verbindungen

zwischen Neuronen als direkte, gewichtete Verbindungen zwischen zwei Zellen i und j dargestellt. Dies erfolgt meist in graphischen Schemata (vgl. Abbildung 2-4).

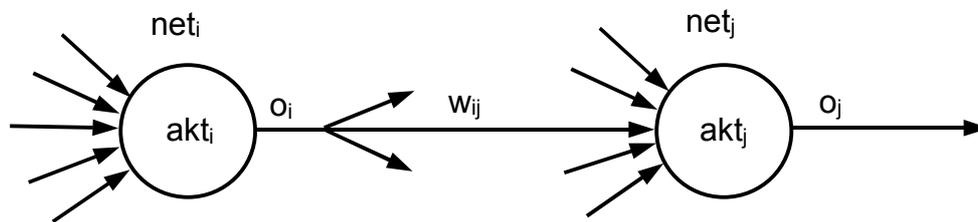


Abbildung 2-4: Darstellung von miteinander verbundenen Zellen („Neuronen“) eines neuronalen Netzes

Ihre Einsatzmöglichkeiten verdanken KNN einer Reihe von Vorzügen [95, 96, 97]. Der wichtigste, die *Lernfähigkeit*, ermöglicht eine Problemlösung durch ein (überwachtes oder unüberwachtes) Training und ersetzt damit die Programmierung eines dazu notwendigerweise bekannten Lösungsweges.

Als problematisch bei manchen Anwendungen von KNN erweist sich jedoch die Implementierung von Vorwissen. Obwohl auf diesem Gebiet ausgiebig geforscht wird [98, 99], konnten noch keine allgemeingültigen Verfahren hierzu entwickelt werden. Die Konsequenz daraus ist, dass auch bereits bekannte Fakten trainiert werden müssen, da *nur Lernen Wissenserwerb* ermöglicht. Ein Eingreifen in die Vorgänge innerhalb eines Netzes, z. B. gezieltes Lernen bestimmter Aspekte durch definierte Neuronen, ist nicht ohne weiteres möglich. Es gibt *keine Introspektion*, d. h. eine Analyse des Wissens ist weder durch ein KNN selbst, noch von außen möglich.

Als lernendes System vermag ein KNN aus gegebenen Trainingsdaten Muster zu approximieren, wenn diese durch die Testdaten *repräsentiert* werden. Zur Mustererkennung werden KNN bereits seit einiger Zeit eingesetzt [47, 48, 100]. Dabei sticht ihre Fähigkeit zu approximieren hervor und grenzt sie zu klassischen Klassifikatoren oder auch Assoziativspeichern ab.

Der Prozess, unvollständige Datensätze mit kontinuierlichen Funktionen zu charakterisieren, wird als *Generalisierung* bezeichnet. Die Eigenschaft des Netzes wird durch seine *Generalisierungsfähigkeit* bewertet. Ein KNN ist so in der Lage, fehlende Punkte oder unklare Informationen zu interpolieren und auf ein allgemeines Modell der Daten abzubilden. Entsprechend trainierte KNN generalisieren. Dieser Prozess wird oft auch als Fähigkeit zur Verallgemeinerung bezeichnet.

Die grundlegenden Komponenten eines KNN werden nachfolgend erläutert. Dabei wird das Hauptaugenmerk auf die in dieser Arbeit zur Anwendung kommenden

Algorithmen gelegt. Im Vordergrund stehen dabei Mustererkennungsaufgaben [48, 101].

2.3.1 Neuronen

In der Literatur [95, 96, 102] werden Neuronen oft auch als Zellen, Knoten, Elemente oder Units bezeichnet. Als zentraler Bestandteil eines jeden Netzwerkes setzt sich die Funktionalität jedes einzelnen Neurons aus mehreren Komponenten zusammen (vgl. Abbildung 2-5).

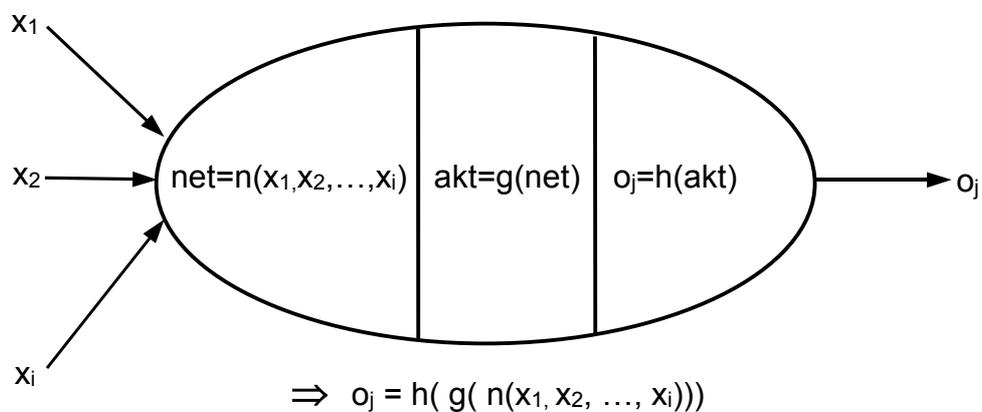


Abbildung 2-5: Schematische Darstellung eines Neurons j und dessen Funktionalität gemäß der Komponenten: Propagierungs- $n(x_1, \dots, x_i)$, Aktivierungs- $g(\text{net})$ und Ausgabefunktion $h(\text{akt})$.

Die Signale aus der Netzeingabe anderer Neuronen werden anhand einer Propagierungsfunktion berechnet. Sie summiert die gewichteten Verbindungen ($x_i = o_i \cdot w_{ij}$) aus den Ausgaben der anderen Neuronen o_i und deren Verbindungsgewichten w_{ij} auf (vgl. Gleichung (2-54)). Der Schwellenwert θ limitiert dabei den Eingang.

$$net_j = \left(\sum_i o_i \cdot w_{ij} \right) - \theta_j \tag{2-54}$$

Zur Aktivierung eines jeden Neurons führt in vielen Anwendungen eine sigmoide Aktivierungsfunktion. Diese kann beispielsweise vom Typ

$$akt_j = a_j = 1 / (1 + \exp(-net_j)) \tag{2-55}$$

sein. Dabei errechnet sich aus akt_j die Aktivität des Neurons für die Ausgabe an das nachfolgende Neuron. Das hat eine (quasi) binäre Ausgabe zur Folge, die durch eine Ausgabefunktion

$$o_j = h(akt_j) \quad (2-56)$$

weitergegeben wird und in der Ausgabeschicht des KNN zur Prädiktion führt. Binäre Ausgabewerte eignen sich dabei in der Ausgabeschicht besonders gut zur Zuordnung in Klassen. Es sei jedoch angemerkt, dass binären Zustände durch einen kontinuierlichen Wertebereich abgedeckt werden, welcher die Aktivierung auf ein Intervall beschränkt, beispielsweise auf $[0, 1]$ oder $[-1, 1]$. Sie haben sich im Hinblick auf die Approximationseigenschaften von KNN gegenüber diskreten Wertebereichen als vorteilhaft erwiesen, da „1“ für „wahr“ und „0“ für „falsch“ somit auch für viele unscharfe Muster angenähert werden kann [103]. In der vorliegenden Arbeit entsprechen die Ausgaben beispielsweise „intakt“ und „defekt“ zur Klassifizierung des Zustandes von Getränkekästen.

2.3.2 Topologie

Das Verbindungsnetzwerk der Neuronen wird auch als Topologie oder Architektur bezeichnet. Neben den Trainingsalgorithmen, der Trainings-Daten-Auswahl und der Form der Datenpräsentation, bestimmt die Topologie die Leistungsfähigkeit, also die Generalisierungsfähigkeit des KNN erheblich mit. Somit ist eine Reihe unterschiedlich aufgebauter Netzwerke denkbar. Ihre Einteilung basiert auf der Richtung der Verbindungen. Rekurrente Netze, d. h. Netze mit Rückkopplungen, führen zur Ausbildung eines Gedächtnisses. Probleme, zu deren Lösung dieses Merkmal notwendig ist, können so auf einfache Art und Weise gelöst werden [95]. Die sogenannten Feedforward-Netze besitzen nur Verbindungen in eine Richtung, von den Eingangsneuronen in Richtung der Ausgangsneuronen, ohne Berücksichtigung der Anzahl und Anordnung der verdeckten Neuronen. Ein solches Neuron leitet erworbenes Wissen weiter, ohne es zu nutzen.

Die Neuronen lassen sich in Schichten organisieren, so dass Neuronen einer Schicht nur mit Neuronen der vorhergehenden und der nachfolgenden in Verbindung stehen. Verbindungen, die eine Schicht überspringen, werden „Shortcut Connections“ genannt. Ihre Verwendung vermag nach [104] zu einer Leistungsverbesserung führen, da so Informationen schneller im ganzen Netz verteilt werden können. Zur Approximation lassen sich stetige Funktionen im Allgemeinen durch ein Feedforward-Netz mit einer verdeckten Schicht darstellen. Um Unstetigkeiten zu berücksichtigen oder komplexere Funktionen und Muster zu modellieren, muss in vielen Fällen eine weitere Schicht eingeführt werden [96, 105].

Aus mathematischer Sicht bildet das Netzwerk auch einen gerichteten, gewichteten Graphen, der mit Hilfe einer Gewichtsmatrix aus allen Schwellen und Verbindungsgewichten dargestellt wird. Die problembezogene Anpassung der Gewichte und Schwellenwerte erfolgt im Training. Dabei spiegeln die Werte der Gewichte die Intensität der Verbindungen wider. Der Wert $w_{ij} = 0$ verdeutlicht, dass keine Verbindung zwischen Neuron i und j besteht, $w_{ij} < 0$ bedeutet eine Hemmung und $w_{ij} > 0$ eine Anregung des Nachfolgeneurons.

In vielen Anwendungen eignet sich zur Mustererkennung besonders das sogenannte Multi-Layer-Perzeptron (MLP) [101]. Dieses Netz stellt den klassischen Typ eines ebenenweise verbundenen Feedforward-Netzwerkes dar, das ohne Rückkopplung nur Verbindungen zur nachfolgenden Neuronenschicht aufweist. In umfassenden Beschreibungen in der Literatur zeigt sich, dass sich das MLP trotz des vergleichsweise einfachen Aufbaus durch sehr gutes Klassifikationsverhalten auszeichnet. Eine typische Topologie zeigt Abbildung 2-6.

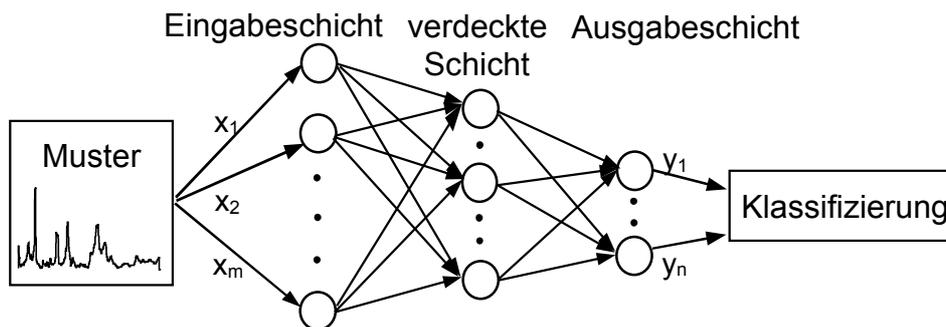


Abbildung 2-6: Multi-Layer-Perzeptron Netzwerk mit einer Eingabe-, einer verdeckten Zwischen- und einer Ausgabeschicht

Das Netzwerk repräsentiert den komplexesten Teil beim Erstellen eines KNN. Es existieren hierzu keine Standard-Methoden [106]. Über den besten Aufbau eines Netzwerkes gibt es mittlerweile viele unterschiedliche Ansichten und viele Anwendungsbeispiele. So betont [96], dass es problematisch sei, die optimale Netzwerkgröße zu finden. Es gilt jedoch als wahrscheinlich, dass MLP-Netzwerke mit einer endlichen Anzahl verborgener Neuronen in der Lage sind, Abschätzungen vorzunehmen. Außerdem erlaubt mittlerweile die Vielzahl von Anwendungen theoretischer Ergebnisse und empirischer Tests, „Leitlinien“ aufzustellen, mit deren Hilfe die grundlegenden Strukturen von Netzwerken aufgebaut werden können. Sie geben Empfehlungen zu der Anzahl verdeckter Neuronen, der Art der geeigneten Aktivierungsfunktionen und der Auswahl der Testprozedur (Trainingsalgorithmus) für eine bestimmte Anwendung als Startkonfiguration. Dies führt zum mittlerweile üblichen Ablauf beim Erstellen der Netzwerke, indem diese Konfiguration als

Ausgangspunkt genutzt wird. Einige abklärende Experimente prägen die funktionellste und stabilste Konfiguration aus. Allerdings tritt die Frage auf, ob ein gegebenes Muster grundsätzlich mit einer Topologie erkennbar ist oder nicht. Dies wird in Abschnitt 2.3.4 diskutiert. So werden Topologien mit zufriedenstellender Realisierung der Klassifizierung angenommen und nicht weiter verbessert. Das bedeutet, dass eine weitere Optimierung meist sehr aufwändig ist und die Generalisierungsfähigkeit des KNN nicht signifikant erhöht [96].

Die angesprochenen Leitlinien führen zu einem Netzaufbau hinreichender Qualität. Es gibt jedoch keine einfache Formel zur Netzkonfiguration und die in der Literatur beschriebenen Verfahren führen oftmals zu falschen Ergebnissen [106]. So erweisen sich die Richtlinien zur Implementierung [96] eines Feedforward-MLP-Netzwerkes größtenteils als heuristisch und von experimentellen Ergebnissen abgeleitet. Um kurze Trainingszeiten zu erreichen und Komplikationen komplexerer Netzwerke zu minimieren, bieten sich Netze mit möglichst geringer Größe an. Der Einsatz von mehr als zwei verborgenen Schichten ist nur in Ausnahmefällen notwendig. In der Regel reicht eine Schicht aus. Zudem ist es zweckmäßig, zu Beginn die Anzahl der Eingangs- und Ausgangsknoten festzulegen, da diese in der jeweiligen Anwendung die Freiheitsgrade (Anzahl der Gewichte und Schwellenwerte) des Netzes wesentlich mitbestimmen. Üblicherweise bestimmt dabei die Anzahl notwendiger Kategorien, Klassifizierungen oder Dimensionen des Ausgaberaumes die Ausgabeknotenzahl. Die Anzahl der Eingabeknoten hingegen orientiert sich an der Anzahl relevanter Eingangsgrößen, die wiederum durch sorgfältige Auswahl von Objekteigenschaften und deren Repräsentation (Codierung) aus dem zur Verfügung stehenden Datenmaterial gewonnen werden. Menge, Qualität und Relevanz repräsentieren die wesentlichen Attribute der Objekteigenschaften sowie der charakteristischen Bereiche, nach denen gruppiert, unterschieden und klassifiziert wird. Für einige Anwendungen erweisen sie sich als evident. Andere erfordern hingegen eine sorgfältige Analyse und Vorverarbeitung des Datenmaterials, was ebenso umfassende Experimente wie auch Einfallsreichtum bedingt.

Wie oben beschrieben, ist die notwendige Anzahl der verborgenen Schichten und deren Einheiten nicht eindeutig bestimmbar. Zu den wichtigsten Einflussfaktoren zählen dabei die Komplexität der Abbildung, die Anzahl der Muster in der Trainingsmenge, die Lernfähigkeit und die Generalisierungsfähigkeit des parametrisierten KNN. Ein Vorwissen über die Komplexität des Problembereiches ist hilfreich, aber nicht Voraussetzung. Daher wird üblicherweise mit einer verborgenen Schicht begonnen. Eine endgültige Bestimmung erfordert jedoch Experimente. Dies gilt vor allem auch für die Anzahl der Knoten je Schicht. Diese Zahl muss so gewählt werden, dass die gewünschten Muster zufriedenstellend erlernt werden können, und damit der Fehler

der Ausgabe innerhalb der festgelegten Grenze der Anwendung liegt. Zu große Netzwerke beginnen oft, Muster „auswendig zu lernen“ (vgl. Abschnitt 2.3.3). Sie bilden Muster zu exakt ab und verlieren dabei ihre Fähigkeit zur Verallgemeinerung. Im Training sowie bei der Prädiktion deutet die Spezialisierung der Ausgabe auf einzelne Muster darauf hin. Zu kleine Netzwerke generalisieren so stark, dass ihre Ausgabe nicht mehr aussagekräftig ist. Um günstige Ausgangstopologien zu erlangen, empfiehlt die Literatur oft folgende Beziehung

$$h = \frac{P \varepsilon_K}{(x_m + y_n)} \quad (2-57)$$

als Faustregel zur Bestimmung der Neuronenanzahl der Zwischenschichten h [96]. Es zeigt sich hier die Abhängigkeit von der Trainingsdatenmenge P (vgl. Abschnitt 2.3.4), der Anzahl der Neuronen der Eingabe- x_m und der Ausgabeschicht y_n mit dem geduldeten Klassifizierungsfehler ε_K , der meist bei 5 % bis 10 % liegt. [100] bespricht weitere vergleichbare Ansätze, die ebenfalls als geeignete Ausgangspunkte angesehen werden, um eine zufriedenstellende Netzwerkleistung, d. h. Fähigkeit zur Verallgemeinerung, zu erzielen. Es sei noch erwähnt, dass es auch Algorithmen mit einer dynamischen Anzahl verborgener Schichten gibt. Sie verändern auch die Anzahl verborgener Neuronen während eines Netzwerktrainings, bis die minimale Anzahl gefunden ist, für die das Annahmekriterium eintritt. Ein Beispiel dazu beschreibt [107]. Der Einsatz dieser Algorithmen wird in dieser Arbeit jedoch nicht berücksichtigt.

Als Folgerung lässt sich feststellen, dass die allgemeinen Forderungen zum Netzwerkaufbau durchaus als nützliche Empfehlung und Startpunkt dienen. Die Ansatzpunkte zeigen sich jedoch als so weitreichend, dass sie nicht nur die Netztopologie, sondern auch die anderen Bereiche der Netzwerkkonfiguration tangieren, wie in den nachfolgenden Abschnitten ausgeführt wird. Grundsätzlich besteht die Schwierigkeit, dass an einem Punkt die Abschätzung des Netzwerks zwar verbessert wird, während sie sich an der anderen Seite wieder verschlechtern kann. Zu große Netze können durchaus eine verbesserte Performance aufweisen, weil ihre zusätzlichen Schichten und Neuronen dazu tendieren, global miteinander zu interagieren. Aber genau das führt an einigen Stellen dazu, dass der Fehler bei der Fähigkeit zu Verallgemeinern steigt. Zu „einfache“ Netzwerke weisen indessen meist entgegengesetzte Effekte auf [96].

2.3.3 Trainingsalgorithmen

Die „Lernfähigkeit“ bezeichnet aus mathematischer Sicht die Eigenschaft eines Algorithmus, ein Netz mit gegebener Topologie eine repräsentierbare Funktion erlernen zu lassen, d. h. Gewichte der Verbindungen und Schwellenwerte korrekt festzusetzen [95]. Die Lernfähigkeit zielt demgemäß darauf ab, die Repräsentierbarkeit einer gesuchten Funktion durch ein (im vorliegenden Fall) im Aufbau unveränderliches Netz zu bewirken.

Dabei unterscheidet man „überwachtes“, „bestärkendes“ und „unüberwachtes“ Lernen. Die nachfolgenden Erörterungen betreffen lediglich Algorithmen, die „überwachtes“ Lernen voraussetzen. Während des Lernens wird jedem Eingabemuster die erwünschte Ausgabe gegenübergestellt. Dies dient dem Auffinden der korrekten Ausgabe zu ähnlichen Eingabemustern in der Arbeitsphase (Prädiktionsphase).

Wird der Zeitpunkt der Gewichtsänderung betrachtet, lassen sich Lernverfahren in zwei Klassen unterteilen. In sogenannten Online-Verfahren erfolgt die Anpassung der Gewichte nach jedem Trainingsmuster, während Offline-Methoden diese Änderung für eine Epoche (alle Trainingsmuster) aufsummieren und dann die Anpassung in Summe vornehmen.

Die Lernregel bildet den Algorithmus ab, gemäß dem das KNN lernt, für eine vorgegebene Eingabe eine gewünschte Ausgabe zu produzieren. Das Lernen erfolgt im KNN dabei meist durch Modifikation der Stärke der Verbindungen, als Ergebnis der wiederholten Präsentation von Trainingsmustern. Der Vollständigkeit wegen seien hier weitere theoretisch mögliche Arten des Lernens aufgeführt. Neben den Gewichten von Verbindungen lassen sich auch die Stärken von Schwellenwerten oder die Art der Propagations-, Aktivierungs- oder Ausgabefunktion modifizieren, neue Verbindungen entwickeln oder existierende löschen. Aber auch die Entwicklung neuer oder die Entfernung alter Zellen bilden den Gegenstand von Forschungsarbeiten [95, 96, 107, 108]. Auch Mischformen kommen vor, wobei es beispielsweise zur Eliminierung einzelner Verbindungen oder Neuronen kommen kann, wenn deren Verbindungsgewichte $w_{ij} = 0$ gesetzt werden. Ein optimales Trainingsergebnis liegt bei minimalem Fehler zwischen erwarteter und tatsächlicher Ausgabe für alle Trainingsmuster. Aus der Vielzahl existenter Lernverfahren wird in der vorliegenden Arbeit das aus der „Backpropagation“ weiterentwickelte Verfahren „Resilient Propagation“ (RPROP) besprochen.

Die Bestimmung von Gewichten und Schwellenwerten bei überwachten Trainingsalgorithmen erfolgt üblicherweise ausgehend von einem zufällig festgelegten Startgewicht w_{ji} für jede Verbindung. Die Minimierung des Netzwerkfehlers geschieht dadurch, dass die Gewichte mit Hilfe des Trainingsalgorithmus so eingestellt werden, dass die Abweichung von Netzwerkantwort t_i und gewünschter Netzwerkausgabe y_i ein Minimum erreicht (Abbildung 2-7).

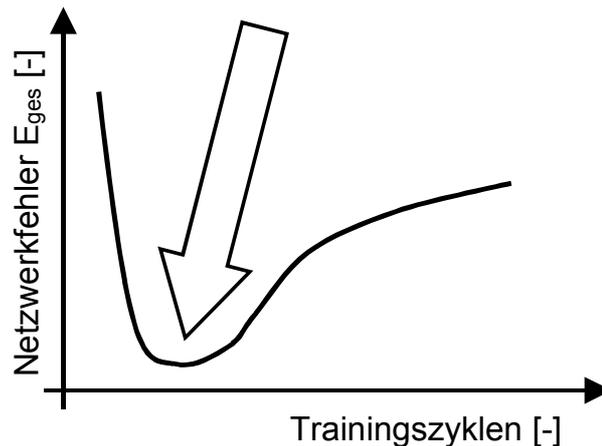


Abbildung 2-7: Netzwerkantwort aller präsentierten Muster für die jeweils durchgeführten Trainingszyklen; das Minimum des Fehlers zeigt der Pfeil an.

Dabei wird in den meisten Fällen der Fehler

$$E_{ges}(W) = \sum_{i=1}^m |t_i - y_i|^2, \quad (2-58)$$

als der quadratische Abstand zwischen der erwarteten t_i und der tatsächlichen y_i Ausgabe aller Ausgangsneuronen minimiert. D. h., der Fehler ergibt sich, indem über alle Trainingsmuster bei den vorhandenen Gewichten die quadratische Differenz zur gewünschten Ausgabe entsprechend aufsummiert wird. Minimiert wird er, indem eine Konfiguration einer Gewichtsmatrix W gesucht wird, bei der die Fehlersumme über alle Trainingsmuster minimal ist. Dies geschieht nach der Vorschrift der jeweiligen Lernregel bis zum „globalen“ Minimum. Dabei werden alle Gewichte jeweils um einen Bruchteil geändert, der durch die Lernrate η_L festgesetzt wird. Im einfachsten Fall erfolgt eine Anpassung um einen Bruchteil des negativen Gradienten der Fehlerfunktion

$$\Delta w_{ij} = \sum_p -\eta_L \frac{\partial E_p}{\partial w_{ij}}. \quad (2-59)$$

Diese Gradientenverfahren kommen in vielen Anwendungen zum Einsatz, da sie einfach implementierbar und zuverlässig sind. Die hier im Weiteren besprochenen

Lernregeln sind Spezialisierungen der allgemeinen Hebb'schen Lernregel, welche die Grundlage für die meisten komplizierteren Verfahren bildet. Sie geht in der Lernphase von dem Idiom aus [95]: „Wenn Zelle j eine Eingabe von Zelle i erhält und beide gleichzeitig stark aktiviert sind, dann erhöhe das Gewicht w_{ij} (die Stärke der Verbindung von i nach j).“ Dies führt zur allgemeinen mathematischen Form

$$\Delta w_{ij} = \eta_L o_i a_j = \eta_L h(o_i, w_{ij}) g(a_j, t_j), \quad (2-60)$$

wobei Δw_{ij} die Änderung des Gewichts der Verbindung, η_L die Lernrate und t_j (auch „Teaching Input“) die erwartete Aktivierung der Zelle darstellen. Die erste Modifikation dieser Grundform führt zur sogenannten Delta-Regel, bei der die Gewichtsänderung proportional zur Differenz $\delta_j = t_j - a_j$, der aktuellen Aktivierung zur erwarteten Aktivierung ist. Die Delta-Regel bildet einen Spezialfall der Backpropagations-Regel und gilt nur für eine einzige Schicht trainierbarer Gewichte. Die Backpropagation ist eine Verallgemeinerung für Netze mit mehr als einer Schicht trainierbarer Gewichte und außerdem für Neuronen mit einer nichtlinearen, monotonen, differenzierbaren Aktivierungsfunktion anwendbar. Die Regel zur Gewichtsänderung ergibt sich analog zu

$$\Delta_p w_{ij} = \eta_L o_{pi} \delta_{pj} \quad (2-61)$$

$$\text{mit } \delta_j = \begin{cases} f'_{akt}(net_{pj})(t_{pj} - o_{pj}) & \text{falls } j \text{ Ausgabeneuron ist,} \\ f'_{akt}(net_{pj}) \sum_k \delta_{pk} w_{jk} & \text{falls } j \text{ verdecktes Neuron ist.} \end{cases} \quad (2-62)$$

Neben verschiedenen anderen Modifikationen dieses Trainingsalgorithmus erweist sich in Feedforward-Netzwerken das in dieser Arbeit eingesetzte Verfahren „RPROP“ als ein schneller und robuster Lernalgorithmus. Die Gradientenabstiegsverfahren suchen generell ein notwendiges Minimum des Gradienten einer beliebigen Funktion, indem sie ihm von einem beliebig gewählten Startpunkt in negativer Richtung folgen. Wie im nächsten Abschnitt beschrieben, verursacht dies in vielen Fällen Probleme. Deswegen gibt es für unterschiedliche Anwendungen eine Fülle von Modifikationen in der Literatur, wobei die Verbesserungen insbesondere auf die Beschleunigung der Konvergenz abzielen. Da eine ausführliche Diskussion aller dieser Methoden hier als nicht angebracht erscheint, wird nachfolgend die in dieser Arbeit verwendete Methode RPROP vorgestellt und die grundsätzlichen Probleme der Gradientenabstiegsverfahren erläutert [95, 96].

RPROP kombiniert die Vorzüge einiger oben genannter Modifikationen. Dabei berücksichtigt dieser Algorithmus die beiden letzten Gradienten, aber nur hinsichtlich ihrer Vorzeichen, nicht ihres Betrages [109]. Jedes Gewicht besitzt zusätzlich einen

eigenen Parameter für die Änderung der Schrittweite. Die Gewichte werden nach dem Vorzeichen des Gradienten der Fehlerfunktion geändert. Sie verwendet die Steigungen $S(t)$ des aktuellen und des vorherigen Zeitpunktes. Der Vergrößerungs- bzw. Verkleinerungsfaktor wirkt sich dabei nicht auf die Lernrate, sondern auf die letzte Gewichtsänderung aus. Somit erhält man für die Gewichte $w_{ij}(t+1)$ und die Gewichtsänderungen $\Delta w_{ij}(t)$ folgende Vorschrift:

$$w_{ij}(t+1) = w_{ij}(t) + \Delta w_{ij}(t) \quad (2-63)$$

$$\Delta w_{ij}(t) = \begin{cases} -\Delta_{ij}(t) & \text{falls } S(t-1) S(t) > 0 \wedge S(t) > 0 \\ \Delta_{ij}(t) & \text{falls } S(t-1) S(t) > 0 \wedge S(t) < 0 \\ -\Delta w_{ij}(t-1) & \text{falls } S(t-1) S(t) < 0 \\ -\text{sgn}(S(t))\Delta_{ij}(t) & \text{sonst.} \end{cases} \quad (2-64)$$

Nach [95] führt die Einführung eines „Weight Decay“ Terms zu einer besseren Generalisierung. Dieser „bestraft“ bei sehr hohen Gewichten die Gewichtsänderung, um zu steile Fehlerspitzen zu vermeiden. Das bedeutet, dass im Vergleich zu anderen Algorithmen eine meist ebenbürtige oder gar überlegene Generalisierung erreicht wird. Zusätzlich wird die Anwendung von Schranken zur Begrenzung der zulässigen Schrittweite auf ein Minimum bzw. Maximum empfohlen. Auch bei RPROP treten noch Probleme während des Trainings auf, wobei auch das sogenannte „Overfitting“ oder „Übertrainieren“ der Netze entsteht, wie nachfolgend erläutert wird (vgl. auch Abschnitt 2.3.4).

Die allgemeinen Probleme eines jeden Gradientenverfahrens stellen sich auch beim Lernverfahren RPROP ein und müssen beim Training Beachtung finden. Im Folgenden sollen die wichtigsten Problembereiche kurz diskutiert werden [95, 96, 110].

Die *Konvergenzgeschwindigkeit* ist bei Gradientenverfahren relativ gering, da sich der Gradient nur annähern lässt. Deshalb darf der Schritt in Richtung des negativen Gradienten eine gewisse Größe nicht überschreiten, damit der Algorithmus sich nicht zu weit vom Graphen der Funktion entfernt [111]. Außerdem wurde schon angesprochen, dass die Methode des steilsten Abstiegs im Allgemeinen nicht direkt zu einem Minimum führt.

„*Symmetry breaking*“ bezeichnet die Notwendigkeit der anfänglichen Initialisierung aller Gewichte mit zufälligen, verschiedenen Werten nahe null. Haben zu Beginn des Trainings alle Gewichte denselben Wert, so erreicht das System einen Gleichgewichtspunkt, an dem überhaupt keine Gewichtsänderungen mehr stattfinden können, wie von [95] anhand einer Beispielrechnung gezeigt.

Die Verwendung ausschließlich lokaler Informationen macht eine Beurteilung der Art eines Minimums unmöglich, so dass sich „globale“ und „lokale“ *Minima* nicht unterscheiden lassen. Andererseits reicht es für viele Anwendungen aus, durch genügend kleine Schrittweite des Gradientenabstiegs ein gutes lokales Minimum zu finden. Kleine Störungen, z. B. in Form von zufälliger Auswahl von Trainingsmustern oder durch zufällige Veränderung der Gewichte, lassen sich dazu einsetzen, gezielt ein lokales Minimum zu verlassen. Diese Maßnahme soll auch die Generalisierungsfähigkeit eines Netzes verbessern.

Die Lernzeit verlängert sich, wenn sich das Verfahren in *flachen Plateaus* bewegt, in denen der Gradient gegen null geht. Da die Gewichtsänderung zunächst bei vielen Verfahren von der Größe dieses Gradienten abhängt, geht auch diese gegen null. Die Lösung dieses Problems erfordert, dass der Gradient auf Plateaus kein Minimum anzeigt. Die erwünschte Vergrößerung der Schrittweite lässt sich durch Einführung eines „Momentum-Terms“ erreichen, der die bereits vollzogene Gewichtsänderung im nachfolgenden Schritt berücksichtigt und so eine Beschleunigung (Erhöhung der Gewichtsänderung) in weiten Plateaus bewirkt [112].

Die *Oszillation in steilen Schluchten* folgt aus großen Werten des Gradienten an steil abfallenden oder ansteigenden Kurven. Die daraus berechnete große Gewichtsänderung vermag, dass ein Sprung an die gegenüberliegende Seite der Schlucht erfolgt. Da sich dort nur das Vorzeichen des Gradienten ändert, springt das Lernverfahren zurück und beginnt zu oszillieren. Auch hier kann ein „Momentum-Term“ durch Dämpfen der Oszillationen helfen. Andererseits vergrößert dieser Term die Wahrscheinlichkeit des *Verlassens gesuchter Minima*, wenn diese in einem engen Tal mit steilen Wänden liegen und damit zu großen Gradienten führen.

Die Länge eines Schrittes in die Richtung des negativen Gradienten hängt nicht nur von dessen Wert ab, sondern meist auch von einem Proportionalitätsfaktor, der die *Schrittweite* bestimmt. Eine selbstständige Anpassung der Schrittweite durch ein geeignetes Verfahren bietet den Vorteil, dass sich für das Problem, einen Kompromiss zwischen den Extrema „große“ oder „kleine“ Schrittweiten zu finden, keine allgemein gültigen Lösungen aufzeigen lassen. Während kleine Schrittweiten meist zu „guten“ Minima, wenigen Oszillationen, aber einem längeren Training führen, liegt der Vorteil größerer Schrittweiten in der schnelleren Konvergenz, wenn diese nicht durch zu hohe Schrittweiten und das Verlassen oder Überspringen guter Minima verfehlt wird.

Die Berechnung und Angabe von Konvergenzkriterien für die Schrittweite erfordert nach [113] meist einen hohen Rechenaufwand. Vor Trainingsbeginn muss außerdem der Zeitpunkt der *Gewichtsänderung* festgelegt werden. Da jeweils nur die Infor-

mation eines einzigen Datensatzes vorliegt, wird die Abschätzung des Gradienten in Online-Verfahren ungenau, so dass Trainingsmuster in zufälliger Reihenfolge präsentiert werden sollten, um eine zufällige Verteilung der Schätzungen des Gradienten um den wahren Wert zu erreichen [96, 114]. Der Vorteil dieser Variante liegt im geringeren Speicherbedarf, da sie keine Hilfsvariable für die Aufsummierung benötigt. Andererseits wird die Abschätzung des Gradienten im Offline-Modus genauer. Die Auswahl eines geeigneten Verfahrens hängt letztlich vom konkreten Problem ab, wie auch [113, 97] beschreiben.

2.3.4 Auswahl geeigneter Eingangsdaten

KNN verarbeiten nur Daten, die in einem geeigneten Eingangsformat vorliegen. Die Anzahl der Eingangsneuronen begrenzt das Eingangsformat eines KNN. Das bedeutet, dass die Information eines zu klassifizierenden Musters, beispielsweise ein Frequenzspektrum bestehend aus etwa 1000 Messpunkten, auf diese Anzahl reduziert werden muss, um eine Verarbeitung durch das KNN zu ermöglichen. Somit fällt der Datenreduktion von Messinformationen eine enorme Bedeutung zu. Hiermit kann bereits ein entscheidender Schritt zur anschließenden Klassifikation vollzogen werden, der jedoch nicht zwingend sein muss [115, 116].

Dem Vorwissen um charakteristische Merkmale eines Musters, d. h. auch der darauf aufbauenden Merkmalsausprägung, kommt ebenfalls eine hohe Bedeutung zu. Bevor in der Mustererkennung die Daten dem KNN präsentiert werden, kann die Datenvorverarbeitung bereits die Generalisierungsfähigkeit des gesamten Netzwerkes limitieren. Das kann dazu führen, dass die spätere Erweiterung eines vorhandenen Netzwerkes, z. B. durch weitere Muster neuer Klassen, aufgrund der getroffenen Einschränkungen nicht mehr möglich ist, da betreffende Bereiche oder Größenordnungen bereits ausgeschlossen sind oder Datensätze durch Vorverarbeitungsalgorithmen, wie z. B. FFT oder Signalfilter, an „Schärfe“ verloren haben [47, 48, 100, 117]. Es kann jedoch auch dazu führen, dass bestimmte „wichtige“ Eigenschaften eines Systems oder Datensatzes hervorgehoben und „unwichtige“ Werte aussortiert werden. Dadurch kann sich ein KNN stark „spezialisieren“. Das bedeutet, es generalisiert nicht mehr, sondern es „lernt auswendig“ und einige Muster werden sehr genau zugeordnet, dafür werden andere nicht mehr erkannt. Oftmals hängt eine derartige Auswahl vom gegebenen Klassifizierungsproblem ab.

Anforderungen an das Datenmaterial

Ein KNN approximiert eine Klasse oder eine Funktion nur dann, wenn Daten zur Verfügung stehen, die diese repräsentieren. Dabei erweist sich nicht nur der Umfang der Datenmenge als wichtig. Essentiell für die Lösung der Aufgabe ist auch, dass das gesuchte Muster eindeutig durch die ausgewählten Daten wiedergegeben wird. Allerdings benötigt ein KNN-Training von Klassifikatoren zusätzlich möglichst viele Klassifikationsgrenzfälle in die Trainingsdatenmenge, d. h. Eingangsdaten, die nahe an der Grenze zweier Klassen liegen [116]. Für Funktionsapproximatoren lassen sich keine derart prägnanten Anweisungen geben. Allgemein muss darauf geachtet werden, keine redundanten Trainingsdaten zu präsentieren bzw. diese aus dem vollständigen Trainingsdatensatz zu entfernen. Sie können ansonsten von dem Netz als besonders wichtig beurteilt werden und das Ergebnis verfälschen. Insbesondere bei sehr großen Datenmengen tritt dieses Problem auf und führt neben der falschen Gewichtung zu erhöhtem Zeitaufwand für das Training.

Für die Approximation einer Funktion müssen die Eingangsvektoren gleichmäßig im Eingaberaum R^n (n bezeichnet die Länge der Eingangsvektoren, also die Anzahl der Eingangsvariablen), ungeachtet der Definition des Abstandes, verteilt sein [118]. Bei Verletzung dieser Bedingung gibt es für große Gebiete des Eingaberaums keine Möglichkeit für das KNN, eine erwünschte Ausgabe zu erlernen. Aufgrund der so verminderten Extrapolationseigenschaften von KNN [111] führt dies zum Herabsetzen der Prädiktionsfähigkeiten in der Arbeitsphase.

Overfitting

Eine gute Generalisierungsfähigkeit verlangt auf jeden Fall die Vermeidung des Problems des „Overfittings“. Dieses tritt auf, wenn das Netz die Trainingsdaten „auswendig“ lernt oder sich auf nebensächliche Einzelheiten konzentriert. Dieser Effekt kann die Konsequenz einer zu hohen Anzahl von Neuronen sein, so dass das Netz beginnt, die Muster zu exakt abzubilden [105]. Auch ein zu langer Lernprozess [119] führt häufig zu einer Vergrößerung der Gewichte und somit zum Verlust der Generalisierungsfähigkeit. Damit verlässt die sigmoide Aktivierungsfunktion ihren linearen Bereich und die Anpassung an nichtlineare Funktionen wird möglich. Die Konsequenz einer übertriebenen Anpassung zeigt Abbildung 2-8. Auf der linken Seite ist die Anpassung für die durch Punkte repräsentierten Trainingsdaten sehr gut, aber dem Netz unbekannte Daten, dargestellt durch Dreiecke, werden mit hohem Fehler abgebildet. Erwünscht in KNN ist der Fall rechts, in dem der Trainingsfehler im Vergleich höher, aber die Generalisierung besser ist. Damit wird deutlich, dass die

alleinige Beurteilung der Güte des Trainings nicht ausreicht, um auf eine gute Leistung eines KNN in der Prädiktion zu schließen.

In [119] werden drei prinzipielle Möglichkeiten zur Verbesserung der Prädiktion genannt:

- Geringe Anzahl verdeckter Neuronen,
- Verhinderung der Ausbildung großer Gewichte,
- Begrenzung der Anzahl der Trainingsepochen.

Durch die Limitierung der Anzahl verdeckter Neuronen werden die Fähigkeiten eines KNN begrenzt, die von der Anzahl seiner Gewichte als Funktion der Neuronenzahl abhängen. Diese Art der Anpassung ist unbefriedigend, da alle möglichen Topologien trainiert werden müssen und danach die Generalisierungsfähigkeit anhand unbekannter Daten zu beurteilen ist, wodurch diese Methode rechnerisch und zeitlich sehr aufwändig wird.

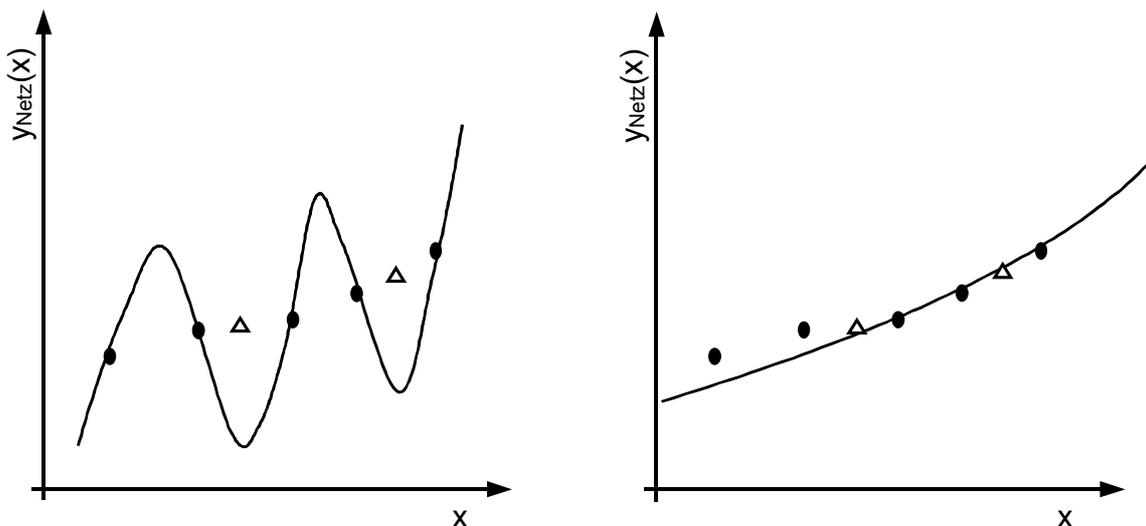


Abbildung 2-8: Zwei mögliche Approximationen des gleichen Datensets mit Trainingsdaten (•) und Daten aus der Arbeitsphase (Δ). Der linke Graph zeigt "Overfitting", rechts wird eine gute Generalisierungsfähigkeit dargestellt.

Um die – gemäß [119] beste – dritte Methode zu realisieren, müssen aus den Trainingsdaten Prüfmuster entnommen werden. Das Training wird wiederholt unterbrochen, um die Generalisierung mit den dem Netz unbekanntem Prüfmustern zu bewerten. Als „unbekannt“ werden hier Muster bezeichnet, die zwar Mitglied der Klassen sind, aber aufgrund ihrer Beschaffenheit von den bereits vorgelegten abweichen. Dieser Prozess wird so lange wiederholt, bis der Fehler der Netzwerk-

ausgabe wieder ansteigt oder einen vorgegebenen Wert unterschreitet. Für die Anwendung dieser als „Kreuzvalidierung“ bezeichneten Alternativen erscheint die Netzgröße nicht mehr kritisch, so lange die Anzahl der Neuronen zur Repräsentation ausreicht, da die (gewünschte) Generalisierungsfähigkeit das Abbruchkriterium darstellt.

Datenreduktion durch Vektorquantisierung

Wenn das Auffinden einer statistisch relevanten Anzahl von Trainingsdaten kein Problem darstellt, stellt sich die Frage, ob Daten redundant sind oder eine Häufung einander ähnlicher Eingabemuster gerade das gesuchte Problem beschreiben soll. Auch wenn letztere Annahme zutrifft, ist es möglich, den Aufwand durch geeignete Maßnahmen zu verkleinern. Der bei diesen Verfahren zwangsläufig auftretende Fehler muss in seiner Größe und Bedeutung abgeschätzt und beurteilt werden.

Die Datenreduktion durch Vektorquantisierung [96] findet vornehmlich im Rahmen der Bildverarbeitung Anwendung [120, 121]. Dabei werden analoge oder stetige Variablen in diskrete umgewandelt. Hier wird der Unterschied zwischen einem Referenzvektor und einem beliebigen Eingabevektor quantifiziert, z. B. durch den euklidischen Abstand oder eine Kostenfunktion. Liegt der Unterschied unterhalb einer vorgegebenen Schranke, wird der Eingabevektor durch den Referenzvektor repräsentiert. Durch Beschränkung der Klassenzahl kann dieses Verfahren auch auf die Ausgabe angewendet werden.

Folgerungen für den Einsatz des KNN

Zusammenfassend stellt ein KNN eine Reihe von Fähigkeiten zur Lösung von Approximations- und Klassifikationsproblemen zur Verfügung, die es gegenüber herkömmlichen Klassifikatoren und Assoziativspeichern abgrenzt [122]. Hierin begründet sich der Einsatz von KNN für industrielle Mustererkennungsaufgaben. Einen kleinen Überblick dazu gibt Tabelle 2-1.

Tabelle 2-1: Hauptunterschiede herkömmlicher Klassifikatoren und KNN [100]

KNN	herkömmliche Klassifikatoren
• lernen von den Daten	• folgen Regeln
• Regeln sind nicht offensichtlich	• Lösung stark spezifisch
• generalisieren	• generalisieren nicht
• verarbeiten Rauschen	• nicht fehlertolerant

Für die Generalisierungsfähigkeit der KNN ergeben sich daraus die Folgerungen zur Behandlung der Daten und der Komplexität des KNN-Modells, um die zu erzielende Lösung zu beeinflussen. Auch wenn in der Literatur gegenläufige Meinungen existieren, ist die zu verwendende Konfiguration üblicherweise ein Mittelweg. So bietet [100] dazu auch eine umfassende Aufstellung zur Komplexität von KNN und der entsprechenden Auswahl der Komponenten in allgemeiner Form an. Tabelle 2-2 stellt dabei die jeweilige Konfigurationsauswahl und ihre zu erwartenden Folgen im Netzwerk gegenüber.

Tabelle 2-2: Zusammenfassender Überblick über die Auswahl der Komponenten bei der Konfiguration eines KNN und deren Auswirkungen auf dessen Komplexität bzw. Generalisierungsfähigkeit [100]

Auswirkung auf die KNN Eigenschaften (generalisierend, robust)	⇐	Komponenten der KNN Konfiguration	⇒	Auswirkung auf die KNN Eigenschaften (präzise, aber instabil)
reduzierte Dimensionen	⇐	Datenreduzierung, Datenvorverarbeitung	⇒	viele Dimensionen
wenig, unpräzise, verrauscht, stark verteilt	⇐	Datenzusammenstellung	⇒	viel, präzise, nicht verrauscht, geringe Verteilung
Topologie				
gering	⇐	(Anzahl verborgener Schichten und Neuronen)	⇒	hoch
KNN-Training				
Parametrierung nach frühen Trainingszyklen bewirkt Verrauschen und steigende Generalisierung	⇐	Unabhängigkeit der Validierungsdaten zum Trainingsfehler	⇒	vorhandene Abhängigkeit führt zum Overfitting
gute Performance auch bei unbekanntem Daten; kann Grenzfälle richtig zuordnen	⇐	Testkriterium	⇒	erreicht gewünschte Genauigkeit bei bekannten Daten

Die Auswahl der Komponenten und schließlich der Applikationserfolg ist bei der Implementierung zu beurteilen [96, 117]. Somit gilt es, jeweils die KNN-Para-

metrierung den Erfordernissen anzupassen und sie zu optimieren. Demzufolge werden in den Abschnitten 4.3 und 4.4 die Auswirkungen geringfügiger Unterschiede der Netzwerktopologie sowie der Datenvorverarbeitung am vorliegenden Fall besprochen.

3 Material und Methoden

3.1 Kombination der eingesetzten Methoden zur Neuronumerik

Den zentralen Bestandteil der Arbeit bildet die Verschmelzung von numerischen mit experimentellen Methoden. Dabei steht zusätzlich zu der Optimierung experimenteller Aufbauten mittels numerischer Methoden (vgl. Kap. 4.1.4) vor allem die Unterstützung des Datenpools zum Training der KNN im Vordergrund (vgl. Kap. 4.4). Es handelt sich somit um eine völlig neuartige hybride Methode, welche es unter der Bezeichnung Neuronumerik vermag, die Potenziale der numerischen Simulation mit denjenigen der KNN zu einem äußerst leistungsfähigen Forschungswerkzeug zu verbinden, wie es Abbildung 3-1 verdeutlicht.

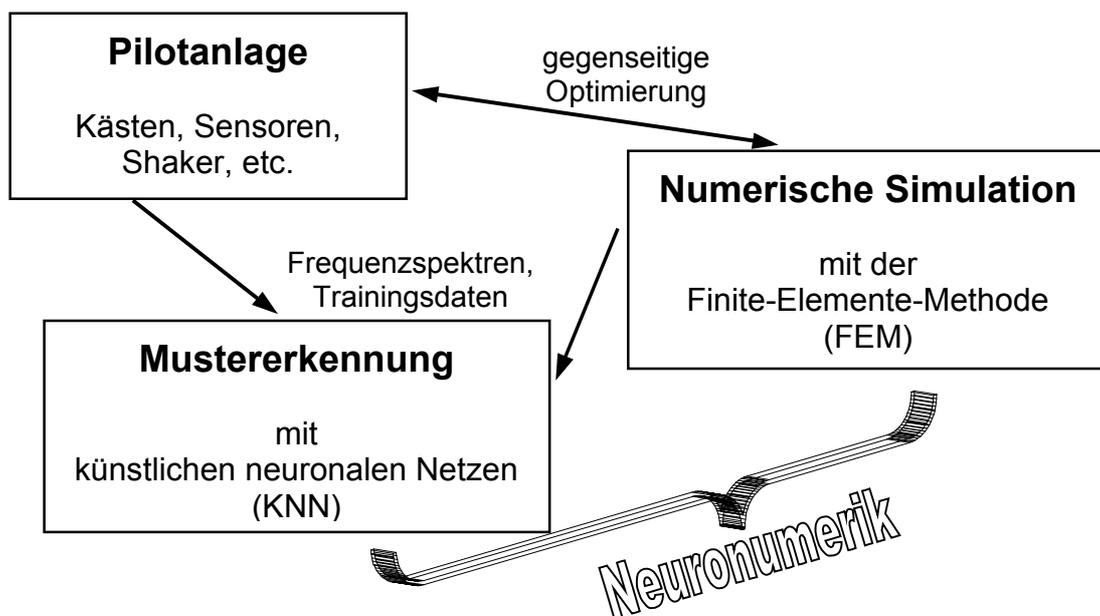


Abbildung 3-1: Begriffsbestimmung zum Aufbau des entwickelten neuronumerischen Werkzeuges

Datensätze aus der Simulation vervollständigen in der neuronumerischen Anwendung den experimentellen Datenpool. Dabei findet zunächst eine Substitution aller „intakten“ und in einem weiteren Schritt aller „defekten“ Fälle mit numerischen Datensätzen statt. Die Untersuchungen im Rahmen der Arbeit analysieren dabei, inwieweit eine partielle oder sogar eine vollständige Substitution der experimentellen Datensätze durch die simulierten Datensätze zu erreichen ist. Konkret bedeutet dies, dass abschließend mit einem rein numerischen Datenpool die KNN-Parametrierung

durchgeführt wird und das KNN zur Prädiktion ausschließlich reale, experimentell gewonnene Datensätze erhält.

Das Augenmerk liegt dabei auf den in der Simulation vorgenommenen Vereinfachungen. Dies erfordert eine besondere Betrachtung von geringfügigen Abweichungen, wie sie bei kleinen Schäden im Vergleich zu dem als „intakt“ gesetzten Getränkekasten auftreten. Liegen nämlich die Abweichungen der numerischen Datensätze in derselben Größenordnung, so kann dies bei der Klassifikation Fehlapproximationen zur Folge haben (vgl. Abschnitt 1.1.2). Das KNN vermag jedoch, je nach festgelegter Spezifität und angewandtem Vorwissen bei der Datenvorverarbeitung, sinnvolle Klassen zur Zuweisung finden. Dieser Punkt wird in Abschnitt 4.4 am Beispiel des Getränkekastens diskutiert.

Das anhand von Abbildung 3-1 illustrierte neuronumerische Werkzeug führt im Rahmen der Arbeit zu dem nach dem Schema von Abbildung 3-2 gegliederten globalen System der automatischen Schadenserkennung von Getränkekästen. Dabei dient eine im Labormaßstab aufgebaute Pilotanlage zur Mustergewinnung und Mustererkennung. Diese Anlage erlaubt, Frequenzspektren auf mechanischem Wege aufzuzeichnen. Dabei handelt es sich, wie nachfolgend besprochen, um die „Frequenz-Antwort“ des Festkörpers nach mechanischer Anregung.

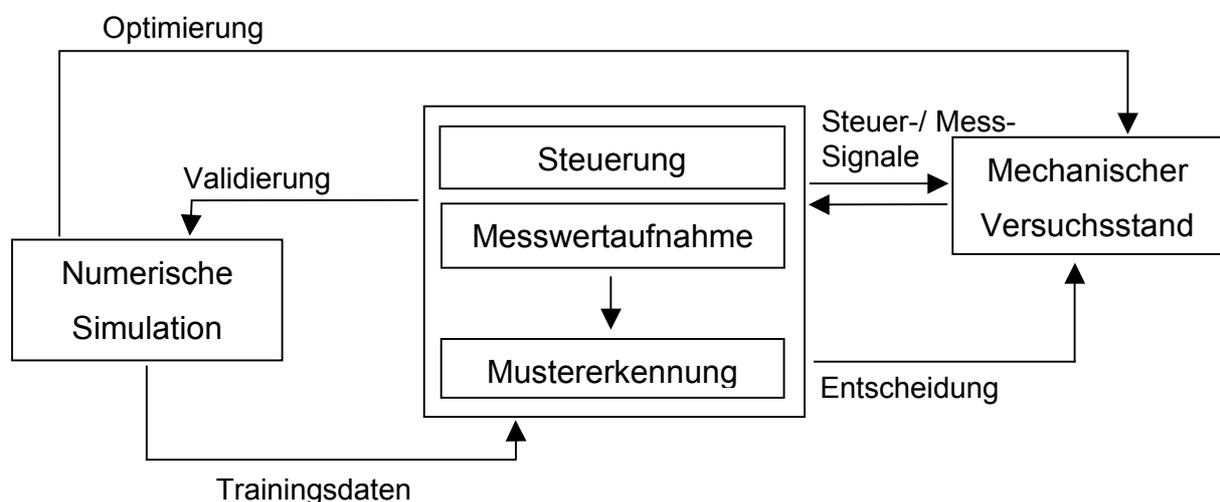


Abbildung 3-2: Grundstruktur des entwickelten Systems zur automatischen Schadenserkennung mittels Neuronumerik

Die Steuerung der Anlage erfolgt mit Hilfe eines handelsüblichen PC, der überdies zur Digitalisierung der Messwerte, sowie zur Mustererkennung und Klassifizierung der Spektren mit Hilfe eines KNN Einsatz findet. Die numerische Simulation des mechanischen Prozesses geschieht darüber hinaus auf leistungsstärkeren Workstations am Leibniz Rechenzentrum München (LRZ). In diesem Kontext sei auf

die nachfolgenden Abschnitte verwiesen, welche die Bestandteile der eingesetzten Methoden und deren Konfiguration für die entwickelte Neuronumerik der vorliegenden Arbeit beschreiben.

3.2 Getränkekästen

Den zentralen Bestandteil aller Untersuchungen bildet der Getränkekasten, auf den alle Applikationen zugeschnitten sind. Zum Einsatz kommt dabei ein handelsüblicher Mehrweg-Getränkekasten (Stapelkasten) aus Polyethylen. Tabelle 3-1 gibt Auskunft über die materialspezifischen Parameter.

Tabelle 3-1: Materialspezifische Parameter des eingesetzten Getränkekastens

Modell: Amstel 24 x 0,33 l des Herstellers Schoeller Plast Werke GmbH [123]	
Maße	398 x 298 x 237 mm (Länge x Breite x Höhe)
Gewicht	1,9 kg
Kunststoff	HD-PE (high density Polyethylen), Bezeichnung: VESTOLEN A 6016
Dichte	962 kgm ⁻³ bei 23 °C, 50 % relative Luftfeuchtigkeit
Herstellungsmethode	Spritzguss (nach ISO 1872)
Fertigungstoleranz	< 1% (bei kleinen Abmessungen 5 – 15 µm)
<u>Mechanische Kennwerte</u>	bei 23 °C, 50 % relative Luftfeuchtigkeit
E-Modul	1600 MPa
Streckspannung	30 MPa
Streckdehnung	10 %
Nominelle Bruchdehnung	> 50 %
Zug-Kriechmodul	(1 h): 900 MPa (1000 h): 450 MPa
Querkontraktion (Poissonzahl)	0,42

Dieses Kastenmodell dient stellvertretend für sämtliche auf dem Markt befindlichen Modelle als Testobjekt (vgl. Abbildung 3-3), sowohl für die Modulkästen der Brauereien als auch für die Einheitskästen der Mineralbrunnen oder Fruchtsaft Betriebe. Lediglich die Verfügbarkeit eines zugehörigen CAD-Geometrie-Files für die angestrebten numerischen Berechnungen (vgl. Abschnitt 3.6) bedingte die Auswahl.

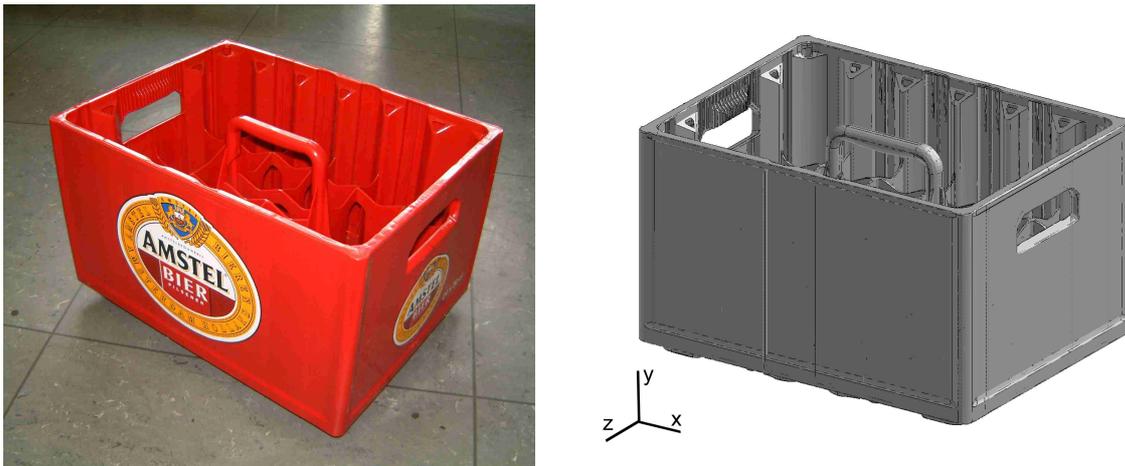


Abbildung 3-3: Eingesetztes Getränkekastenmodell mit zugehöriger CAD-Geometrie [123]

In der vorliegenden Arbeit wird unter den Begriffen „Schaden“ oder „Schadensfall“ ein defekter, nicht mehr zur Weiterverwendung im Sinne eines Mehrwegsystems einsetzbarer Getränkekasten verstanden. Demzufolge stellen sowohl Risse als auch Deformationen und fehlende Segmente Schäden dar. Im weiteren Sinne zählen dazu außerdem abweichende Kastingeometrien sowie Kästen aus anderem oder gealtertem Material.

Die Schäden der zum Einsatz kommenden Kastenproben wurden repräsentativ ausgewählt. Als repräsentativ wird dabei ein grundlegender Querschnitt möglicher Schäden erachtet, der sich wie nachfolgend beschrieben zusammensetzt. Der Schadenspool basiert auf Kästen mit mechanisch verursachten, künstlichen Schäden. Er stützt sich zum einen auf empirisch evaluierte Beobachtungen von häufig auftretenden Schäden, beispielsweise des Griffes. Zum anderen begründet sich die Zusammenstellung des Schadenspools auf den bereits in Abschnitt 2.3.4 besprochenen Kriterien zur Auswahl geeigneter Trainingsdaten für KNN. So sind zur Erzielung einer guten Prädiktion durch Netzwerke auch besonders Randfälle der gewählten Klassen wichtig. Die Auswahl hängt demzufolge nicht unmittelbar mit der Häufigkeit ihres Auftretens in der Praxis zusammen. Dementsprechend setzt sich der Schadenspool, wie bereits erwähnt, hauptsächlich aus verschiedenen größeren und kleineren Rissen und Deformationen sowie einigen abgetrennten Teilen des Tragkörpers an Wänden, Griffen und Gefachen zusammen. Auch einige Mischformen werden betrachtet. Die wichtigsten Positionen der berücksichtigten Schäden fasst Tabelle 3-2 zusammen.

Tabelle 3-2: Auflistung berücksichtigter, eingesetzter Modellschäden (genaue Positionierung und Beschreibung der Schäden vgl. Anhang 7.2)

Ort des Schadens	Art
	<ul style="list-style-type: none"> - einzeln und in Kombination eingesetzt - mehrfach über das Modell verteilt
Griffe – außen	Durchtrennung, komplett abgetrennt
Tragegriff – Mitte	Durchtrennung, komplett abgetrennt
Wand – längs	Risse, kurze (ca. 3 cm) und lange (ca. 10 cm)
Wand – quer	Risse, kurze (ca. 3 cm) und lange (ca. 10 cm)
Boden	Durchtrennung einzelner Rippen
Ecken	Abtrennung
Gefache	Durchtrennung

Abbildung 3-4 illustriert einige Beispiele als Auswahl von typischen Modellschäden. Über die genaue Position der studierten Schadensfälle gibt Anhang 7.2 anhand von Tabelle 7-1 sowie Tabelle 7-4 Auskunft.

Zur abschließenden Beurteilung des entwickelten Systems dienen zwei, aus der Vielzahl am Markt befindlichen Kastenformen zufällig ausgewählte, hier nicht weiter beschriebene Modelle ähnlicher Bauart. Sie sind somit Teil des Abschlusstestdatensatzes und spiegeln die Abgrenzung des Systems zu Fremdmodellen wider. Im Hinblick auf die Sensitivität der Methode, also der Detektierbarkeit von Schäden, erweisen sie sich des Weiteren als Basis für einen Vergleich.

Der experimentell betrachtete Pool an Schadensfällen besteht demnach aus baugleichen Getränkekästen und zwei Fremdmodellen. Außerdem werden weitere Schadensfälle numerisch simuliert (vgl. Tabelle 7-3), wobei sich diese Untersuchungen auch mit geringfügigen Veränderungen der Materialparameter (E-Modul, Dichte, Poissonzahl) befassen. Dies erlaubt es, die Einflüsse geringfügiger Materialschwankungen zu präzisieren. Zur Vergrößerung des Datenpools wird zudem die Symmetrie des Kastens ausgenutzt, indem Datensätze aus gegenüberliegenden Sensorpositionen (vgl. Abbildung 3-10) jeweils als unabhängige Datensätze dem Datenpool zugeführt werden. Dies erscheint durchaus als zulässig, da hier ausschließlich lineare Vorgänge betrachtet werden.



Abbildung 3-4: Auswahl typischer Modellschäden gemäß Tabelle 7-4

Bei allen erstellten Fällen wird in Anlehnung an die in Kapitel 2 vorgestellte Theorie davon ausgegangen, dass jede geometrische oder materialspezifische Veränderung Auswirkungen auf die Signalausbreitung hat, und diese in Abhängigkeit zu Größe und Ort des Schadens steht. Ebenso wird im Folgenden das mechanische Verhalten des Kunststoffes als elastisch angenommen. Dies ermöglicht die Betrachtung des Materialverhaltens nach linear phänomenologischer Theorie [124], wie sie auch in

den Grundlagen beschrieben wurde. Diesbezüglich darf die Beanspruchung der Getränkekästen den Grenzwert zum Übergang in irreversible Deformationen, also zu plastischem Verhalten, nicht überschreiten [125].

Die Auswirkung der Schäden auf die mechanische Signalübertragung wird in Abschnitt 4.1 und 4.2 betrachtet. Ebenso erfolgt eine Sensitivitätsanalyse und die Beurteilung der für die weitere Arbeit entscheidenden Positionen. Besondere Beachtung findet dabei der Schaden am Griff, da er einen Schwachpunkt optischer Systeme darstellt und dessen Unversehrtheit von besonderer Bedeutung im Hinblick auf die Gebrauchssicherheit ist.

3.3 Versuchsstand

Als Pilotanlage dient eine im Labormaßstab aufgebaute Schwingprüfanlage (vgl. Abbildung 3-5), die mit mechanisch aufgezwingener Erregung arbeitet. Dabei wird direkt und zentral dem Probenkörper (Prüfling, Getränkekasten) eine „gleitende Sinusschwingung“ aufgezwingen, die mit einem elektrodynamischen Schwingerreger erzeugt wird (vgl. Abschnitt 3.3.2).

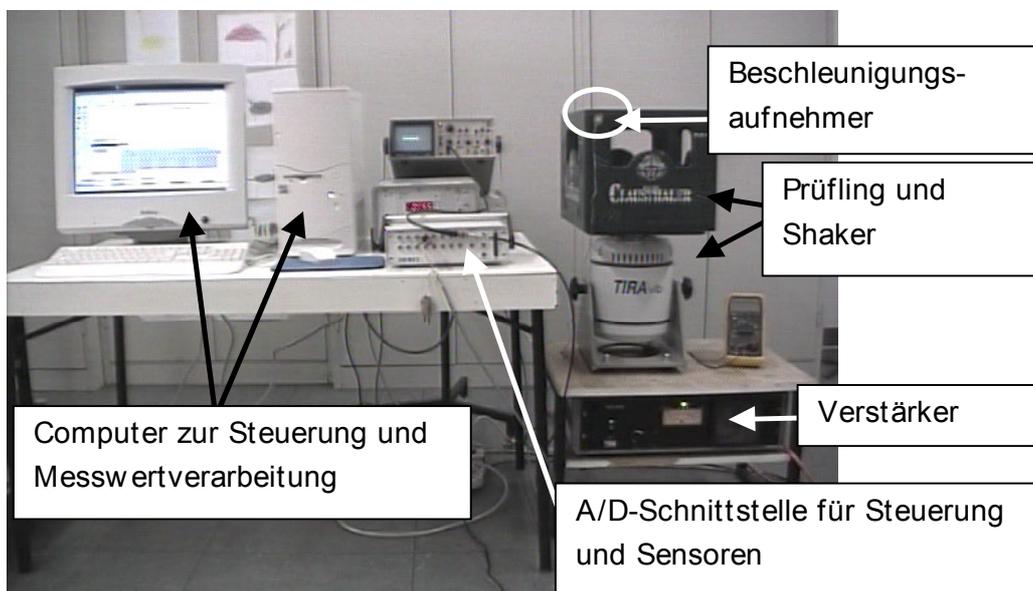


Abbildung 3-5: Pilotanlage im Labor

3.3.1 Aufbau

Abbildung 3-6 zeigt den schematischen Aufbau des Versuchsstandes (Pilotanlage). Dabei übernimmt ein handelsüblicher PC (Pentium III, 450 MHz, 128 MB) die Steuerung der Schwingprüfanlage. Eine DAP-Messkarte im PC (Data Acquisition Prozessor) empfängt die analogen Signale über eine Anschlussbox von den Sensorverstärkern und digitalisiert sie (Abtastrate 20 kHz). Der Verstärker des elektrodynamischen Schwingerregers (Shaker) leitet indessen Steuersignale zur mechanischen Anregung weiter. Das zusätzlich implementierte Multimeter und ein Oszilloskop dienen der unabhängigen Überprüfung der verschiedenen Signale. Tabelle 3-3 listet die technischen Daten auf.

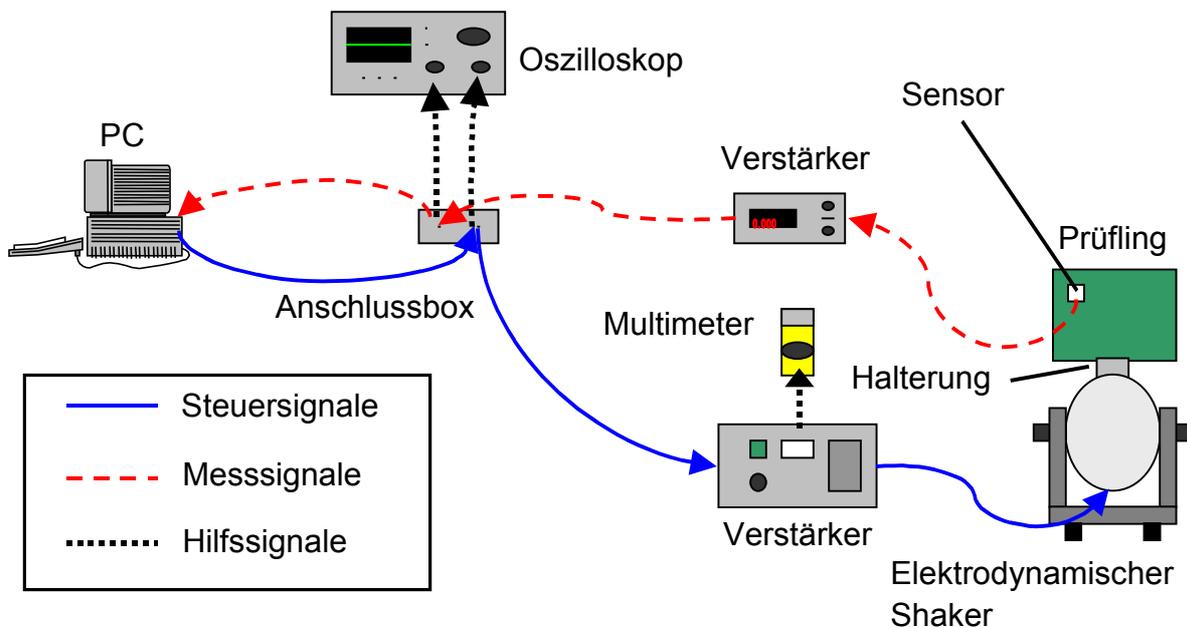


Abbildung 3-6: Schematische Darstellung des Versuchsstandes

Schwingprüfanlage und Halterung für den Prüfling

Eine speziell konstruierte Halterung aus Aluminium fixiert den Prüfling zentral am Kastenboden (vgl. Abbildung 3-7). Diese 110 x 110 mm große Aluminiumplatte wird durch Schrauben (M6) direkt an Gewindebohrungen am Schwingbolzen und der Kasten mittels u-förmiger Haken an der Platte angeschraubt. Dies gewährleistet die Übertragung der sinusförmigen vertikalen Bewegung des Bolzens direkt auf den Prüfling. Überdies verhindert die Befestigung ein „Wandern“ des Prüflings.

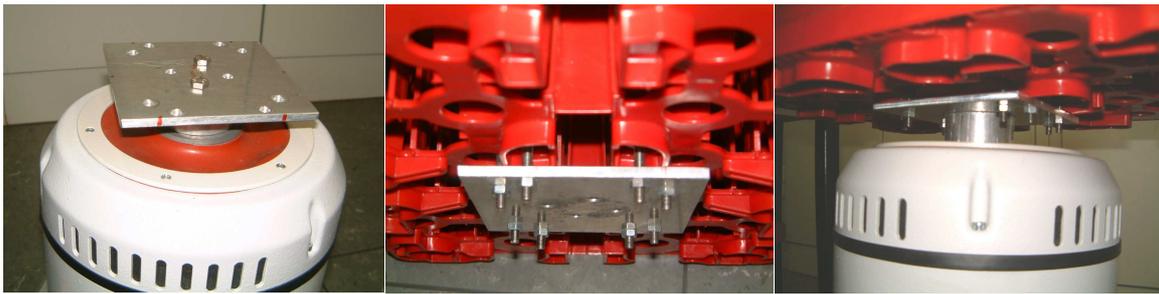


Abbildung 3-7: Halterung (Expander) zur Befestigung des Prüflings am Shaker

Weiterhin ermöglicht diese Art der Fixierung ein freies, von äußeren Einflüssen ungehindertes Schwingen des Prüflings. So findet eine fehlerfreie Ausbildung und Detektion von Eigenformen bzw. –schwingungen statt, mit geringem zu erwartenden Rauschen. Dies erleichtert den Vergleich zur numerischen Simulation.

Auch ein Kippen oder mögliche Querschwingungen der Versuchseinrichtung werden durch die speziell vertikal ausrichtbare Führung am Schwenkgestell des Shakerfußes bei minimierter Querbeschleunigung verhindert. Das Schwenkgestell dämpft außerdem die Übertragung von Schwingungen auf den Aufstellort und dessen Umgebung (vgl. Abbildung 3-8).



Abbildung 3-8: Shaker mit Prüfling und positionierten Sensoren

Beschleunigungssensoren

Wie bereits in Abbildung 3-6 demonstriert, wird das Antwortsignal des Prüflings mit Hilfe von unabhängigen, separat angebrachten Sensoren aufgenommen. Ihr Messbereich (0 bis 1500 Hz, Sensorresonanz bei 3000 Hz) ermöglicht die Betrachtung des gesamten geforderten Messbereichs von 50 bis 1000 Hz. Es handelt sich dabei um DMS-Beschleunigungsaufnehmer (Fabrikat: burster 500 g, Typ 89015-500), deren Funktionalität eine Wheatstonesche Brückenschaltung mittels Dehnungsmessstreifen (DMS) zugrunde liegt [126, 127]. Sie lassen sich frei über den kompletten Prüfling positionieren, so dass alle Kästen mit derselben Vorgehensweise analysiert werden können. Die Ausrichtung der Sensoren erfolgt jeweils in der Hauptschwingrichtung der Prüfposition. Hierzu gilt festzuhalten, dass die Querschwingempfindlichkeit dieser Sensoren aufgrund der Konstruktion der Sensoren nach dem Prinzip eines Biegebalkens vernachlässigbar gering ist. Ein Gehäuse schützt den Sensor vor elektromagnetischen Störfeldern. Das Signal des Sensors verhält sich proportional zur Beschleunigung senkrecht auf dessen Montagefläche. Eine einfache, flexible, vom Hersteller (burster Präzisionsmesstechnik) empfohlene Befestigung der Sensoren am Prüfling erfolgt mit Bienenwachs als Fixiermittel (vgl. Abbildung 3-9). Dabei findet die Signalaufnahme an den in Abbildung 3-10 angezeigten Positionen (0 bis 6) statt, die auf den Linien A, B, C und M liegen. Die Punkte 1 und 4 stellen die bei der Neuronumerik in der Hauptsache betrachteten Punkte dar. Ihre Auswahl wird in Abschnitt 4.1.4 erläutert. Als entscheidend zur Prozessüberwachung erweist sich außerdem der Steuersensor „0“, der sich direkt auf der Halterung am Schwingbolzen befindet.



Abbildung 3-9: Anbringung eines Beschleunigungsaufnehmers am Kastengriff

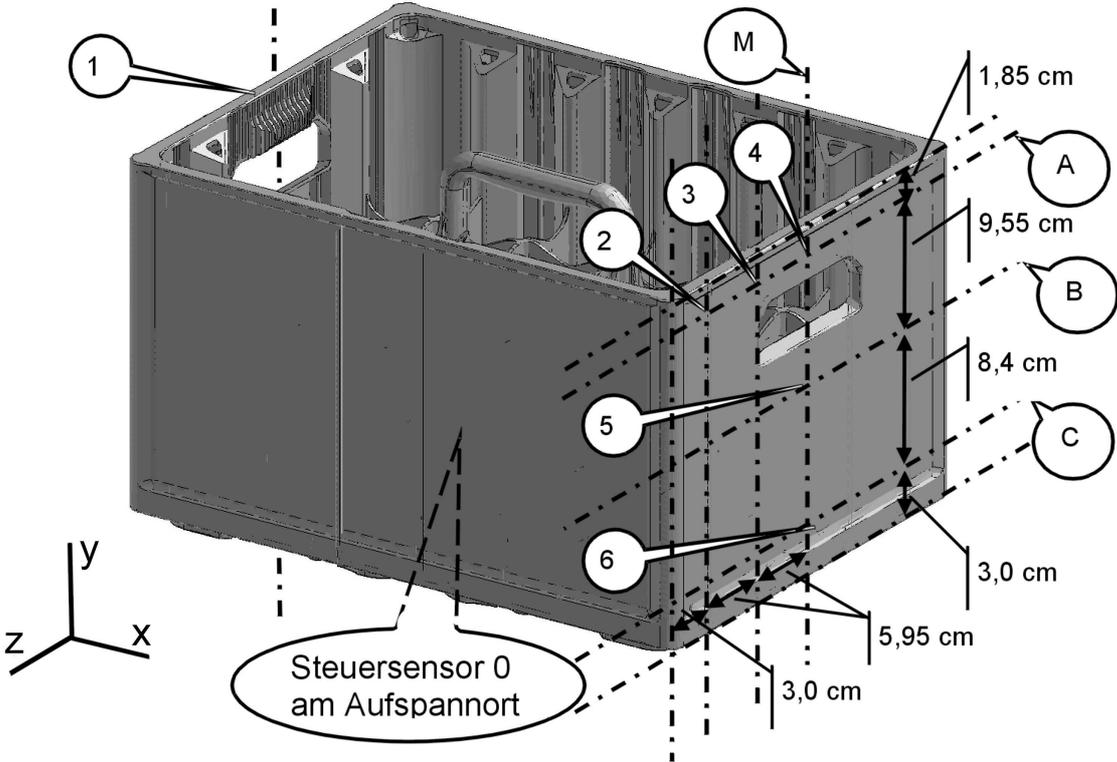


Abbildung 3-10: Messpositionen 0 bis 6 entlang der Messlinien A, B, C und M bezogen auf das eingezeichnete Koordinatensystem x, y, z

3.3.2 Steuerung und Automation

Eine wichtige Forderung an die Regelstrategie bei Schwingprüfanlagen besteht darin, dass diese dem Prüfobjekt angepasst werden muss. Bedingt durch Prüfling und Halterung ist es jedoch normalerweise schwierig, einen Kontrollwert einzuhalten sowie Abweichungen zu korrigieren. Dabei wird ein vollständiges Abkoppeln der Eigenschwingungen des Prüflings von der Anregung aufgrund mechanischer Restriktionen nur schwer erreicht [128]. Demzufolge wird üblicherweise bei komplexen Geometrien ein fester Verstärkerpegel zum Start der Testreihe vorgegeben. Eine Testspezifikation gilt somit nur für den definierten Verstärkerpegel und wird mittels eines Kontrollensors (Steuersensor) am Aufspannort dokumentiert (vgl. Abbildung 3-11). Dieses Signal dient außerdem zur Berechnung von Übertragungsfunktionen [129, 130].

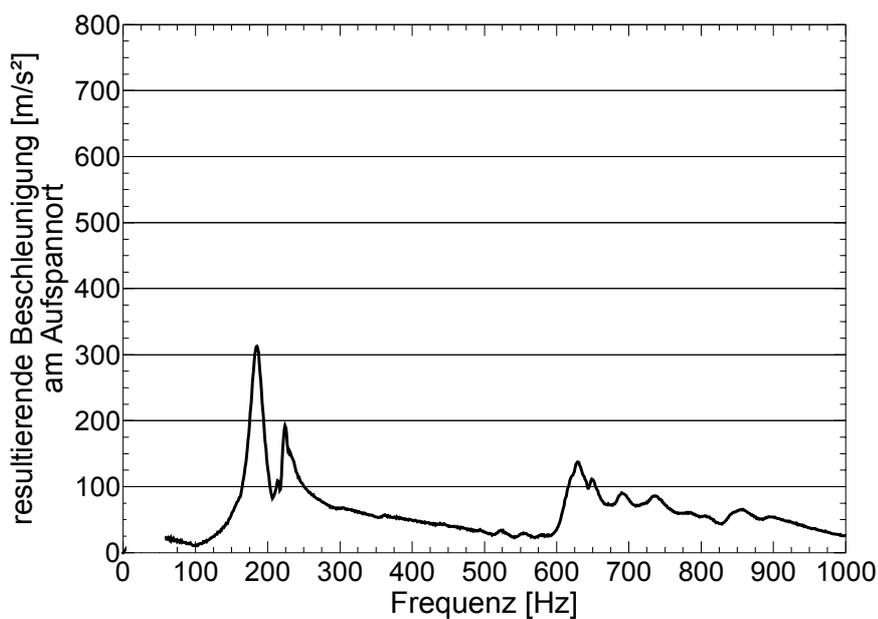


Abbildung 3-11: Steuersignal am Steuersensor für den aufgespannten intakten Kasten (in Richtung der vertikalen Bolzenbewegung)

Basierend auf diesen Bedingungen resultiert die nachfolgend für die Versuchsanlage konfigurierte Steuerung. Der Ablauf richtet sich nach einem festgesetzten Testprogramm für die ausgewählte Testspezifikation (Tabelle 3-3). Der Startpegel für einen intakten Kasten ist Anfangsbedingung für jede Testreihe.

Tabelle 3-3: Testspezifikation

Gültig für die eingesetzte Anlagenkonfiguration mit einem elektrodynamischen Shaker der TIRA GmbH [131]:	Schwingprüfanlage Typ: TIRAvib 52120 → Schwingerreger TIRAvib S522 (Sinusvektorkraft 200 N, Hauptresonanz >5500 Hz) → Verstärker TIRAvib A 50150 (Sinusdauerleistung 500 W)
Startwert	50 Hz
Startbeschleunigung (Amplitude der Anfangsbedingungen)	75 ms ⁻² bei definiertem Verstärkerpegel am Referenzort (Stößel) (4,35 V bei 300 Hz konstanter Sinusschwingung und aufgespanntem intakten Kasten)
Endwert	1000 Hz
Steuerung	Shaker-Anregung mit konstanter Einstellung des Verstärkerpegels
Anregungsart A/D-Wandlung	Linear gleitende Sinusschwingung in 25 s DAP-Karte (Microstar 5200a/526) Abtastrate 20 kHz, (Blockgröße = 512 ⇒ 20 Punkte je Periode bei 1000 Hz)
Sensoren	DMS-Beschleunigungsaufnehmer (burster 500 g, Typ 89015) Messbereich 0-500 g, Arbeitsbereich 0-1500 Hz, Sensorresonanz bei 3000 Hz)

Die Ansteuerung des analogen Shakerverstärkers erfolgt über eine DAP-Karte, deren Ein- und Ausgaben mit Hilfe der Regelungssoftware DASYlab 5.03 [132] generiert und weiterverarbeitet werden. Die kommerzielle, aus Modulen aufgebaute Software ermöglicht dabei eine zweckmäßige Gestaltung des Testablaufes. Schematisch zeigt Abbildung 3-12 ein Schaltbild.

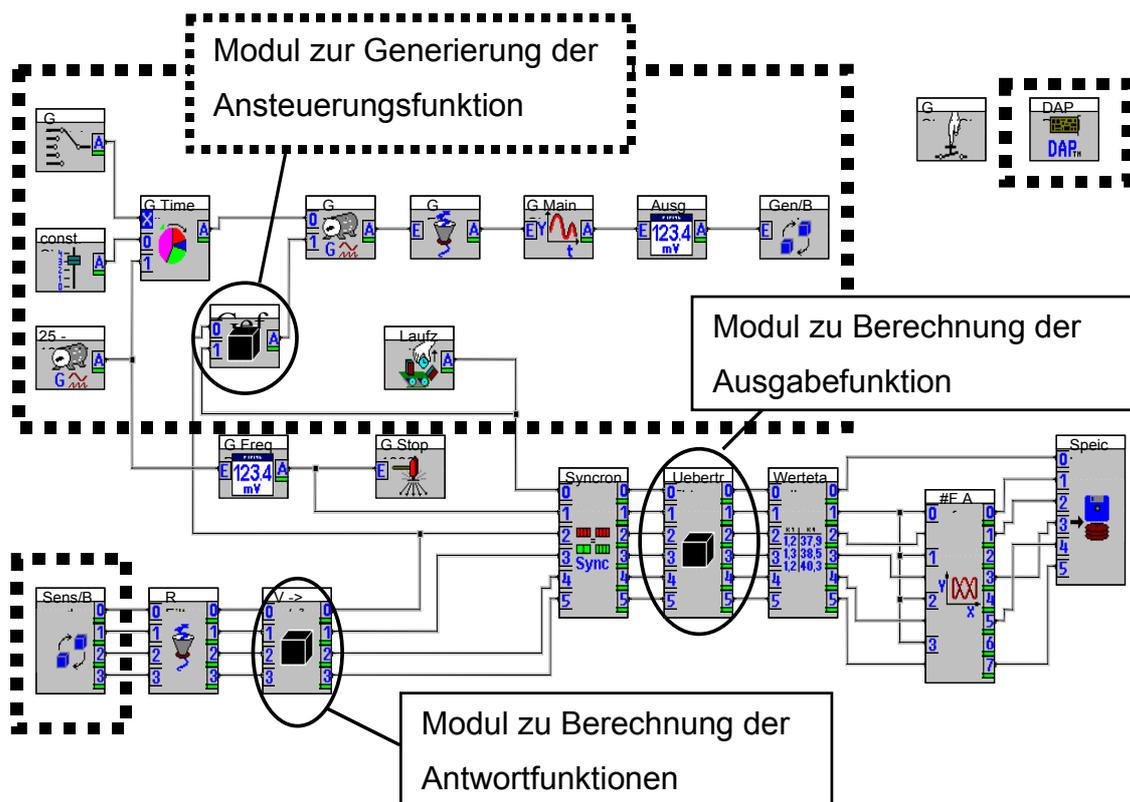


Abbildung 3-12: Schaltbild aus DASylab zur Steuerung des Sinussweep und der Messwerterfassung

Die Schaltung besteht aus einigen komfortablen Standardmodulen wie Schaltflächen, Kontrollanzeigen und Eingabefenstern. Hervorgehoben werden hier ihre drei Hauptbestandteile:

- Modul zur Generierung der Anregung

Dieses Modul generiert einen ansteigenden Sinussweep (50-1000 Hz) anhand einer linearen Zeitrampe von 25 s mit konstanter Ausgangsamplitude. Diese Amplitude beeinflusst nicht den Verstärkerpegel. Das auf der DAP-Karte generierte Steuersignal ist somit unabhängig von Prozessorressourcen des PC. Es dient zur Signalvorgabe für den Shaker-Verstärker und wird dort entsprechend des gewählten Pegels verstärkt.

- Modul zu Berechnung der Antwortfunktionen

Mit Hilfe sensorspezifischer Kalibrierfaktoren werden die unverarbeiteten Messwerte hier zu Beschleunigungssignalen transformiert.

- Modul zu Berechnung der Ausgabefunktion

Dieses Modul ermittelt aus Antwortsignal und Ansteuerungssignal bei Bedarf die Übertragungsfunktion. Auch wird hier, entsprechend der Formatanforderung vom klassifizierenden KNN die Weiterverarbeitung für jedes angestrebte Format, bezüglich der erforderlichen Datenvorverarbeitungsmethoden (vgl. Kap. 3.4) implementiert.

Die Konfiguration des Ausgabemoduls ermöglicht die direkte Weitergabe eines Datenstromes zum „trainierten“ KNN, um eine Klassifizierung der Spektren vorzunehmen.

Wie bereits erwähnt, findet die Generierung der Ansteuerfunktion ausschließlich auf dem DAP-Karten-eigenen Prozessor statt, wodurch sich eine Beeinflussung der Taktrate durch PC-bedingte „Windows-Prozesse“ vermeiden lässt. Ebenso übernimmt die DAP-Karte in einem dort implementierten Arbeitsspeicher die Zwischenspeicherung der Messdaten, so dass es am Eingang der Karte bei der A/D-Wandlung zu keinem Datenverlust aufgrund von zu langsamen Taktraten des PC kommen kann.

3.3.3 Besprechung der Testspezifikation

Die Testspezifikation (vgl. Tabelle 3-3) und die darin dokumentierten Anfangsbedingungen des experimentellen Pilotsystems resultieren aus Ergebnissen von Vorversuchen, in denen Bereiche weitgehend linearen Verhaltens der Sensorsignale für die eingesetzten Messbereiche erprobt wurden. Demgemäß sind die Systemparameter festgelegt. Abbildung 3-13 verdeutlicht dies anhand einer linearen Erhöhung des Verstärkerpegels. Die separat dargestellte Frequenz in Abbildung 3-14 zeigt dabei lineares Verhalten, d. h. eine Erhöhung des Verstärkerpegels hat eine lineare Erhöhung des Sensorsignals zur Folge. Diese Ergebnisse gelten für den linear elastischen Bereich und sind daher aus thermodynamischer Sicht als reversibel anzusehen. Insbesondere findet also keine plastische Verformung statt.

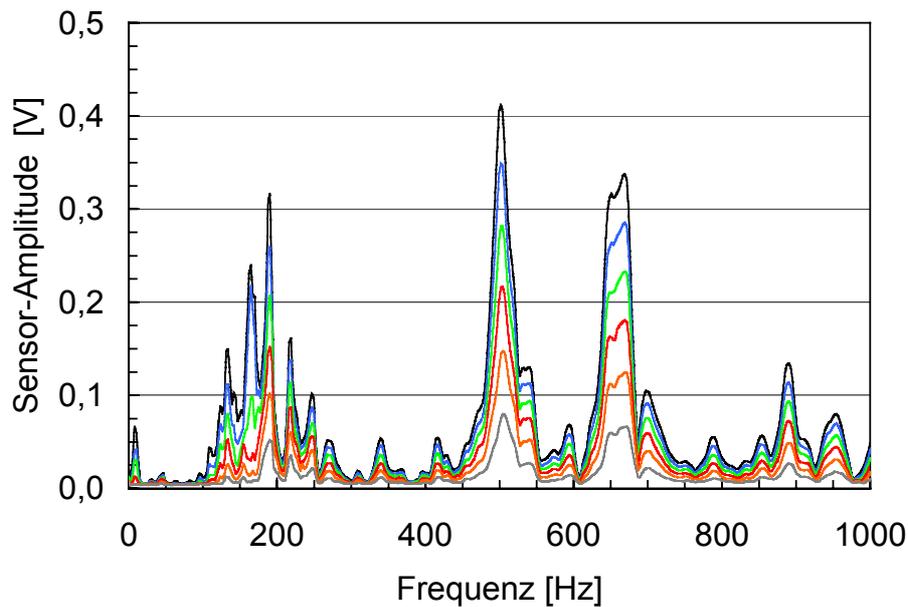


Abbildung 3-13: Darstellung des Antwortspektrums eines Messpunktes bei linearer Erhöhung des Anregungspegels des Verstärkers

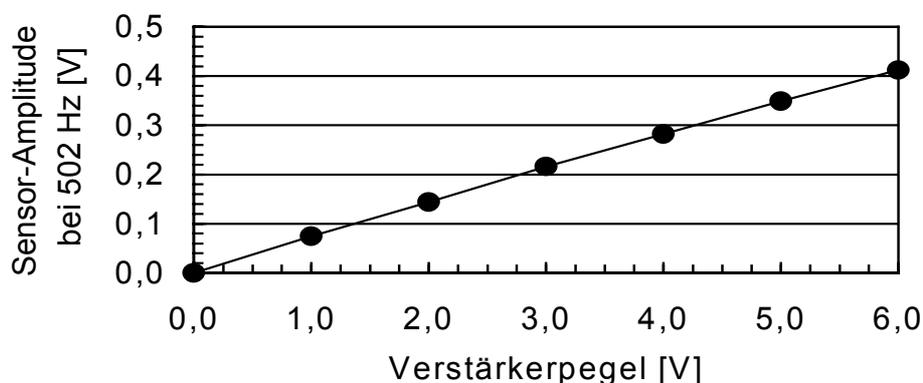


Abbildung 3-14: Verstärkerpegel und Antwortsignal bei Pegelerhöhung am Beispiel der Frequenz 502 Hz aus Abbildung 3-13

Ausgehend von diesem Sachverhalt wird im Weiteren immer das aktuell gemessene Signal direkt eingesetzt und, wie nachfolgend in Gl. (3-1) und (3-2) beschrieben, das jeweilige Messsignal entsprechend seinem Messzeitpunkt t weiterverarbeitet. Die Betrachtung einer strukturbedingten Phasenverschiebung bei der Signalübertragung innerhalb des Festkörpers entfällt demzufolge.

Die Gültigkeit der Hersteller-Kalibrierung der Beschleunigungsaufnehmer wurde im Hinblick auf ihr Rauschverhalten angenommen, wobei bei eingesetztem Verstärkungsfaktor des Vorverstärkers von 55 ein Rauschen von maximal $\pm 0,5 \text{ ms}^{-2}$

festgestellt wurde. Bei einem Messwert von 100 ms^{-2} entspricht das einem Fehler von maximal 1 %. Die Frequenzspektren werden dadurch nur wenig verrauscht.

Die Schwingprüfanlage (TIRAvib 52120) stellt laut Herstellerangabe ein stabiles wartungsarmes System dar, die mit Hilfe des Belastungsdiagramms „TV52120“ ihrer technischen Dokumentation überprüft und kalibriert wird. Für den täglichen Gebrauch ist es ausreichend, die täglichen Anfangsbedingungen zu kontrollieren [131]. Ein Querschwingfehler aufgrund von ungewollter Querschleunigung der Schwingprüfanlage konnte nicht nachgewiesen werden.

Die Digitalisierung der analogen Messsignale erfolgt hardwarebedingt mit einer Abtastrate von 20 kHz. Dies bietet eine hinreichende Genauigkeit von ca. 1000 Messpunkten je Spektrum (50 bis 1000 Hz).

Zusammenfassend sind die Parameter der Testspezifikation (vgl. Tabelle 3-3) als leistungsfähige mittlere Einstellung der zur Anwendung kommenden Pegelbreite zu bewerten. Die gegebenen Voraussetzungen gelten für den gesamten Messbereich. Unter Berücksichtigung der Anfangsbedingungen und einer täglich zu überprüfenden Nullpunkteinstellung der Sensoren gibt sie die Testbedingungen aller Versuchsreihen wieder.

3.4 Daten-Vorverarbeitung für das KNN

Wie bereits in Abschnitt 2.3.4 beschrieben, kommt der Auswahl geeigneter Eingangsdaten für das KNN eine enorme Bedeutung zu. Die jeweiligen Antwortspektren repräsentieren die zu klassifizierenden Schadensfälle. Sie bestehen, wie in Abschnitt 3.3 beschrieben, aus ca. 1000 Messdaten.

Um eine geeignete Weiterverarbeitung zu gewährleisten, erweist es sich als zweckmäßig, eine Datenreduktion auf eine begrenzte Zahl von Punkten vorzunehmen. Besagte Anzahl und das eingesetzte Daten-Vorverarbeitungs-Verfahren (DVV) richten sich dabei nach der Leistungsfähigkeit des eingesetzten Netzes (vgl. Abschnitt 2.3.4). Normalerweise wird dabei ein Verfahren gesucht, dessen Komplexität möglichst niedrig ist, und das dennoch leistungsfähige Ergebnisse für das KNN liefert. Die in den Datensätzen enthaltene Information muss dazu auf geeignete Weise extrahiert und von den Netzeingängen verarbeitbar gemacht werden. Ziel ist es, ein auch im Hinblick auf den Rechenaufwand möglichst einfaches Verfahren anzuwenden, welches die charakteristischen Eigenschaften detektiert und nicht-redundante Datensätze zur Verfügung stellt.

Diese Arbeit setzt zwei Typen von Messsignalfunktionen ein, die jeweils mittels zweier Verfahren weiterverarbeitet werden. Dies sind zum einen das direkte Antwortsignal (Typ A) und zum anderen das der Übertragungsfunktion (Typ B). Daraus ergeben sich vier Datenvorverarbeitungs-Formate, die das KNN anschließend einliest. Tabelle 3-4 veranschaulicht die verschiedenen, erprobten Verfahren. Die Aufteilung des Spektrums in Frequenzklassen und deren Integration erweist sich dabei als besonders geeignet. Die Integration 10 gleich großer Frequenzklassen verdeutlicht das Signalverarbeitungsverfahren 1 mittels Gleichung (3-3). Die Aufteilung in 100 Frequenzklassen und Aufsummierung des Integrals jeder 10ten Klasse („Shiften“) auf 10 Summen (gemäß Gl. (3-4); Signalverarbeitungsverfahren 2) führt zu einer verfeinerten Betrachtung.

Sie werden zum einen vom direkten Antwortsignal am Messort berechnet (vgl. Gl. (3-1)) und führen zum anderen zu den Verfahren A-1 und A-2. Zusätzlich wird die Übertragungsfunktion aus dem Quotienten des Signals am Messort und dem Signal der Anregung gebildet (vgl. Gl. (3-2)), dargestellt durch die Verfahren B-1 und B-2.

Tabelle 3-4: Auflistung eingesetzter Daten-Vorverarbeitungs-Verfahren (DVV); in Kombination ergeben sie A-1, A-2, B-1 und B-2.

Typ der Messsignalfunktion	Beschreibung
A. Direktes Antwortsignal	Keinerlei Vorverarbeitung des Messsignals, lediglich Multiplikation mit den Kalibrierfaktoren. $s_{\text{Sensorsignal}}(x) = \text{Antwortsignal}(t)$ (3-1)
B. Übertragungsfunktion des Antwortsignals	Quotient des Antwortsignals am Messort zum Anregungssignal zum jeweiligen Messzeitpunkt t . $s_{\text{Übertragungsfunktion}}(x) = \frac{\text{Antwortsignal}(t)}{\text{Anregungssignal}(t)}$ (3-2)
Verfahren der Signalverarbeitung	Beschreibung
1. Integration von 10 Frequenzklassen	Entsprechend der Klassenbreite werden 10 gleich große Klassen integriert. Je Klasse gilt (3-3) $I_{Ai} = \int_{b_i}^{b_{i+1}} s(x) dx .$
2. Integration von 100 Frequenzklassen und geshiftete Aufsummierung auf 10 Klassen	Entsprechend der „Integration von 10 Klassen“ werden 100 Frequenzklassen integriert und jede 10te stufenweise auf 10 Klassen summiert. Je Klasse gilt (3-4) $I_{Ai} = \sum_{m=1}^{10} \int_{b_j}^{b_{j+1}} s(x) dx \quad \text{mit} \quad j = 1 + 10 \cdot (m - 1) .$
<i>i</i> : Laufvariable für Frequenzklassen (1 bis 10) <i>b_i</i> und <i>b_{i+1}</i> : obere und untere Klassengrenze <i>m</i> : Laufvariable zur „Shiftung“ (1 bis 10) <i>j</i> : Laufvariable für Frequenzklassen (1 bis 100) <i>x</i> : Laufvariable in Frequenzrichtung (50 bis 1000 Hz) <i>t</i> : Zeitpunkt der Signalaufnahme; Referenz bei Berechnung der Übertragungsfunktion	

Der Vollständigkeit halber sei erwähnt, dass neben den durchgeführten Untersuchungen auch andere Verfahren getestet wurden. Bei der ersten Anwendung zeigte sich jedoch schnell, dass weitere Vorverarbeitungsverfahren, wie z. B. eine

Nivellierung oder Normierung der Spektren, aber auch eine Berechnung des Flächenträgheitsmomentes je Frequenzklasse, keine wesentliche Verbesserung der Klassifikation bringen. So wird der Schwerpunkt der Arbeit auf die oben beschriebenen Vorverarbeitungsverfahren gelegt. Als Beispiel verdeutlichen nachfolgend vier unterschiedliche Spektren das angewandte Verfahren (vgl. Abbildung 3-15).

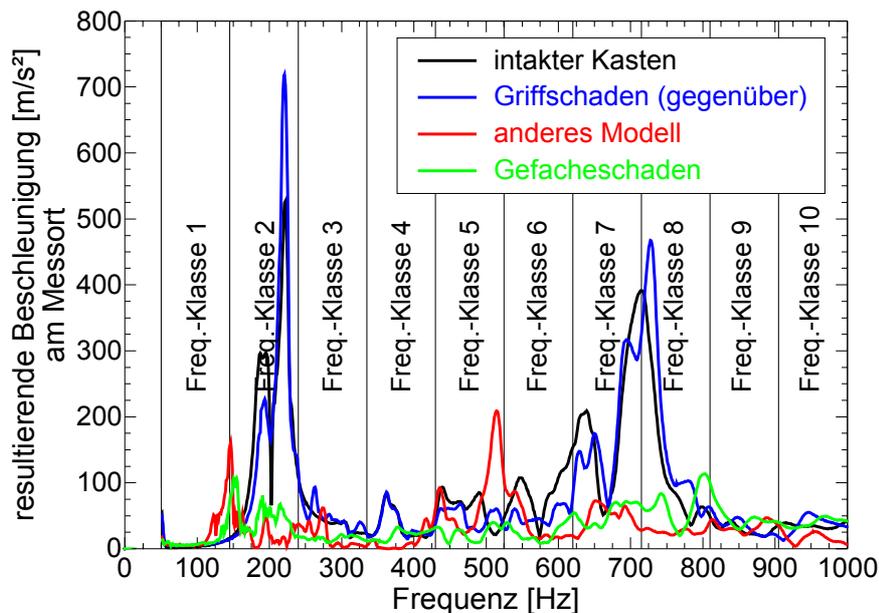


Abbildung 3-15: Spektren vier verschiedener, als Beispiel ausgewählter Schadensfälle, die gemäß der eingezeichneten senkrechten Hilfslinien in Frequenzklassen unterteilt (A-1) und integriert werden (Klasse 1 bis 10). „Gegenüber“ bedeutet dabei, dass sich die Messposition auf der dem Schaden gegenüberliegenden Seite des Getränkekastens befindet.

Das Verfahren A-1 (vgl. Tabelle 3-4) dient dazu, die Spektren („Schadensfälle“) auf zehn Frequenzklassen zu reduzieren. Abbildung 3-16 demonstriert die schematisierte Ausgabe dieser Vorverarbeitung des direkten Sensorsignals als Balkendiagramm.

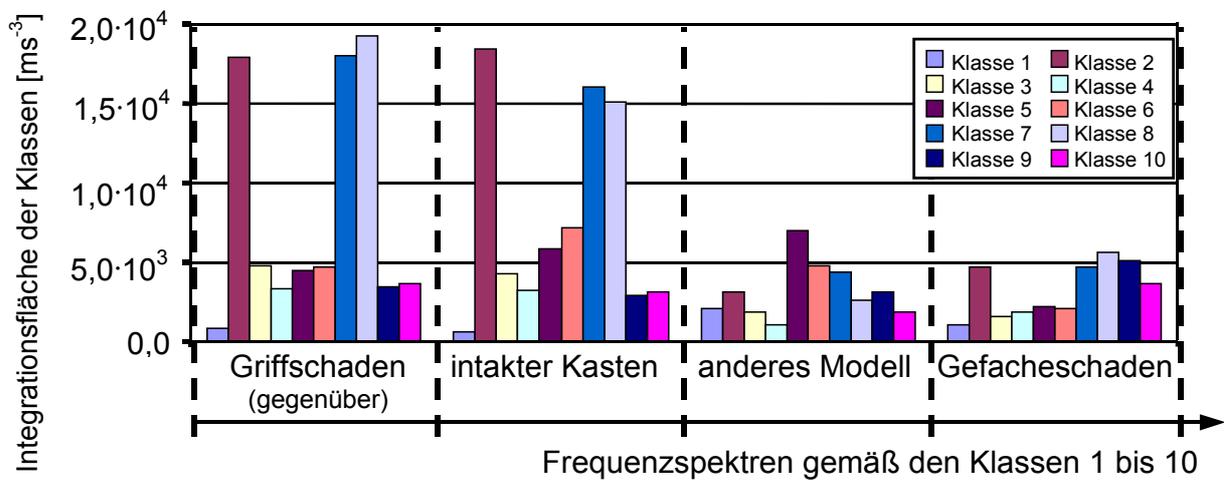


Abbildung 3-16: Ausgabe bei der Vorverarbeitung von Frequenzspektren am Beispiel der Reduzierung auf 10 Eingangsneuronen; Integration nach Methode A-1 gemäß der Aufteilung in Klasse 1 bis 10 nach Abbildung 3-15

Der Datenpool ist vom Umfang her so ausgelegt, dass er gemäß Auswahl und Anzahl der Schadensfälle der Theorie (vgl. Abschnitt 2.3.4) entspricht. Dazu sind je nach Ziel des KNN-Trainings 20 bis 100 Datensätze im Einsatz. Ausschlaggebend dafür sind in erster Linie die eingesetzte Netztopologie und die geforderte Zuordnung der Ausgabe. Die tatsächliche Menge wird anhand der Versuchsreihen bestimmt.

Der Datenpool der zur Anwendung kommenden Schadensfälle wird durch Wiederholungsmessungen um den Faktor 10 vergrößert. Im Hinblick auf den praxisrelevanten Einsatz wird dabei ein „künstlicher“ Fehler erzeugt, der aus absichtlich vorgenommener, ungenauer Sensorpositionierung, verschobener Positionierung auf der Halterung, sowie Systemrauschen erzeugt wird. Der durchschnittliche „künstliche Fehler“ liegt beim Vergleich der Antwortspektren in der Größenordnung von 1-5 % (vgl. Abschnitt 4.2.1 und Abbildung 4-13), jedoch sind an einigen Peaks dabei Abweichungen von bis zu 50 % möglich.

3.5 Weiterentwicklung vorhandener KNN-Codes

Das eingesetzte KNN bildet eine spezifische Konfiguration eines am Lehrstuhl für Fluidmechanik und Prozessautomation (LFP) entwickelten KNN-Codes. Der Code beruht auf der Programmiersprache C++ nach den Regeln des ANSI C++-Standards. Der LFP-KNN-Code bietet die Möglichkeit, auf den in Abschnitt 2.3 beschriebenen Grundlagen die vollständige Netzwerk-Topologie inklusive aller notwendigen Parameter zu erstellen. Darüber hinaus ermöglicht er die Implementierung des erforderlichen Trainingsalgorithmus in der Trainingsphase sowie die Anwendung des KNN in der Prädiktionsphase.

Zur Mustererkennung der unterschiedlichen Antwortspektren greift das KNN auf Datenpools nach dem in Abschnitt 3.4 vorgestellten Format zurück. Im Rahmen der Arbeit behandelt Abschnitt 4.3 die Möglichkeiten zur grundlegenden Klassifikation der experimentellen Daten, wobei Trainings- und Prädiktions-Datensätze experimentellen Ursprungs sind. In Abschnitt 4.4 werden die experimentellen Trainings-Datensätze schrittweise mit numerischen substituiert: Zuerst die Daten „intakter“ Kästen, dann alle „defekter“ Kästen und schließlich der komplette Datensatz.

Die Gewichte und Schwellenwerte der Eingänge der Neuronen stellen in der vorliegenden Arbeit die trainierbaren Parameter dar. Der Prädiktionsfehler des Netzes lässt sich deshalb lediglich minimieren, indem optimale Gewichte und Schwellenwerte gefunden werden, wie in Abschnitt 2.3.3 beschrieben. Das Ziel ist erreicht, wenn der Gradient der Fehlerfunktion für alle Gewichte i , also

$$\bar{\nabla}E = \left(\frac{\partial E}{\partial w_1}, \dots, \frac{\partial E}{\partial w_i} \right) \quad (3-5)$$

minimiert wird und somit ein Minimum des Fehlers der Netzantwort erreicht ist.

Die übrigen Parameter des Netzwerkes und des Trainingsalgorithmus liegen vorab fest und werden nicht weiter verändert. Die Bestimmung der Grundkonfiguration erfolgt ausgehend von allgemeinen Empfehlungen [100] und einigen Vorversuchen. Eine Ausnahme bildet dabei die Topologie des Netzwerkes, für die in Abschnitt 4.4.2 aufgrund eines „Dual-Sensorsystems“ ein neuer Aufbau gesucht wird. Tabelle 3-5 listet die fixen Parameter des eingesetzten KNN und des Trainingsalgorithmus RPROP (Resilient Propagation) auf.

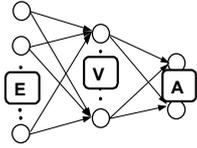
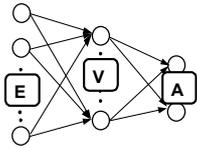
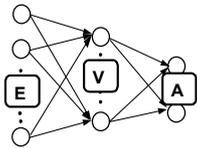
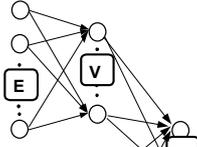
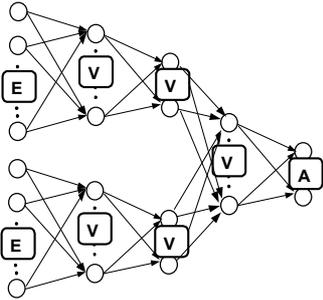
Tabelle 3-5: Konfiguration der Parameter des eingesetzten LFP-KNN bei Verwendung des Trainingsalgorithmus RPROP

Netzwerk Parameter	Einstellung bzw. Startwerte
Lernmethode	überwachtes Lernen
Netzwerkdynamik	statisch
Eingangsformat der Neuronen	Normierung: $x_i = \left(\frac{x_{\text{Eingang}} - \mu}{\sigma_s} \right)$
Ausgabeformat der Neuronen	keine Skalierung bzw. Normierung
Verrauschung der Eingangsdaten	Verrauschungsfaktor: 0 - 10 %
Startgewichte	Random Range: -0,001 bis 0,001
RPROP - Koeffizienten	Lernrate η steigend: 1,2 Lernrate η fallend: 0,5 Weight Decay Term: 0,0 Begrenzung oberes Limit: 5,0 Begrenzung unteres Limit: $1,0 \cdot 10^{-7}$ Schrittweite - Delta Weight: 0,05
Aktivierungsfunktion	Sigmoide: $akt_j = 1/(1 + \exp(-net_j))$ (vgl. Gleichung (2-55))
Gewicht-Anpassung	offline
Gütekriterium	halber quadratischer Fehler: $E_{ges} = \frac{1}{2} \sum E_w^2 \quad (3-6)$
Berücksichtigte Fehlerarten bei der Fehlerminimierung im Netz	MSE (mittlerer quadratischer Fehler): $E_{MSE} = \frac{\sum (\text{ist} - \text{soll})^2}{n_{\text{Ausgabeneuronen aller Muster}}} \quad (3-7)$
	RAE (relativer absoluter Fehler): $E_{RAE} = \frac{\sum \left \frac{\text{ist} - \text{soll}}{\text{soll}} \right }{n_{\text{Ausgabeneuronen aller Muster}}} \quad (3-8)$
	Gewichtung der Fehlerarten: $\frac{\text{Trainingsdaten}}{\text{Testdaten}} = 0,9$

Das eingesetzte Standard-Netzwerk zur Klassifikation des Antwortspektrums eines Sensors besteht aus 10 Eingangsneuronen, 5 Neuronen in der versteckten Schicht und 2 Ausgangsneuronen, alle in Feedforward-Richtung verbunden. Die Schadensdetektierung beruht darauf, die Signale in „intakt“ (Ausgabeneuron 1) und „defekt“ (Ausgabeneuron 2) zu klassifizieren (vgl. Abbildung 2-6). Dazu approximieren die jeweiligen Ausgangsneuronen für „wahr“ eine „1“ und für „falsch“ eine „0“. „1“ bedeutet somit, dass die dem Ausgabeneuron zugewiesene Eigenschaft zutrifft, und „0“ steht für die Ablehnung der zugewiesene Eigenschaft. D. h. für die vorliegende Anwendung (2 Ausgangsneuronen), dass eine korrekte Zuordnung beider Neuronen, die mit der Vorgabe übereinstimmt, entweder die Netzwerkausgabe „0-1“ oder „1-0“ erzielen muss. Eine andere Ausgabe stellt einen Widerspruch zu Vorgabe dar und wird daher im Rahmen der Arbeit als „defekt“ gewertet.

In diesem Kontext werden die in Tabelle 3-6 aufgeführten Topologien untersucht. Dabei wird nicht nur die spezifische Aufteilung des Sensorspektrums berücksichtigt, sondern auch eine genauere Spezifizierung der Klassifizierung und damit die Detektierung spezieller Schadensfälle. Eine bessere Informationsgewinnung und daher eine verbesserte Schadenserkennung lässt sich durch Verwendung von mehreren, an verschiedenen Orten positionierten Sensoren erwarten. Dies erfordert das Studium von geeigneten Netztopologien für einen Multisensoreinsatz. Tabelle 3-6 demonstriert schematisch Topologien für Uni- und Dual-Sensoranordnungen.

Tabelle 3-6: Eingesetzte Topologien im Uni-Sensor- und Dual-Sensorsystem

Bezeichnung	Neuronenzahl und Verbindungen (Eingang E) X (verdeckt V) X (Ausgang A)
Uni-Sensorsystem	$5 \times 3 \times 2$ $10 \times 5 \times 2$ $10 \times 10 \times 2$ 
Uni-Sensorsystem mit Schadensklassifizierung	$10 \times 5 \times 1$ $10 \times 7 \times 5$ 
Dual-Sensorsysteme	$20 \times 10 \times 2$ 
Verbindung zweier 10x5-Stränge:	$2 \times (10 \times 5) \times 2$ 
Verbindung zweier 10x5x2-Stränge:	$2 \times (10 \times 5 \times 2) \times 3 \times 2$ $2 \times (10 \times 5 \times 2) \times 5 \times 2$ 

Zur Beurteilung ihrer Qualität wird die Ausgabe des Netzes mit bekannten Schäden verglichen. Dies ermöglicht eine Beurteilung der Klassifikationsfähigkeit des Netzes. Das Beispiel gemäß Abbildung 3-17 verdeutlicht, dass es Datensätze mit eindeutiger Approximation gibt (z. B. Prüflinge 5 und 12-20). Bei anderen gestaltet sich eine korrekte Interpretation schwer (Prüflinge 4, 7, 21 und 24). Auch Datensätze mit falscher Zuordnung (Prüfling 22) können auftreten.

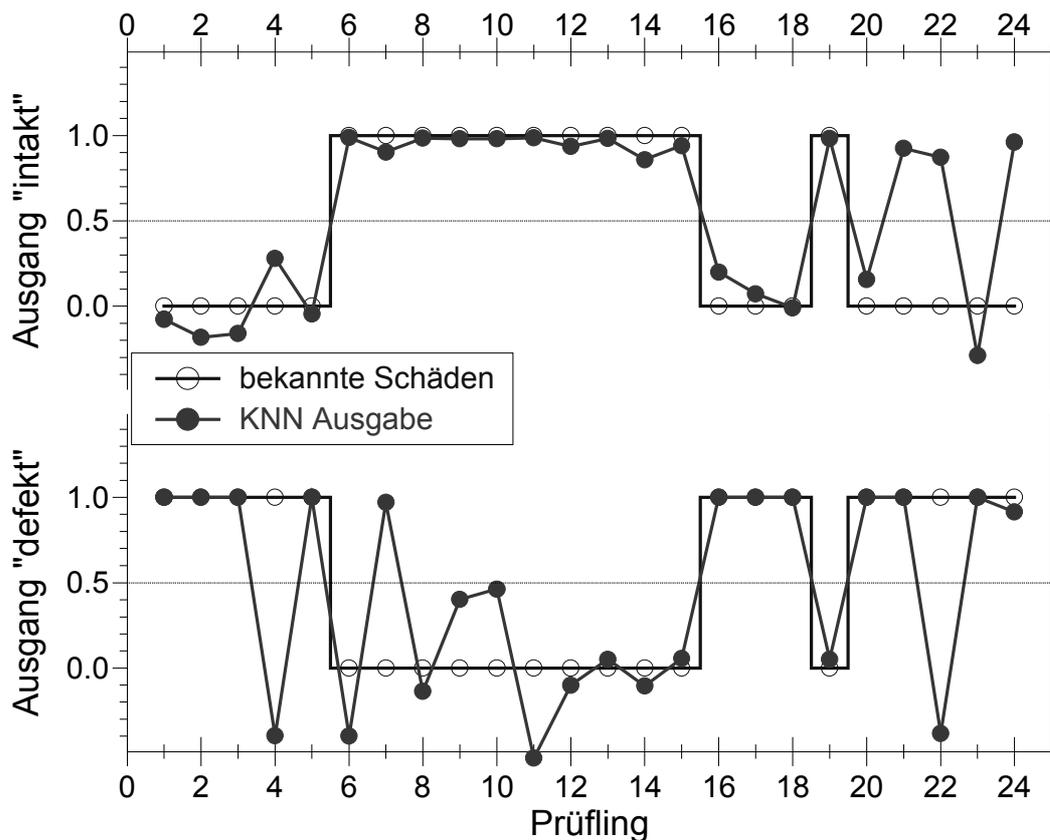


Abbildung 3-17: Klassifizierungsgraph am Beispiel einer zufällig ausgewählten „intakt-defekt“ Klassifizierung: Auftragung des Vergleichs bekannter Schäden mit der tatsächlichen KNN-Ausgabe. 24 Prüflinge werden getestet. Der Wert „1.0“ gibt die Annahme und „0.0“ die Ablehnung der jeweiligen Klassifikation an.

Zur Beurteilung der Qualität der Klassifikation werden aus einem Klassifikationsgraph (vgl. Abbildung 3-17) die Gesamtfehlerraten für die Klassen „intakt“ und „defekt“ sowie der Gesamtfehler der Klassifizierung berechnet. Dabei wird der prozentuale Fehler der Zuordnung zu einer Ausgabe Klasse in Abhängigkeit von der bekannten Soll-Ausgabe ermittelt (vgl. Tabelle 3-7). Im Folgenden wird immer der Gesamtfehler der Klasse, d. h. nicht die einzelnen Knoten des KNN, sondern deren Gesamtausgabe für eine Klasse betrachtet. In Abbildung 3-17 gelten somit die Prüflinge 4, 7, 21, 22 und 24 als falsch klassifiziert und damit als „defekt“. Die Gewichtung der Fehleranteile, bezogen auf die jeweiligen Knoten, wird nicht explizit errechnet. Sie wird bei Bedarf anhand der Klassifizierungsgraphen diskutiert, da es zu einer nicht eindeutigen Approximation der zusammengehörigen Ausgabe-Paare kommen kann. Um im Hinblick auf den Praxiseinsatz auf der sicheren Seite zu sein, werden diese im Rahmen der Arbeit als Fehler gewertet und der „defekten“ Klasse zugeordnet. Bei der Netzwerkgestaltung hingegen ermöglicht die Betrachtung dieser Fälle die

Beurteilung des KNN bezüglich seiner Sensibilisierung auf bestimmte Grenzfälle. Dies führt beispielsweise zu einem erneuten gezielten Training mit einer angepassten Datenauswahl.

Tabelle 3-7: Vorgehensweise bei der Berechnung der Fehlerraten

	Fehler		
	intakt	defekt	Gesamtfehler
Vorgehensweise	$\frac{n_{Fi}}{n_i}$	$\frac{n_{Fd}}{n_d}$	$\frac{n_{Fi} + n_{Fd}}{N_a}$
Beispiel nach Abbildung 3-17	9,1 %	30,8 %	20,8 %

$N_a = n_i + n_d$: Anzahl aller Prüflinge
 n_i : Anzahl der intakten Prüflinge (im Test bekannt)
 n_d : Anzahl der defekten Prüflinge (im Test bekannt)
 n_{Fi} : Anzahl der Fehler bei Zuordnung der intakten Prüflinge
 n_{Fd} : Anzahl der Fehler bei Zuordnung der defekten Prüflinge

3.6 FEM-Software (MSC/PATRAN-NASTRAN)

Die numerische Simulation wird auf Grundlage der FEM durchgeführt, vgl. auch Abschnitt 2.1. Dabei kommt das kommerzielle Softwarepaket MSC/PATRAN-NASTRAN zum Einsatz [133]. Die modale „Frequency-Response-Analyse“ baut dabei auf den Prinzipien der dynamischen Schwingungslehre auf, wie sie in Abschnitt 2.2 beschrieben sind. Die Auswahl dieser Methode erfolgte aus Gründen der Praktikabilität. In diesem Zusammenhang sind die vorhandenen Rechnerkapazitäten bzw. Rechenzeiten am LRZ sowie der damit zur Verfügung stehende Speicherplatz von entscheidender Bedeutung. Die modale Frequency-Response-Methode bietet hierbei gegenüber der Transienten-Response-Methode den Vorzug kleineren Speicherplatzbedarfs.

Den Nutzen der numerischen Simulation erbringt zu Beginn die einfache Einsicht in das grundlegende Schwingungsverhalten des Festkörpers mittels Eigenformen (vgl. Abschnitt 4.1.1). Die Evaluierung der numerisch ermittelten Eigenformen des Getränkekastens bildet den Ausgangspunkt bei der Optimierung des Versuchstandes. Dies gilt nicht nur im Hinblick auf die Anlagenplanung im Vorfeld, sondern auch zur begleitenden Beurteilung der Experimente (vgl. Abschnitt 4.1.4). Ferner

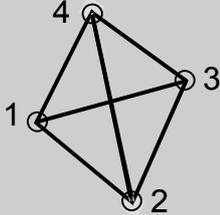
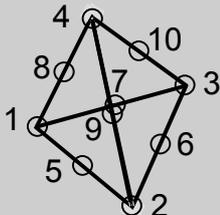
ermöglicht die numerische Simulation vor allem, günstige Sensorpositionen und einen geeigneten Ort der Anregung bzw. Form der Halterung herauszuarbeiten [134].

Des Weiteren stellt die Simulation im Zuge des entwickelten Neuronumerik-Hybrids eine große Anzahl von Mustern zur angestrebten Unterstützung des KNN-Trainings in Form von errechneten Frequenzspektren bereit (vgl. Abschnitt 4.1.2). Die Nutzung der erzeugten Modell-Schadensfälle stellt somit einen sehr effizienten Weg zur Abdeckung des benötigten KNN-Datenpools dar. Insgesamt erleichtert die numerische Simulation die Generierung weiterer Schadensmodelle, insbesondere im Vergleich mit einer kostenintensiven Erzeugung von experimentellen Datensätzen, die die geforderte Breite abdecken.

Konfiguration und Einsatz von MSC/PATRAN

Die Durchführung der FEM-Analyse erfordert zunächst die Erstellung einer der Software kompatiblen Geometrie, die das komplexe Modell des Getränkekastens darstellt. In hier nicht aufgeführten Vorversuchen zeigte sich, dass Vereinfachungen weitreichende Auswirkungen auf das Simulationsergebnis haben. Datensätze mit geometrischen Vereinfachungen lassen zwar Tendenzen erkennen, eignen sich jedoch nicht für eine Klassifikation. Daher hat sich als zweckmäßig erwiesen, möglichst genaue Geometriedaten einzusetzen. In dieser Arbeit kommt der zur Konstruktion des Spritzgusses verwendete original CAD-Datensatz des Kastenherstellers [123] zum Einsatz. Den Import dieses Datensatzes (Format „iges“ der Software Pro/ENGINEER) in das Format der eingesetzten FE-Software leistet das Pre- und Postprozessor-Programm MSC/PATRAN. Es ermöglicht außerdem die Diskretisierung (Vermaschung) in die zur Simulation notwendigen finiten Elemente mittels eines implementierten Netzgenerators. Dabei werden zehnknotige Tetraederelemente (TET10) eingesetzt. Diese werden wegen begrenzter Rechnerkapazitäten erst in einem zweiten Schritt aus einem mit vierknotigen Tetraederelementen (TET4) vermaschten Modell erstellt. TET10 zeichnen sich gegenüber TET4 durch verbesserte Genauigkeit aus, da sie nicht auf Kantengeraden beschränkt und somit weniger fehleranfällig sind [91]. Tabelle 3-8 gibt einen Überblick über die wichtigsten Daten der praktizierten Vorgehensweise bei der Vermaschung der CAD-Geometrie.

Tabelle 3-8: Import und Vermaschung des CAD-Formates

CAD-Quelle	Software: Pro/ENGINEER
Kastenmodell „Amstel“ [123]	Format: IGES
Transformation in MSC/PATRAN 8.5	(Längen in mm)
erwartete Modelldimension	400
globale Toleranz	0,1
Zusammensetzung des „solids“	1 Festkörper, nicht unterteilt
freie Oberflächen	4632
Vermaschung mit TET4 Elementen	
	
globale Modell-Toleranz	0,5
globale max. Kantenlänge der Elemente	4
Knotenzahl	125002
Elementzahl	377453
Vermaschung mit TET10 Elementen (gewonnen durch Modifizierung von TET4-Modell)	
	
globale Modell-Toleranz	0,5
Knotenzahl	751729
Elementzahl	377453

Die weitere Konfiguration des FEM-Modells erfordert die Materialparameter aus Tabelle 3-1. Zur spezifischen Berechnung des als CAD-Geometrie zur Verfügung gestellten Kastenmodells erfolgte eine zusätzliche Validierung der eingesetzten Materialparameter. Diese geschieht durch den Vergleich mit experimentell erfassten Frequenzspektren und Eigenfrequenzen, die in Abschnitt 4.1.3 beschrieben werden.

Als Ausgabe des Preprozessors erhält man ein Eingabe-File im ASCII-Format, das darauf dem Solver MSC/NASTRAN zugeführt wird.

Konfiguration und Einsatz von MSC/NASTRAN

Die Verwendung des Solvers MSC/NASTRAN beruht auf zwei Lösungssequenzen. Zur „Modal Frequency-Response-Analysis“ findet die Sequenz SOL103 zur Simulation von Eigenformen und Eigenfrequenzen Einsatz. Sequenz SOL111 dient indessen der Simulation von Frequenzspektren an spezifischen Knotenpunkten aufgrund eines Frequenzsweeps. Im Anhang (vgl. Abschnitt 7.1) befindet sich je eine grundsätzliche Konfiguration (Code-Listing) eines Eingabe-Files für beide Sequenzen. Diese zeigen die vorgenommenen Einstellungen auf den entsprechenden Kartenplätzen [135].

Der Hauptunterschied beider Lösungssequenzen besteht darin, dass SOL103 zur Berechnung reiner Eigenformen von einem ungedämpften System ausgeht. Die Dämpfung wird also bei dieser Simulation nicht berücksichtigt (vgl. Gleichung (2-26)). Das führt zu dem bereits beschriebenen, freien dynamischen Verhalten des Systems.

Zur Simulation der Frequenzspektren an spezifischen Knotenpunkten wird auf die Sequenz SOL111 übergegangen. Hier kommt dem Dämpfungsterm nun die Bedeutung der strukturellen Dämpfung zu, die aus Gründen der Vereinfachung über das ganze Modell konstant gesetzt wird. Ebenso wird der Anregung eine Funktion vorgegeben (vgl. Abbildung 3-11), die experimentellen Ursprungs ist. Sie entspricht der Systemantwort an der Halterung des intakten Kastens.

Die entscheidenden Funktionen der Codes werden nachfolgend kurz erläutert. Die Simulation setzt als grundlegende Eigenschaften homogenes Material und lineares elastisches Verhalten voraus. Zur Anregung und als Antwort treten dabei nur kleine Verschiebungen auf. Nur die oben beschriebenen Adaptionen von MSC/PATRAN-NASTRAN für die beiden Sequenzen werden vorgenommen. Unverändert bleiben im Code indessen die grundlegenden Methoden zur modalen Frequency-Response Simulation.

MSC/NASTRAN Version 70.7 realisiert das „Large-Mass-Prinzip“. In der vorliegenden Anwendung dient es der numerischen Simulation von Eigenschwingungen. In der modifizierten MSC/NASTRAN Version V2001 konvertiert die Funktion SPCD - eine Konvertierung innerhalb der Methode der „enforced motion“ auf Basis des „Large-Mass-Prinzips“ - den „Large-Mass“-Ansatz in ein Verfahren,

das dem Modell direkt die Anregungskraft aufzwingt. Dies gewährleistet eine effektivere und fehlerfreiere Implementierung im Solver [94].

Zur Simulation bedarf es außerdem der Berücksichtigung der mechanischen Auflager-Restriktionen. Hier ist insbesondere die Fixierung der Elementknoten (Randbedingung) wichtig, wie dies im Experiment die Halterung verwirklicht. Im Code dient hierzu ein „RBE2-Element“. Dies ist ein „Festkörperelement“, das die Freiheitsgrade der Knoten begrenzt und somit eine Fixierung vorgibt.

Die Validierung der numerischen Datensätze (Spektren) erfolgt anhand einer Sensitivitätsanalyse. Sie wird in Abschnitt 4.1.3 für die intakte Geometrie des Kastens vorgenommen. Der validierte Datensatz findet danach zur Generierung von Schadensfällen Verwendung. Diese werden Bestandteil des Datenpools für die angestrebten neuronumerischen KNN-Trainings.

Die Abbildung von Schäden im CAD-Modell geschieht in Form des systematischen Entfernens von Elementen aus der Originalgeometrie. Dabei werden die an den Positionen von Rissen, Brüchen, etc. platzierten Elemente als vordefinierte Gruppen ausgeblendet (vgl. Abbildung 7-2). So sind auf einfache und schnelle Weise eine große Anzahl von Schäden simulierbar.

4 Ergebnisse und Diskussion

Die Präsentation der Ergebnisse erfolgt in Anlehnung an die in Abbildung 3-2 gezeigte, schematische Struktur. Dabei werden zunächst die vom Getränkekasten ausgeführten Schwingungen numerisch simuliert (vgl. Abschnitt 4.1). Im Vergleich mit experimentellen Daten findet die Validierung des Modells statt. Außerdem werden die so gewonnenen Erkenntnisse über das Verhalten des Systems genutzt, um im Hinblick auf einen experimentellen Versuchsstand Hinweise zur Unterstützung der Konstruktion zu erhalten und geeignete Versuchskonfigurationen zu erzielen.

Bei der methodischen Entwicklung steht der Nachweis der Reproduzierbarkeit und der Unterscheidbarkeit der verschiedenen Spektren an erster Stelle. Demgemäß widmet sich Abschnitt 4.2.1 diesem Thema. Abschnitt 4.2.2 präsentiert indessen Spektren, welche die Spannweite der möglichen Schadensfälle aufzeigen.

Anhand der zum Einsatz kommenden KNN wird das Klassifizierungsverhalten der experimentell ermittelten Schwingungsspektren an Modell-Schadensfällen aufgezeigt (vgl. Abschnitt 4.3). Dabei wird eine Klassifizierung in „intakt“ und „defekt“ angestrebt. Die Auswirkungen der Netzwerkgröße sowie der Datenvorverarbeitung auf die Approximationseigenschaften des KNN finden in Abschnitt 4.3.2 und 4.3.3 Berücksichtigung. Exemplarisch stellt Abschnitt 4.3.4 eine verfeinerte Ausgabe vor, die weitere Klassifizierungsmerkmale repräsentiert.

Abschnitt 4.4 bespricht abschließend die Verwendung numerischer Datensätze zum neuronumerischen KNN-Training. Zum Einsatz kommen sowohl Datensätze gemischter Herkunft als auch Datensätze rein numerischer Herkunft. Mit Hilfe von Modifikationen am Netzwerk sowie der zuvor gewonnenen Erkenntnisse wird die automatische Schadenserkenkung mittels Neuronumerik realisiert.

4.1 Numerische Simulation der Schwingungen eines Getränkekastens

Die Erörterung der Basiserkenntnisse geschieht anhand der Vorstellung der Eigenmoden des Getränkekastenmodells. Es werden hieraus Schlussfolgerungen, auf für die Anwendung geeignete, Orte zur Signalbeobachtung gezogen sowie Hinweise zum Aufbau eines experimentellen Versuchsstandes erarbeitet. Letzterer trägt wiederum zur Validierung der numerischen Ergebnisse bei. Alle Ergebnisse sind, falls nicht anders ausgewiesen, mit den Materialparametern gemäß Tabelle 3-1 bere-

chnet. Tabelle 7-3 listet die eingesetzten numerischen Modell-Schadensfälle N1 bis N17 auf und Abbildung 3-10 erläutert die betrachteten Sensorpositionen 0 bis 6.

4.1.1 Eigenmoden

Zum grundlegenden Verständnis der möglichen und vor allem der für die Anwendung im Sinne der vorliegenden Arbeit bedeutenden Bewegungsformen erfolgt zu Beginn die Berechnung der ersten Eigenformen des eingesetzten, zentral am Boden fixierten, Getränkekastens. Abbildung 4-1 illustriert eine Auswahl der in diesem Fall von 0 Hz bis 1000 Hz berechneten 200 Eigenformen. Dabei handelt es sich um die ersten Eigenformen von Griff und Seitenwänden. Um die Schwingungsformen zu verdeutlichen, ist dabei jeweils das Gitter des unverformten Kastens unterlegt, das die Ruheposition wiedergibt. Die Form der möglichen Verschiebung ist anhand von Farb-abstufungen dargestellt. Die dimensionslose Auftragung der Eigenvektoren in Abbildung 4-1 bis Abbildung 4-4 aus der Modalanalyse beruht auf der Normierung der Amplituden zur generalisierten Masse $m_j = 1$ (vgl. Abschnitt 2.2.2).

Aus Gründen der Zweckmäßigkeit werden hier lediglich die für das System interessanten Eigenmoden präsentiert, die aufgrund ihrer Verschiebungs- bzw. Beschleunigungsamplitude in den weiter unten berechneten Frequenz-Antwort-Spektren in Erscheinung treten. Grundsätzlich ist die Zahl der bestimmbareren Eigenmoden eines Modells so groß wie dessen Anzahl von Freiheitsgraden einschließlich aller Translations-, Rotations- und Festkörperbewegungen. Der größte Teil dieser Moden tritt nicht messbar in Erscheinung, da diese aufgrund ihrer Richtung und Stärke vernachlässigbar sind.

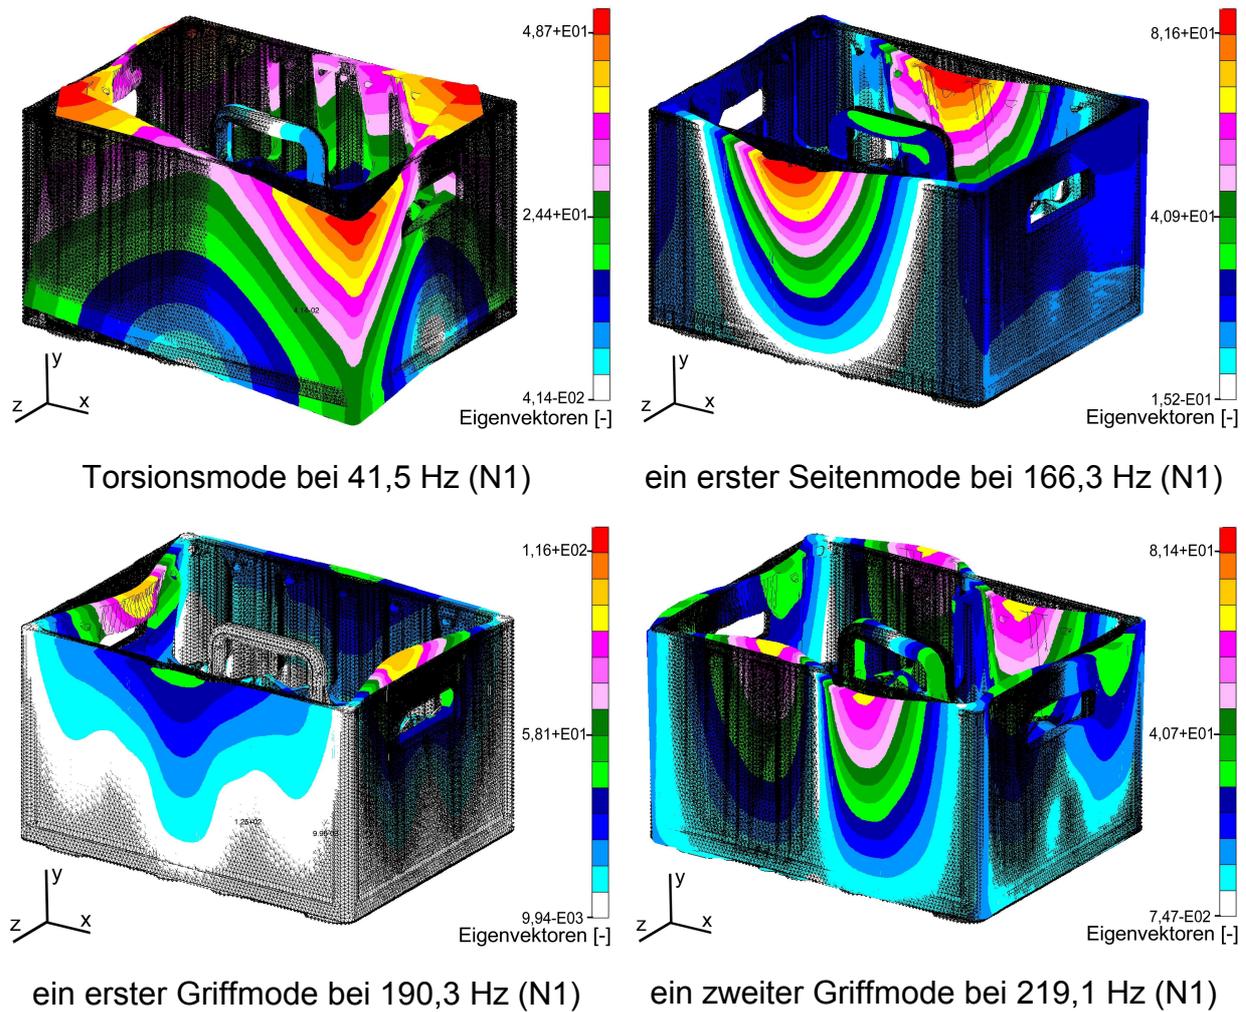


Abbildung 4-1: Auswahl von Eigenformen des intakten Getränkekastens (N1); berechnet mit Hilfe numerischer Modalanalyse auf Basis der FEM

In Abbildung 4-1 ist außerdem gut erkennbar, wie beispielsweise in der Griffregion zuerst der einfache und in einem nachfolgenden Mode ein zweifacher Schwingungsbauch erscheint. In weiteren, nachfolgenden Moden bilden sich dreifache, vierfache und weitere, mehrfache Bäuche aus (bzw. zwei Knotenpunkte, drei Knotenpunkte, etc.). Diese sind hier nicht mehr illustriert. Auch kann ein Schwingen dieser Bäuche in gleicher und entgegengesetzter Richtung beobachtet werden. Ebenso findet man bei höheren Frequenzen Überlagerungen aller dieser Formen. Ähnliche Bewegungen zeigen auch die Seitenwände sowie einzelne Bauteilabschnitte, wie die Gefache, der Mittelgriff und in einigen Bereichen auch der Boden (vgl. Abbildung 4-2).

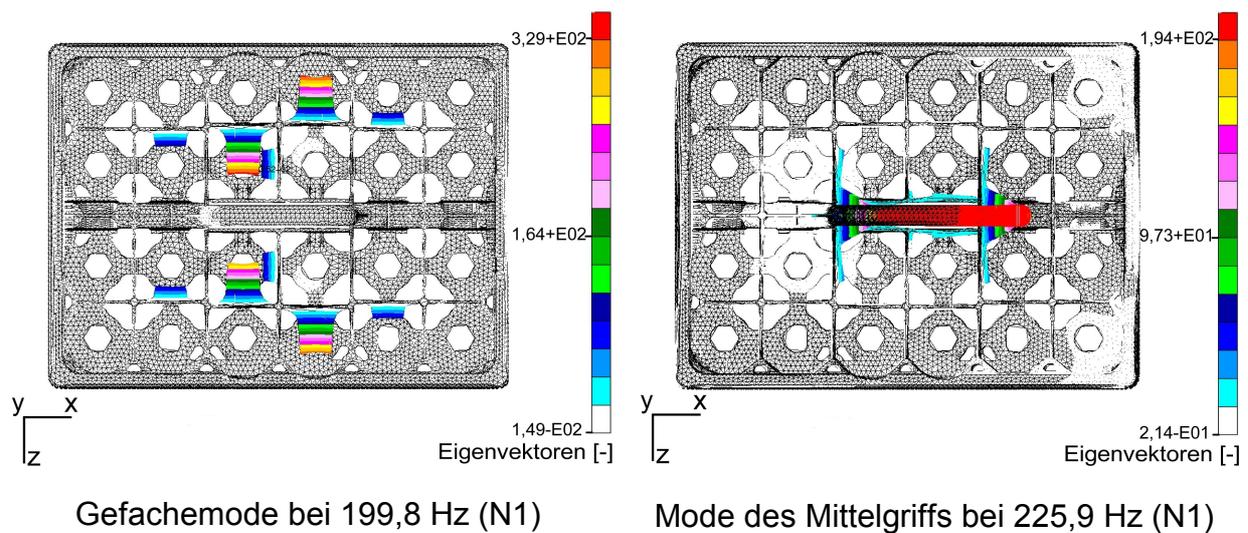


Abbildung 4-2: Auswahl eines Gefachemodes und eines Mittelgriffmodes in der Draufsicht des intakten Getränkekastens (N1); berechnet mit Hilfe numerischer Modalanalyse auf Basis der FEM

Besonders die Vielzahl von Gefachemoden (hier nicht illustriert) verdeutlicht, dass die einzelnen Gefacheabschnitte einzeln oder gleichzeitig in die gleiche oder entgegengesetzte Richtung sowie in Torsion schwingend auftreten können. Mit steigender Frequenz werden die Wellenlängen kleiner und somit steigt die Zahl der Schwingungsknoten je Bauteil. Die meisten dieser Moden haben zwar nur geringe Auswirkung auf die Bewegung des Gesamtkastens, sind aber bei Frequenzmessungen durchaus detektierbar, wie nachfolgend gezeigt wird.

Sämtliche Moden können in den weiter unten beschriebenen Frequenzspektren als Peak wiedergefunden werden (vgl. Abschnitt 4.1.2). Sie treten dort als Linearkombinationen der einzelnen Eigenformen in unterschiedlichen Amplituden auf, wobei Schwingungsbäuche größere Amplituden als Knotenpunkte aufweisen. Ihre Bedeutung innerhalb des Spektrums am jeweiligen Messort und die sich daraus für einen experimentellen Versuchsstand ergebenden Folgerungen erläutert Abschnitt 4.1.4.

Den grundlegenden Einsatz der Schwingungsanalyse verdeutlicht nachfolgend Abbildung 4-3 am Beispiel einer Eigenform eines für die spätere Klassifikation wichtigen Schadensfalls. Dabei wird eine vergleichbare Schwingungsform des intakten (N1) und des defekten (Griffriß N7) Kastens abgebildet. Zusätzlich zu den Eigenmoden des jeweiligen Schadens treten die Moden auf, die der intakte Kasten aufweist. Die Überlagerung des Schadens und die daraus resultierende Asymmetrie im Gesamtkörper bedingen eine geringfügige Verschiebung im Frequenzband. Außerdem verdeutlichen bereits hier die unterschiedlichen Formen in den beiden

Griffregionen die voneinander abweichenden Frequenzspektren der Antwortsignale von Schadensfällen, die in Abschnitt 4.1.2 diskutiert werden.

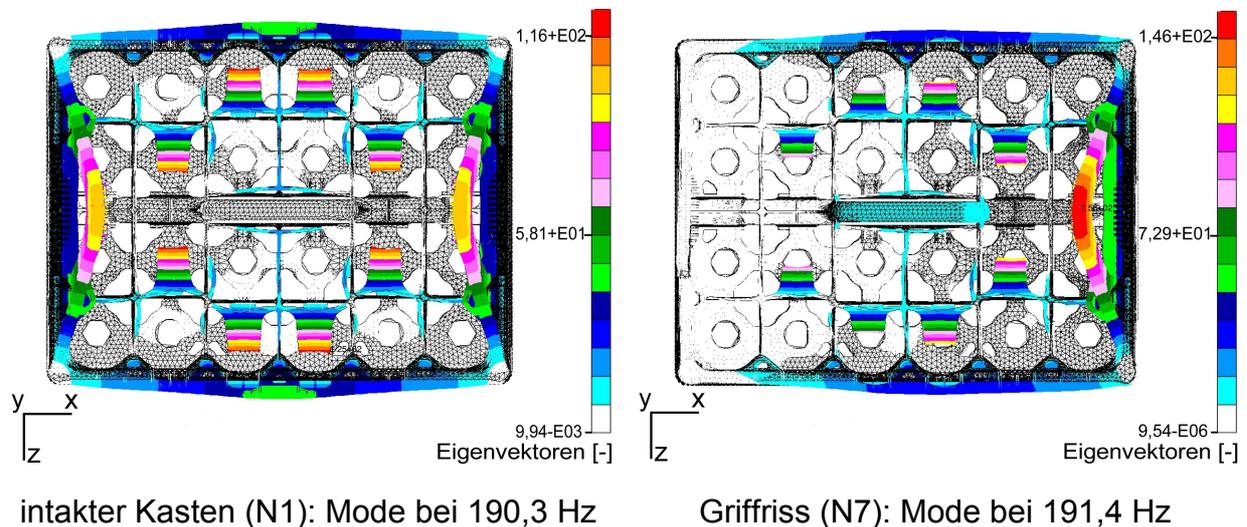


Abbildung 4-3: Vergleich der Schwingungsform des intakten Kastens (N1) zur Schwingungsform des Schadensfalls (N7 – defekter Griff, LS) bei vergleichbarer Frequenz in der Draufsicht; berechnet mit Hilfe numerischer Modalanalyse auf Basis der FEM

Außerdem treten auch Eigenformen bei Frequenzen auf, in denen der intakte Kasten keine Antworten zeigt. Auch dies führt zum Auftreten von Systemantworten, die für jeden Schaden Unterschiede aufweisen. Überhöhte Peaks in den jeweiligen Spektren geeigneter Messorte verkörpern dies. Auch zeigen sich beim Vergleich der Spektren der Sensorposition am Griff zwei Hauptregionen besonders starker Amplituden. Der nachfolgender Abschnitt 4.1.2 beschreibt diese näher.

Als weiteres Beispiel zeigt Abbildung 4-4 Griffmoden eines defekten Griffs (N7, linke Seite) sowie die Eigenform einer defekten Seite (N5, obere lange Seite) deren Eigenfrequenzen zu der vergleichbarer Eigenformen des intakten Kastens stark verschoben sind.

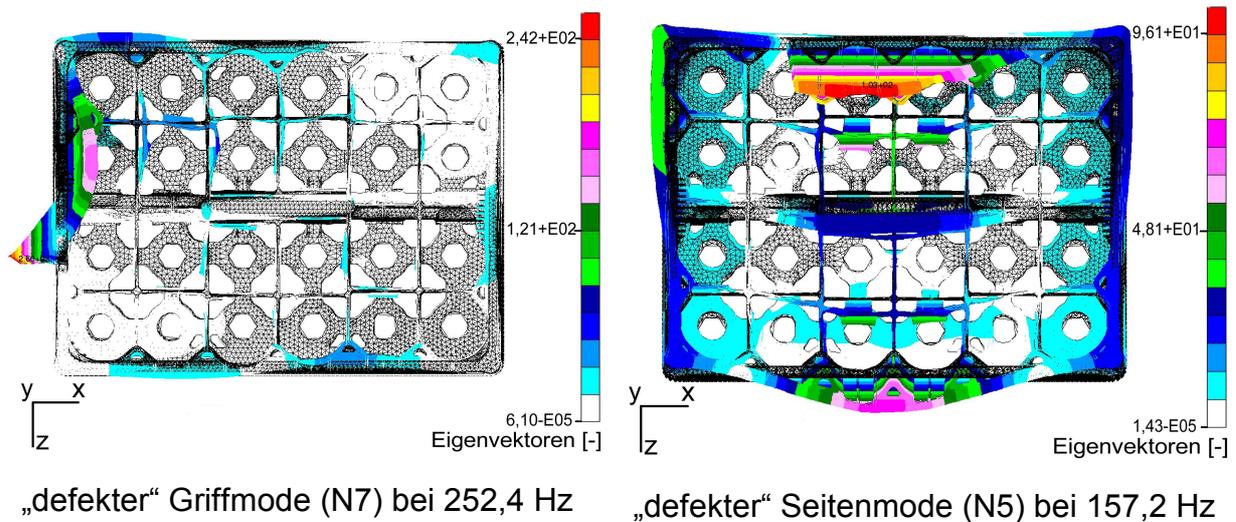


Abbildung 4-4: Weitere Beispiele für Eigenformen: defekter Griff (N7, linke Seite) und defekte Seite (N5, Riss obere lange Seite) in der Draufsicht; berechnet mit Hilfe numerischer Modalanalyse auf Basis der FEM

Es gilt darüber hinaus anzumerken, dass die hier dargestellten Eigenformen mit der NASTRAN-Lösungssequenz SOL103 berechnet sind, welche die Dämpfung im System nicht berücksichtigt. Zur Diskussion und zum Verständnis der Bedeutung der Eigenmoden für den Aufbau der Versuchsanlage erweist sie sich als geeignet. Um der Notwendigkeit der Berücksichtigung der Dämpfung innerhalb eines Festkörpers gerecht zu werden, wird nachfolgend zur Berechnung der Frequenz-Antwort-Spektren mit der Lösungssequenz SOL111 gearbeitet.

4.1.2 Frequenzspektren

Die Begründung der Existenz unterschiedlicher Frequenz-Antwort-Spektren lieferte der vorangegangene Abschnitt. Nachfolgend wird nun erörtert, wie sich die Eigenmoden im Frequenzspektrum der numerischen Simulation der Frequenzantwort mit NASTRAN-Lösungssequenz SOL111 auswirken. Die Diskussion des Zusammenhangs von Moden und ihrer Peaks erbringt die Grundlage zum Aufbau des experimentellen Versuches, der sich für die neuronumerische Mustererkennung von Schäden an Getränkekästen eignet. Dabei zeigen numerisch simulierte Spektren auf, wo sich der für das geplante Detektionssystem aussagekräftigste, sensitivste Messort befindet. Im Hinblick auf industrielle Flaschenabfüllanlagen (Querlauf ermöglicht größeren Durchsatz) wird nachfolgend die schmale Seite des Getränkekastens als bevorzugter Messort betrachtet. Abbildung 4-5 und Abbildung 4-6 verdeutlichen die Sensitivität anhand jeweils dreier Messpunkte entlang der Mess-

linien A (Punkte 2, 3 und 4) und M (Punkte 4, 5 und 6) aus Abbildung 3-10. Aufgetragen ist dabei immer die Hauptbewegungsrichtung des Bauteilabschnitts.

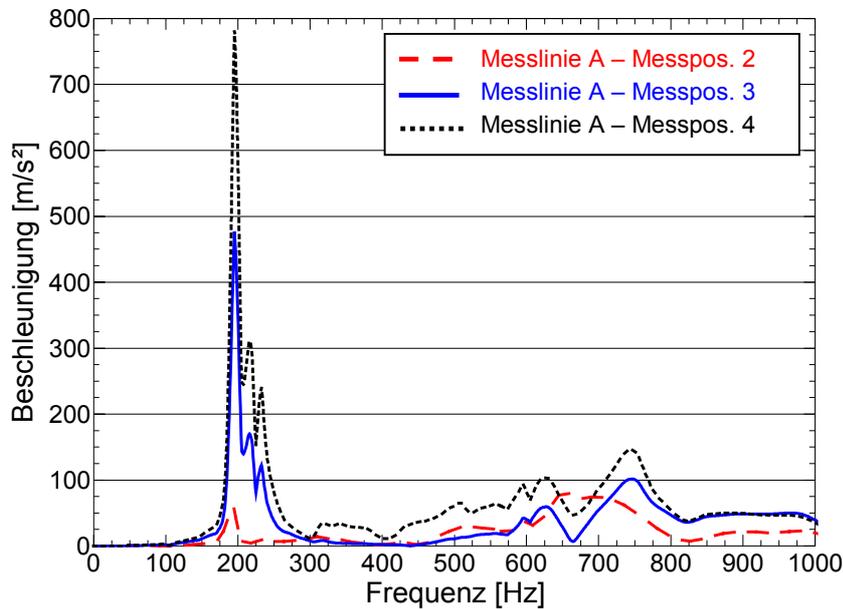


Abbildung 4-5: Intensität der Spektren der Messpunkte 2, 3 und 4 entlang der Messlinie A am Griff (vgl. auch Abbildung 3-10) für den „intakten“ Fall (N1)

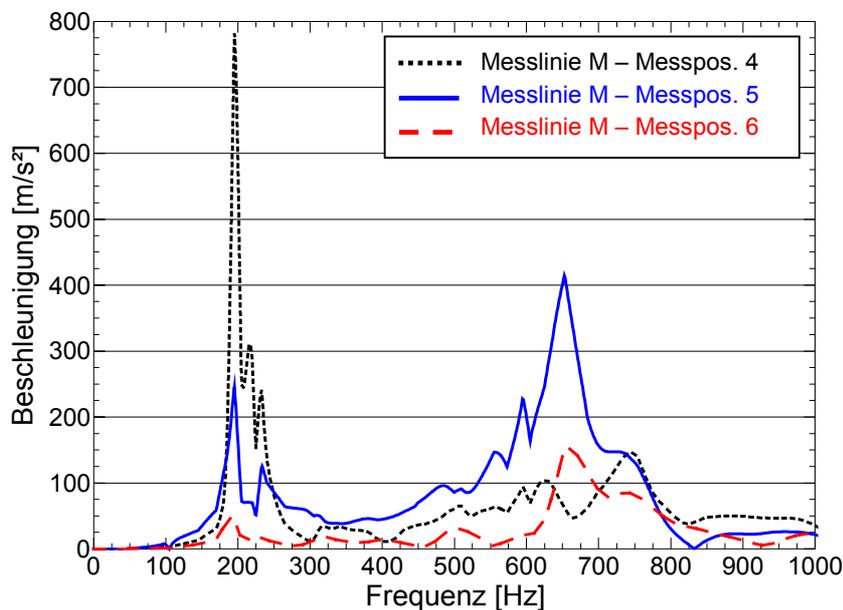


Abbildung 4-6: Intensität der Spektren der Messpunkte 4, 5 und 6 entlang der Messlinie M der schmalen Seite (vgl. auch Abbildung 3-10) für den „intakten“ Fall (N1)

Der Frequenzabschnitt von 170 bis 260 Hz zeigt jeweils einen deutlichen Peak, der jeweils für die Messposition 4 am stärksten ausgeprägt ist. Dies zeichnet die beiden Griffe an den schmalen Seiten (Pos. 4 und aus Symmetriegründen auch Pos. 1) als besonders sensitive Regionen des Kastens aus. Auch Position 5, Seitenmitte (vgl.

Abbildung 4-6), erscheint als sensibler Messort aufgrund des hohen Peaks bei 600 bis 700 Hz. Seine Betrachtung erfolgt zwar unten im KNN, er kommt jedoch nur optional für zusätzliche Sensoren in Betracht, da ein Schaden dieser Seite unwahrscheinlich ist. Diese konstruktionsbedingte Erkenntnis basiert auf Verordnungen und Konstruktionshinweisen zur Stapel- und Gebrauchsfähigkeit von Getränkekrästen des freien Handels. Gemäß diesen sind Ecken und Kanten der Kräfte besonders versteift und somit im intakten Zustand schwingungsarm. Dies untermauert die Auswahl des auch aus anlagen- und messtechnischen Gesichtspunkten als besonders günstig betrachteten Messortes am Griff (Pos. 1 und 4). Es werden daher im Weiteren ausschließlich diese Positionen betrachtet.

Ausgehend von den für die Simulation eingesetzten Materialparametern (vgl. Tabelle 3-1) zeigt Abbildung 4-7, dass geringfügige Abweichungen um je $\pm 2,5\%$ bei E-Modul und Dämpfung nur geringfügige Verschiebungen der Spektren hervorrufen. Abbildung 4-7 zeigt auch, dass Materialschwankungen in dieser Größenordnung erst bei höheren Frequenzen in der Frequenzantwort erscheinen. Am deutlichsten zu erkennen ist dies jeweils zwischen 600 und 800 Hz. Ein veränderter E-Modul verschiebt dort die Peaks entlang der Frequenzachse, eine variierte Dämpfung beeinflusst die Höhe der Peaks.

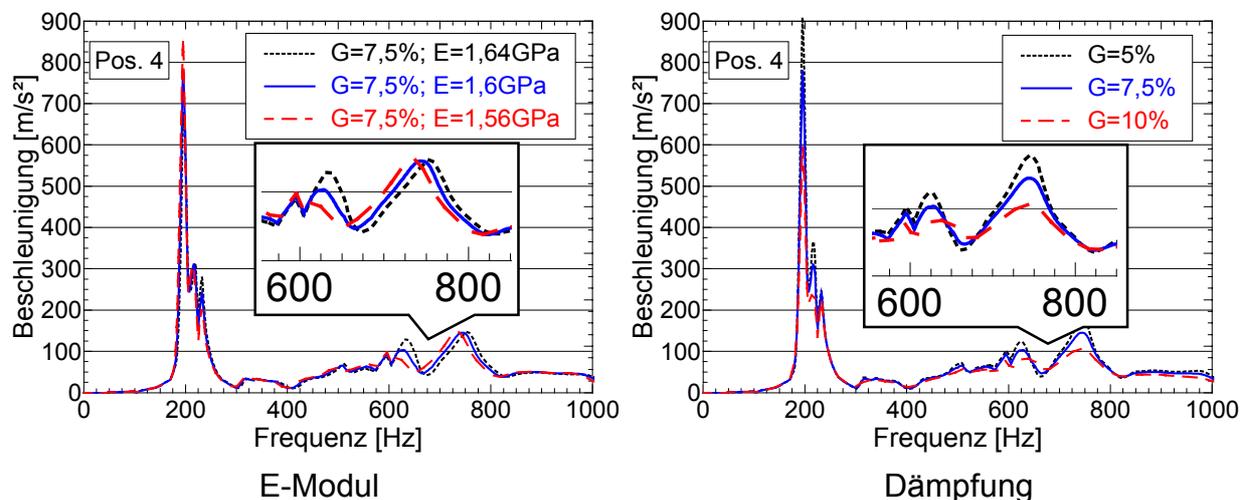


Abbildung 4-7: Sensitivität der Spektren hinsichtlich der Materialparameter E-Modul und Dämpfung, ausgehend von den Parametern nach Tabelle 3-1 für den „intakten“ Fall (N1)

Im Gegensatz zur Sensitivität des Modells hinsichtlich seiner Materialparameter zeigt die Auswahl der Sensorposition, d. h. des Messortes, einen erheblich größeren Einfluss auf das Frequenzspektrum. Dies verdeutlicht die Gegenüberstellung zweier Messpunkte, deren Messort symmetrisch zum Kastenmittelpunkt angeordnet ist (vgl.

Abbildung 4-8). Die dortigen Antwortsignale sind im Idealfall, d. h. bei exakt symmetrischer Positionierung und intaktem Kasten oder einem zu den Messorten symmetrischen Schadensfall, identisch. Für die Simulation bedeutet das eine in idealer Weise exakt symmetrische Vermaschung, welche mit Tetraederelementen allerdings nicht möglich ist. So sind, wie auch in allen anderen Fällen, Abweichungen der Spektren voneinander zu erwarten. Dies ist in Abbildung 4-8 aus dem Vergleich der Positionen 1 und 4 für den „intakten“ Fall (N1) bei 600 bis 800 Hz ersichtlich. Außerdem zeigt der Vergleich der Antwortspektren des Griffschadens (N7, Pos. 1 und 4) deutlich die Sensitivität des Messortes für diesen Schadensfall auf. Insbesondere der Peak von 180 bis 210 Hz erscheint im Spektrum des Sensors auf der Seite des Griffschadens nicht. Abbildung 4-3 verdeutlicht dies unter anderem an einer Eigenform dieses Griffschadens.

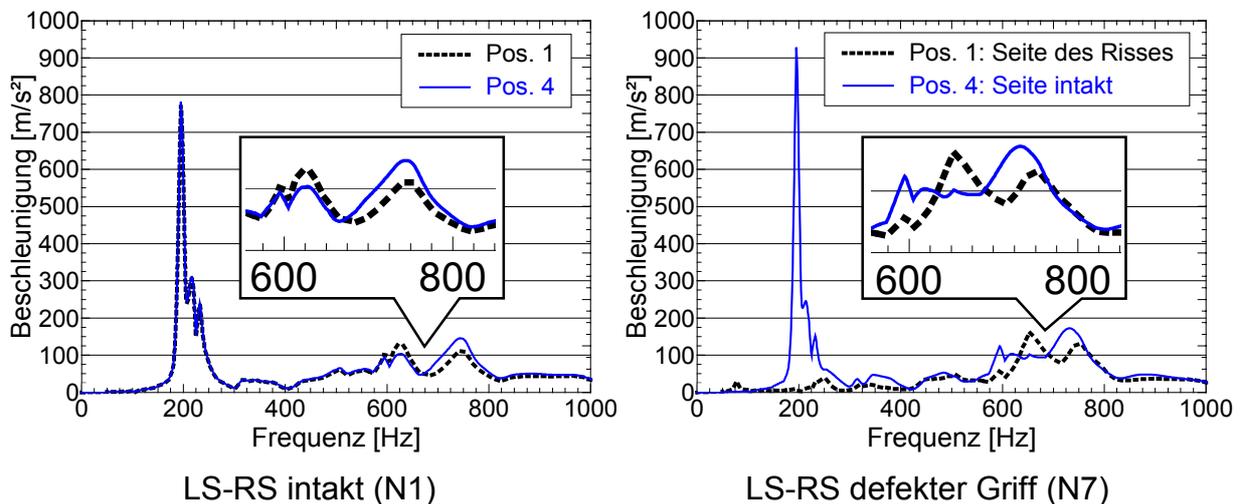


Abbildung 4-8: Gegenüberstellung der Spektren der symmetrischen Messorte (linke Seite (LS) und rechte Seite (RS)) am Griff (Messpunkt 1 und 4 nach Abbildung 3-10) für den „intakten“ Fall (N1) und den Schadensfall defekter Griff (N7); (Materialparameter nach Tabelle 3-1)

Die Abweichung des Spektrums des intakten Getränkekastens (N1) bei 600 bis 800 Hz (linker Graph von Abbildung 4-8) liegt in der Größenordnung der aufgetragenen geringfügigen Parameterschwankungen (vgl. Abbildung 4-7). Im Vergleich mit Abbildung 4-8 fällt besonders auf, dass die Abweichung im Spektrum des Griffschadens N7 (rechter Graph) erheblich größer ist. Dies unterstreicht die besonders geeignete Festlegung der beiden Positionen zur Detektion von weiteren Schadensfällen. Abschnitt 4.2.2 veranschaulicht dies auch anhand experimentell aufgenommener Spektren. Besonders im Hinblick auf die späteren Klassifizierungen durch KNN bei der Betrachtung von Uni- und Dual-Sensorsystemen und bei Anwendung des neuronumerischen Trainings erlangt diese Erkenntnis Bedeutung.

4.1.3 Validierung - Vergleiche der numerischen mit experimentellen Ergebnissen

Die Validierung des numerischen Systems hängt einerseits eng zusammen mit der Erarbeitung von experimentell reproduzierbaren Signalen (vgl. Abschnitt 4.2.1). Andererseits hat die Ausgestaltung der numerischen Simulation an sich eine hohe Bedeutung für die Güte ihrer Ergebnisse. In diesem Zusammenhang spielt die Auswahl und Feinheit der Gitterstruktur und der Elementtypen eine wichtige Rolle. Im Rahmen der Arbeit erfolgte die Vermaschung der Hersteller-CAD mit Tetraederelementen. Abbildung 4-9 zeigt Ergebnisse der Berechnung mit vier- (TET4) und zehn-knotigen (TET10) Elementen.

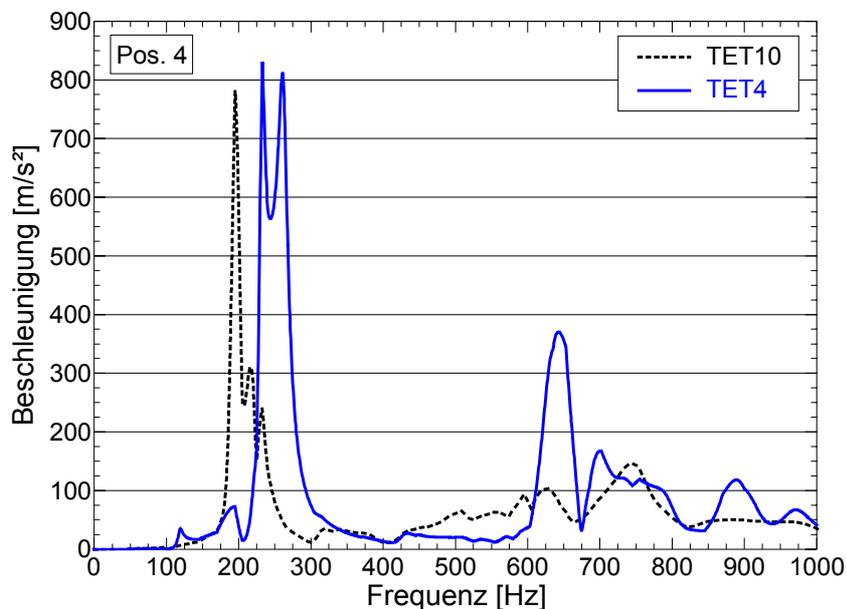


Abbildung 4-9: Vergleich numerisch simulierter Frequenzspektren einer mit Tetraederelementen (TET4 und TET10) vermaschten Getränkekasten-CAD der Position 4 für den intakten Kasten (N1); (Materialparameter nach Tabelle 3-1, Vermaschung nach Tabelle 3-8)

In jedem Spektrum sind die Hauptpeaks erkennbar. Es wird jedoch deutlich, dass deren Ausprägung an den verschiedenen Positionen sehr unterschiedlich ist. Ein Vergleich mit dem experimentellen Spektrum untermauert die bessere Eignung des zehn-knotigen (TET10) Elements. In Anbetracht der Komplexität der Geometrie des Modells liefern TET10-Elemente eine annehmbare Übereinstimmung, wie Abbildung 4-10 verdeutlicht.

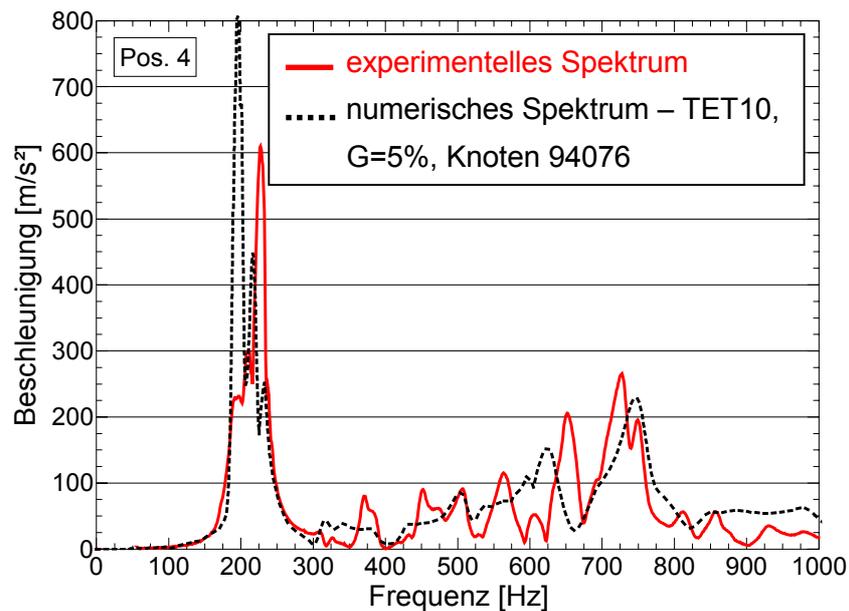


Abbildung 4-10: Vergleich des mit TET10 vermaschten numerischen mit dem zur Validierung herangezogenen experimentellem Spektrum (Position 4 für den intakten Kasten (N1); Materialparameter nach Tabelle 3-1, Vermaschung nach Tabelle 3-8)

Es ist ersichtlich, dass je nach Grad der Vereinfachung (d. h. TET10 bzw. TET4) im Modell eine bessere oder schlechtere Annäherung an den realen Fall erreicht wird. Die Haupttendenzen sind jedoch in allen Modellen vorhanden.

Die ortsgebundene Messpunktauswahl (in der Numerik ist das der jeweilige beobachtete Knoten) spielt dabei eine wichtige Rolle. Das bedeutet im Hinblick auf die experimentelle Positionierung des Sensors, dass schon eine kleine räumliche Verschiebung einen Effekt auf das zu erwartende Spektrum hat. Dieser Effekt findet sich auch in der numerischen Simulation bei der Betrachtung benachbarter Element-Knotenpunkte wieder. Abbildung 4-11 dokumentiert die Sensitivität der numerischen Simulation bei geringfügigem Verschieben des Beobachtungsknotens. Geringfügiges Verschieben bedeutet dabei eine horizontale oder vertikale Verschiebung auf der Getränkekastenoberfläche um 1 bzw. 2 finite Elemente. Bei einer maximalen Kantenlänge der TET10 von ca. 4 mm entspricht das einem Versatz von bis zu 4 mm je Element im CAD-Modell.

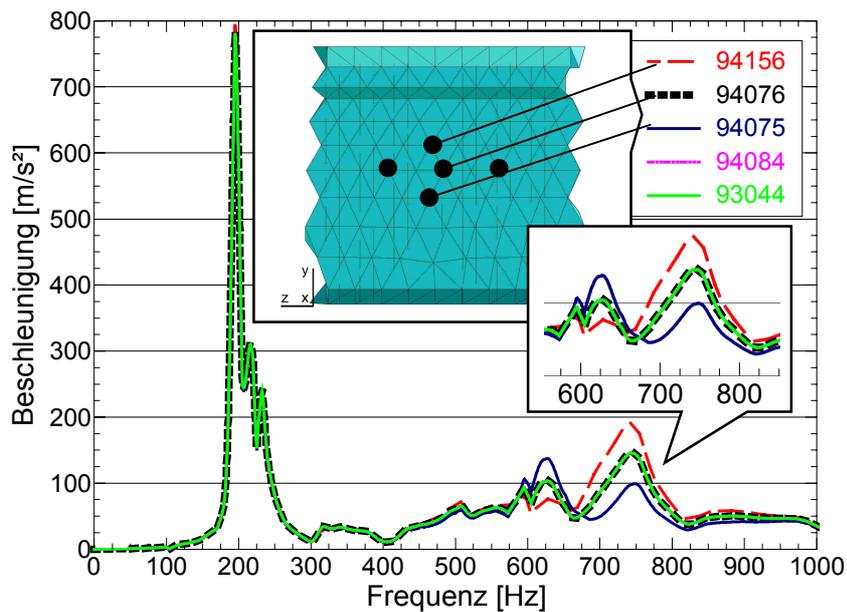


Abbildung 4-11: Sensitivität gegenüber einer Verschiebung des Messortes an Pos. 4 des Griffes (N1); Vergleich von Frequenz-Antwort-Spektren benachbarter Elementknoten des mit TET10 vermaschten Getränkekastens anhand drei horizontal angeordneter Knoten (94084, 94076 und 93044) und drei vertikal angeordneten Knoten (94156, 94076 und 94075); (Materialparameter nach Tabelle 3-1)

Diese Kurven verdeutlichen die Sensitivität jedes Messortes, wobei eine Verschiebung von links nach rechts (Knoten 94084, 94076 und 93044) nicht empfindlich ist. Die Spektren dieser horizontal angeordneten Knoten liegen in der Abbildung 4-11 übereinander. Die Frequenzantworten der vertikal angeordneten Knoten (94156, 94076 und 94075) dagegen zeigen besonders zwischen 600 und 800 Hz deutliche Höhenunterschiede der Peaks. Sie weisen die Größenordnung der Abweichungen der Spektren am experimentellen Messort auf, treten im Vergleich zu den experimentellen, am Versuchsstand aufgenommenen Spektren jedoch nur im hinteren Teil des Spektrums in Erscheinung (vgl. auch Abbildung 4-13). Experimentell wird dies bereits durch die Größe der Auflagefläche des Sensors von 1 cm^2 verursacht. Er liefert so allerdings einen Mittelwert im Vergleich zu den numerisch einzeln berechneten, exakten Antworten.

Die Validierung des Systems gilt somit zu diesem Zeitpunkt als abgeschlossen, obwohl noch eine Vielzahl möglicher Abweichungen vorliegen. Es wird zur Kenntnis genommen, dass diese teilweise durch die vorgenommenen Vereinfachungen verursacht wurden, zu denen am wichtigsten die Vermaschung zählt. Da insbesondere im Vergleich dazu experimentell Abweichungen auch durch unexakte

Platzierung, sowohl des Sensors als auch des Prüflings auf der Halterung, entstehen können, wird der Fehler hingenommen und in Abschnitt 4.4 anhand der Qualität der neuronumerischen Klassifizierung nochmals beurteilt. Dort wird der Fehler nicht mehr als akzeptabel beurteilt, wenn das KNN keine Zuordnung mehr treffen kann.

4.1.4 Folgerungen zur Konstruktion eines Versuchsstandes

Die in den vorangegangenen Abschnitten beschriebenen, numerischen Ergebnisse stellen im Hinblick auf die Praktikabilität der zu betrachtenden Messpunkte eine Auswahl dar, die die Anforderungen industrieller Fördermittel berücksichtigt. Dort ist der Griff ein prädestinierter Messort, da sich die Kästen am Laufband bereits so ausgerichtet bewegen, dass der Messort gut zugänglich ist und keine spezielle Positionierung vorgenommen werden muss.

Abbildung 4-1 liefert hierzu eine weitere Begründung. Eigenformen stellen immer von der jeweiligen Struktur begünstigte Bewegungszustände dar. Daher ist mit Hilfe jeder einzelnen Eigenform ein gesonderter Einblick in das strukturspezifische Verhalten möglich. Das ermöglicht, visuell anhand der Schwingungsbilder, den Schluss auf günstige Messorte zur Positionierung von Sensoren. Jeweils bezogen auf die aktuelle Frequenz eines Eigenmodes hat die Positionierung auf einem Schwingungsbauch hohe Beschleunigungspeaks in Bewegungsrichtung zur Folge. Die Positionierung in Schwingungsknoten bewirkt dagegen kleine bis keine Peaks. Somit wird die Sensitivität von Messpositionen interpretierbar. Die Betrachtung der Spektren in Abbildung 4-8 und der Griffmoden von Abbildung 4-1 zeigt, dass die in dieser Bauteilregion aufeinanderfolgenden Eigenmoden an der Sensorposition bei etwa 190 Hz (Griffmode 1) ein angehendes Maximum im Spektrum bewirken, das bei 219 Hz (Griffmode 2) wieder stark abnimmt. Natürlich sind hierzu nicht nur die Moden des Griffs zu berücksichtigen. Sie verdeutlichen lediglich anhand des hier besprochenen Beispiels, warum manche Moden im Spektrum eines Messorts besonders gut und andere weniger sichtbar werden. Auch besondere, konstruktive Versteifungen im Modell, besonders an Ecken und Kanten, setzen die Sensitivität dieser Stellen und damit ihre Eignung als mögliche Sensorposition herab.

Im Hinblick auf die Funktionalität des experimentellen Versuchsstands im Labor spielt die diskutierte Sensorpositionierung eine Nebenrolle. Dennoch wird dieser Messort beibehalten und ein möglichst praxisnaher Aufbau des Laborversuchsstandes angestrebt. Daher stehen besonders die Befestigungsarten der Getränkekästen und die Durchführung geeigneter Testprogramme im Vordergrund des Interesses. Ausgehend von den numerischen Ergebnissen, wird für die Pilotanlage

die zentrale Anregung von unten und die damit erzielbare Symmetrie der Moden favorisiert und umgesetzt. Es können so, wie bereits besprochen, vergleichbare Punkte auf beiden Seiten der Kästen geschaffen werden (vgl. Abbildung 4-8).

Aufgrund der zentralen Anregung eignet sich der bereits numerisch eingesetzte Sinussweep besonders, um das Modell zu validieren und den Versuchsstand zu optimieren. Mit einem Sinussweep erreicht man so ein weitgehend freies Schwingen der nacheinander auftretenden Eigenformen, das als eine unverrauschte Signalantwort mittels Sensoren abgreifbar ist. Der Vorteil für die Numerik liegt darin, dass ein derartiges System einfach zu konfigurieren ist. In diesem Kontext stellt ferner die „Frequency-Response-Analyse“ die Vorstufe zur „Random-Analyse“ dar, die in künftigen Weiterentwicklungen zum Einsatz kommen wird. Es ist somit zweckmäßig, das Modell mittels Frequenzsweeps zu validieren und deren Frequenzspektrien weiter zur Mustererkennung zu verwenden. Auch zeigte sich, dass die Annahme elastischen Materialverhaltens Gültigkeit besitzt, ebenso wie die Vermaschung mit Tetraederelementen beibehalten werden kann, da mit dem erstellten numerischen Modell eine hinreichend genaue Übereinstimmung mit der experimentellen Versuchsanlage erzielt wird (vgl. Abbildung 4-10). Inwieweit diese Übereinstimmung für die Mustererkennung mittels KNN geeignet ist, diskutiert Abschnitt 4.4.

Als weitere Anmerkung illustriert Abbildung 4-12 die Verformung des Kastenbodens an der Befestigung des Kastens (vgl. Abbildung 3-7). Sie tritt in Richtung der aufgezwungenen Kraft („Enforced Motion“) auf das Modell und auch den realen Getränkekasten auf. Die numerische Simulation liefert dazu eine Eigenform in Anregungsrichtung bei 100,4 Hz. Sie verdeutlicht die bereits diskutierte, nur schwer erreichbare Abkopplung der Eigenschwingungen des Prüflings von der Anregung des System (vgl. Abschnitt 3.3.2), die sich so auch im Spektrum des Steuersensors wiederfindet (vgl. Abbildung 3-11).

In y-Richtung tritt dabei eine deutliche Resonanz auf. Sie wird als deutliche Verformung des Randes zu den fixierten Elementen sichtbar (vgl. Abbildung 4-12), welche die Halterung simulieren. Diese Region ergibt im Experiment die meisten Probleme, weil das Getränkekastenmaterial bei unsachgemäßer Positionierung sowie übermäßiger Krafteinwirkung Schäden davon tragen kann. Dennoch empfiehlt es sich, die Fixierung in dieser Form beizubehalten, da sie das oben beschriebene, symmetrische Schwingungsverhalten begünstigt.

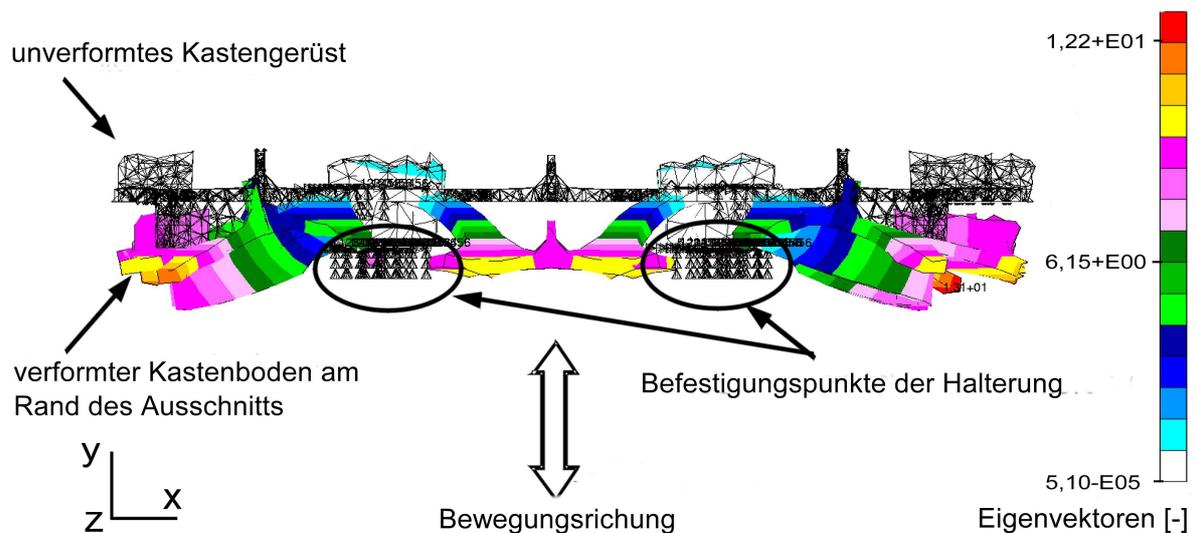


Abbildung 4-12: Ausschnitt der Eigenform bei 100,4 Hz: Deutliche Ausprägung der Verformung an der Befestigung des Kastenbodens in der Bewegungsrichtung der Anregung (y-Richtung); Befestigungspunkte der Halterung entsprechend (Abbildung 3-7); Auftragung der dimensionslosen Eigenvektoren, die zur generalisierten Masse ($m_j = 1$) normiert sind.

Als weiterer Nebeneffekt wird durch diese Bewegung das System auch auf die Gefache sensibilisiert. Gerade Schäden in den Gefachen (Risse, fehlende Bauteile) verursachen eine starke Verminderung der Stabilität des inneren Getränkekastengerüsts. Das bedeutet für die Detektion, dass sich insbesondere diese Schäden durch die Anregung auf die Signalübertragung im Prüfling abschwächend auswirken und somit am Messort (Griffsensor) im Antwortspektrum als Abweichung erscheinen.

4.2 Experimentelle Ergebnisse der Schwingungstests

Wie in der Numerik gilt es anhand des experimentellen Aufbaus zu zeigen, ob unterschiedliche Spektren für verschiedene Schadensfälle und Getränkekastenmodelle messbar sind. Nur dann können diese auch klassifiziert und im Sinne der Arbeit zur neuronumerischen Schadenserkenkung eingesetzt werden.

Dazu wird zunächst die Reproduzierbarkeit der Versuchseinrichtung diskutiert. Anschließend wird auf die Darstellung einiger Modellschäden eingegangen. Wie bereits im vorangegangenen Abschnitt 4.1 dargelegt, werden nachfolgend die Sensorpositionen 1 und 4 betrachtet (vgl. Abbildung 3-10). Tabelle 7-1 und Tabelle 7-4 führen die experimentell betrachteten Schadensfälle E1 bis E17 auf.

4.2.1 Reproduzierbarkeit

Zur Beschreibung der Reproduzierbarkeit ist besonders der „praxisnahe“, „künstliche“ Fehler der vorgenommenen Wiederholungsmessungen zu betrachten. Eine möglichst exakte Positionierung von Kasten und Sensor erlaubt reproduzierbare Spektren mit einem Messfehler von $\pm 1\%$ (vgl. Abschnitt 3.3.3). Jedoch im Hinblick auf den praxisnahen Einsatz des Systems ist gerade diese exakte Positionierung problematisch, wenn der apparative Aufwand gering gehalten werden soll.

Um dem Rechnung zu tragen und auch um einen „natürlich verrauschten“ Datenpool für das angestrebte KNN-Training zu erhalten, wird hier absichtlich ein „künstlicher“ Fehler erzeugt. Der „künstliche“ Fehler deckt dabei eine ungenaue Sensorpositionierung sowie eine ungenaue Positionierung des Getränkekastens auf der Halterung der Anregung ab. Dies soll sowohl die Problematik von Fertigungstoleranzen der Hersteller abdecken als auch gegenüber einer geringen, zwar im Experiment nicht festgestellten, aber möglichen, nicht vermeidbaren plastischen Verformung, also einer bleibenden Kastenbeschädigung, absichern.

Schließlich wurde eine „künstliche“ Abweichung der Spektren in der Größenordnung von 5 % produziert. D. h., im Mittel weichen die Beschleunigungsamplituden jeder einzelnen Messfrequenz eines Frequenz-Antwort-Spektrums um 5 % von den Amplituden des jeweiligen gemittelten Spektrums eines Messortes ab. Jedoch sind an einigen Peaks Abweichungen der Amplituden von bis zu 50 % möglich. Die in Abbildung 4-13 eingefügten Fehlerbalken veranschaulichen dies mit Beispielen für 200 Hz, 608 Hz und 700 Hz.

Die Fehler einzelner Amplituden der Frequenzen erscheinen auf den ersten Blick sehr groß. Verglichen mit Abbildung 4-11, dem numerischen Gegenstück des „künstlich hervorgerufenen“ Fehlers, erweisen sich die experimentellen Datensätze als anfälliger. Die Abweichungen wachsen bereits bei geringen Störungen des Messvorgangs stärker. Gerade deshalb wird der so produzierte Datenpool akzeptiert und weiter unten dem KNN zugeführt.

Die gewonnene Kurvenschar des intakten Kastens (E1 und E2) - und auch die Kurvenscharen der betrachteten Schadensfälle E3 bis E17 - erlangt dabei besondere Bedeutung zum Testen der Prädiktionsfähigkeit des KNN (vgl. Abschnitt 2.3.4). Dabei ist es notwendig, eine Menge von Mustern zu präsentieren, welche die geforderte Klasse des intakten Kastens repräsentiert. Grenzfälle, wie sie die Frequenzspektren mit den maximalen Abweichungen der obigen Kurven darstellen, spielen dabei eine wichtige Rolle, da sie teilweise Überschneidungen mit einer

anderen Klasse aufweisen. Die Diskussion der Approximationsfähigkeit des zum Einsatz kommenden KNN erfolgt anschließend in den Abschnitten 4.3 und 4.4.

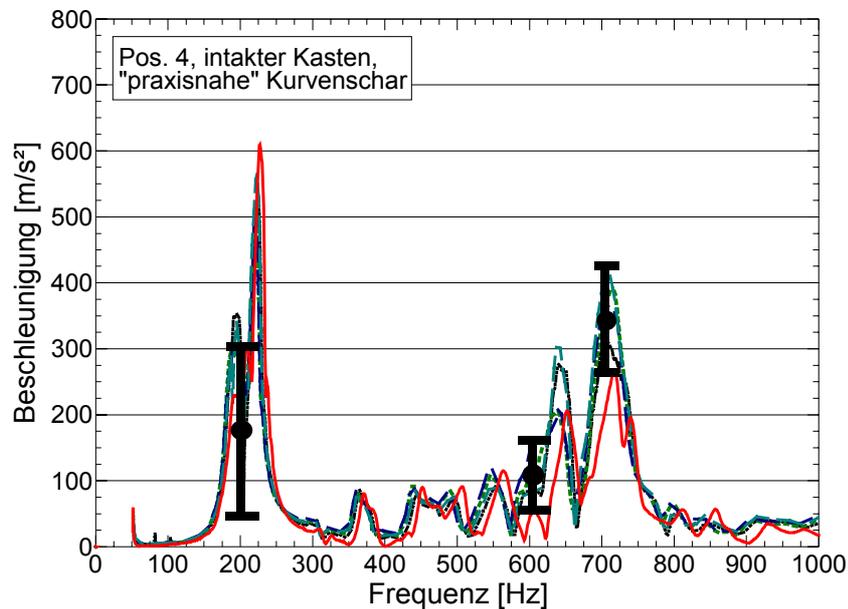


Abbildung 4-13: Kurvenschar von Wiederholungsmessungen an einem Messpunkt unter Berücksichtigung des künstlich erzeugten „praxisnahen“ Fehlers; Fehlerbalken veranschaulichen bei 200 Hz, 608 Hz und 700 Hz maximale Abweichungen. Die Durchschnittliche Abweichung zum gemittelten Spektrum liegt bei 5 %.

4.2.2 Modell-Schadensfälle

Nachfolgend werden Beispiele für weitere, potenzielle Modell-Schadensfallspektren diskutiert. Sie visualisieren einen Auszug der zum Einsatz kommenden Spektren experimentellen Ursprungs (vgl. Schadensfälle E1 bis E17 in Tabelle 7-1 und Tabelle 7-4). Dabei gelten für alle Schäden dieselben Kriterien bezüglich der Reproduzierbarkeit ihres „künstlich“ erzeugten Schadensfallpools (Abbildung 4-13) und hinsichtlich der Sensitivität ihrer Spektren (vgl. Abbildung 4-5 bis Abbildung 4-11). Ein Schaden bedeutet dabei im vorliegenden Anwendungsfall eine veränderte Geometrie. Nachfolgend illustriert Abbildung 4-14 schematisch einen qualitativen Überblick des Schadensfallpools.

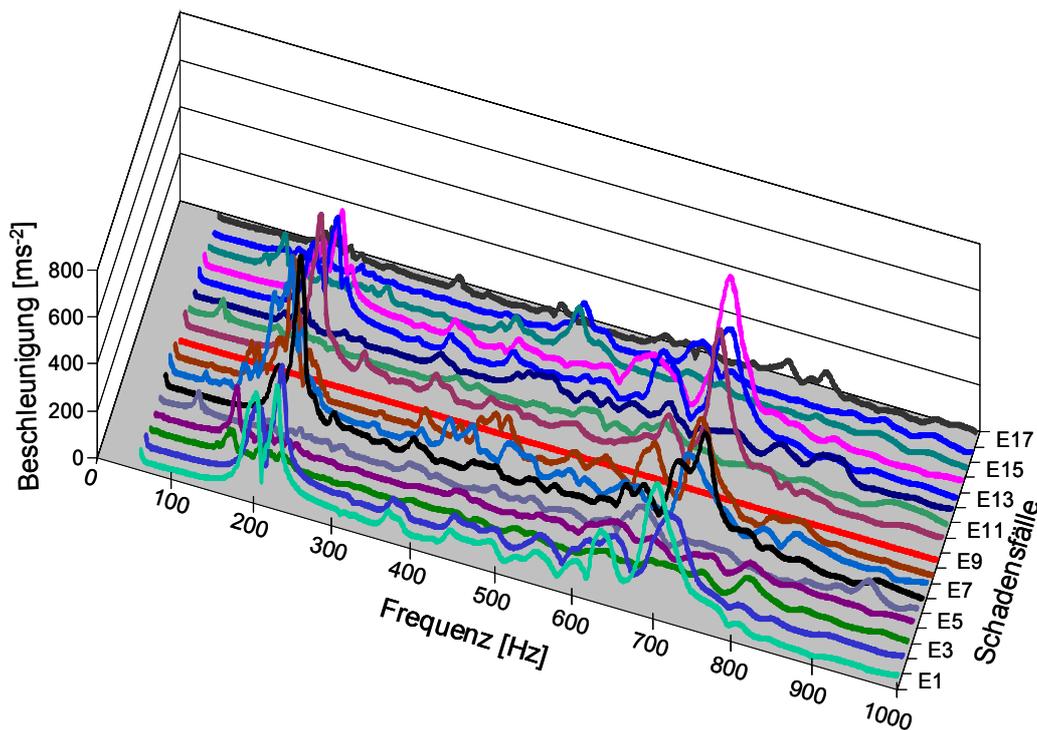


Abbildung 4-14: Qualitativer Ausschnitt der Spektren des Schadensfallpools eingesetzter experimenteller Modellschäden; schematische Auftragung der Schadensfälle E1 bis E17 (Tabelle 7-1)

Über den gesamten Kasten verteilt ist eine Vielzahl von Schäden denkbar. Die vorgestellten Schäden stellen daher einen Auszug der für das angestrebte KNN-Training wichtigen Fälle dar. Ihre Auswahl und Anzahl ist eine Folgerung aus den Erkenntnissen der Diskussion der numerischen Spektren (vgl. Abschnitt 4.1.2). Unterscheidungsmerkmale werden auch bei den Spektren experimentellen Ursprungs durch erste visuelle Beurteilungen ersichtlich. Sie zeichnen sich, besonders im Bezug auf die Durchführung einer Schadenserkennung, durch unterschiedliche Antwortspektren mit unterschiedlichen Peakpositionen und -amplituden bei verschiedenen Schadensfällen aus.

Im Folgenden werden einige wichtige Schadensfälle diskutiert, die auch Grenzfälle beim Vergleich von Spektren unterschiedlicher Schadensklassen repräsentieren. Die Beispiele des experimentellen Datenpools verdeutlichen die Identifikation von Schäden an Getränkekästen in Folge eines Vergleiches von experimentellen Frequenzspektren, wie es anhand der numerischen Simulation bereits Abschnitt 4.1 belegt. Dem Griffschaden (Vergleich der Spektren in Abbildung 4-15) kommt dabei eine besondere Bedeutung zu, da er den derzeit eingesetzten optischen Schadenserkennungssystemen der Industrie aufgrund von schwer unterscheidbaren „Schatten und Kontrasten“ Probleme bereitet. Auch die sogenannten „kleinen“ und „verdeckten“

Schäden, wie sie speziell in den Gefachen auftreten, werden betrachtet (vgl. die Spektren in Abbildung 4-16 und Abbildung 4-17).

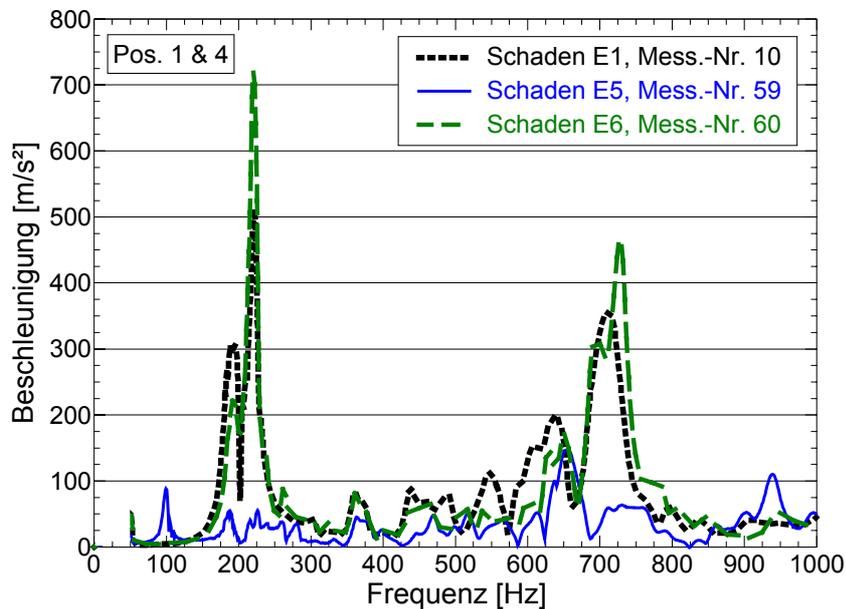


Abbildung 4-15: Vergleich von Griffschaden (E5: Pos. 1, Mess-Nr. 59; E6: Pos. 4, Mess-Nr. 60) und intaktem Kasten (E1: Pos. 4, Mess-Nr. 10); der Griffschaden befindet sich auf der Seite von Messposition 1.

Abbildung 4-15 zeigt auch, dass hier spezifische Peakänderungen hauptsächlich in zwei Bereichen auftreten, und zwar bei 150 bis 250 Hz und bei etwa 600 bis 800 Hz. Der Vergleich mit den numerischen Ergebnissen aus Abbildung 4-8 liefert übereinstimmende Tendenzen der Antwortsignale. Die dem Schaden entfernte Messposition (E6) weist in Abbildung 4-15 Ähnlichkeiten mit dem „Intakt“-Spektrum (E1) auf, wogegen das direkt am Schaden aufgenommene Spektrum (E5) deutliche Unterschiede aufzeigt. In Anbetracht der Tatsache, dass genau diese Art des Schadens für optische Detektionssysteme Probleme aufwirft, stellen die aufgezeigten Abweichungen ein deutliches Kriterium zur Selektion dar.

Das Beispiel eines Risses (Schadensfall E13 und E14) unterhalb des Griffes bei Messposition 4 verdeutlicht den Fall eines „kleinen“ Schadens. Der Vergleich der Frequenzspektren von Abbildung 4-16 zeigt dabei lediglich geringfügige Unterschiede im Bereich oberhalb von 400 Hz auf. Dies lässt bereits hier vermuten, dass beim neuronumerischem KNN-Training Probleme entstehen können (vgl. Abschnitt 4.4). Da ein Auftreten dieses Schadens aber wegen seiner Position im versteiften, „geschützten“ Bereich unter dem Griff unwahrscheinlich ist, wird er für die nachfolgenden Untersuchungen nicht gesondert betrachtet, jedoch im Auge behalten und bei der Beurteilung des KNN als möglicher Grenzfall berücksichtigt.

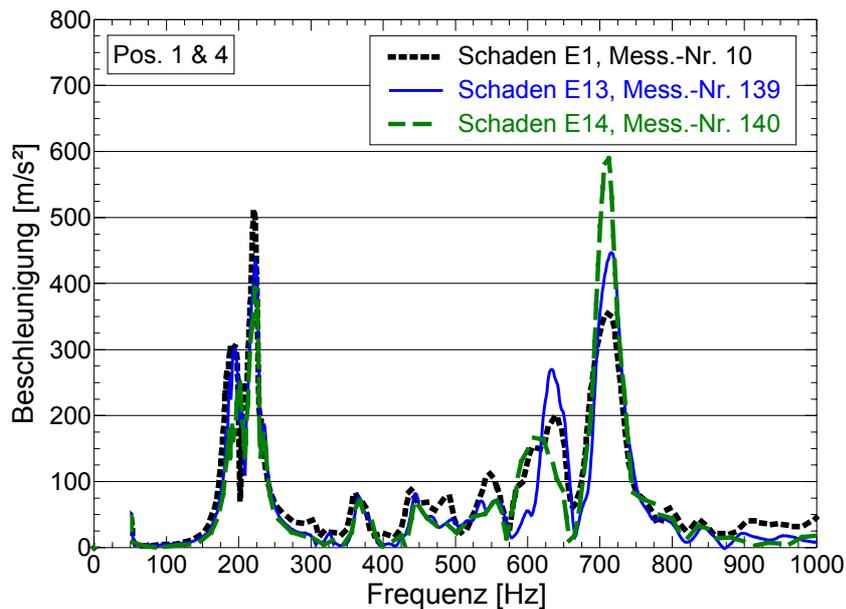


Abbildung 4-16: „Kleiner“ Schaden: Riss auf der Seite unter dem Griff (E13: Pos. 1, Mess-Nr. 139; E14: Pos. 4, Mess-Nr. 140) und intaktem Kasten (E1: Pos. 4, Mess-Nr. 10); der Schaden befindet sich auf der Seite von Messposition 4.

Als „verdeckte“ Schäden gelten für optische Systeme Schäden innerhalb der Kastenwände, da sie meist von außen nicht erkennbar sind. Wenn sie nicht besonders aufgebogen erscheinen, bleiben sie unerkant. Wegen seines komplexen Aufbaus stellt dabei besonders das gesamte Gefache eine Problemzone dar. Doch gerade dort befindliche, vermeintlich unerkennbare Schäden sind mit der Versuchsanlage sehr gut detektierbar, wie Abbildung 4-17 für eine sehr geringe Beschädigung im Gefache (E3 und E4) zeigt. Bedingt ist dies durch die zentrale Anregung von unten, die den mittleren Kastenbereich besonders belastet. Da Schäden im Gefache die Versteifung bzw. Stabilität der Konstruktion verändern, werden sie somit auch in der Signalübertragung bemerkbar. Die dabei verminderte, gedämpfte Signalübertragung spiegelt sich besonders in der Peakhöhe der Antwortspektren wider. So sind die Kurven der Fälle E3 und E4 im Vergleich zu E1 (vgl. Abbildung 4-17) beide nicht besonders ausgeprägt, aber dennoch charakteristisch.

Um das Gesamtbild der Spektrenbetrachtung abzurunden, erfolgt zusätzlich die Betrachtung von zwei sogenannten Fremdkästen (vgl. Abbildung 4-18), die stellvertretend für die immense Vielfalt der am Markt befindlichen Kastenmodelle stehen. Es handelt sich dabei um zwei unterschiedlich stark versteifte Modelle, die jeweils 20 Euro-Flaschen fassen. Ihre Auswahl wurde zufällig getroffen.

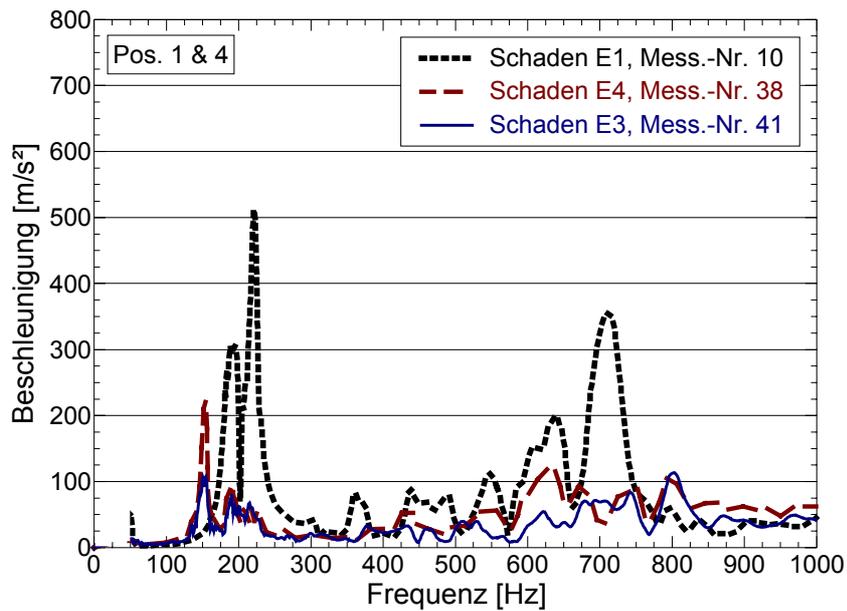


Abbildung 4-17: „Verdeckter“ Schaden im Gefache (E3: Pos. 4, Mess-Nr. 41; E4: Pos. 1, Mess-Nr. 38) und intaktem Kasten (E1: Pos. 4, Mess-Nr. 10)

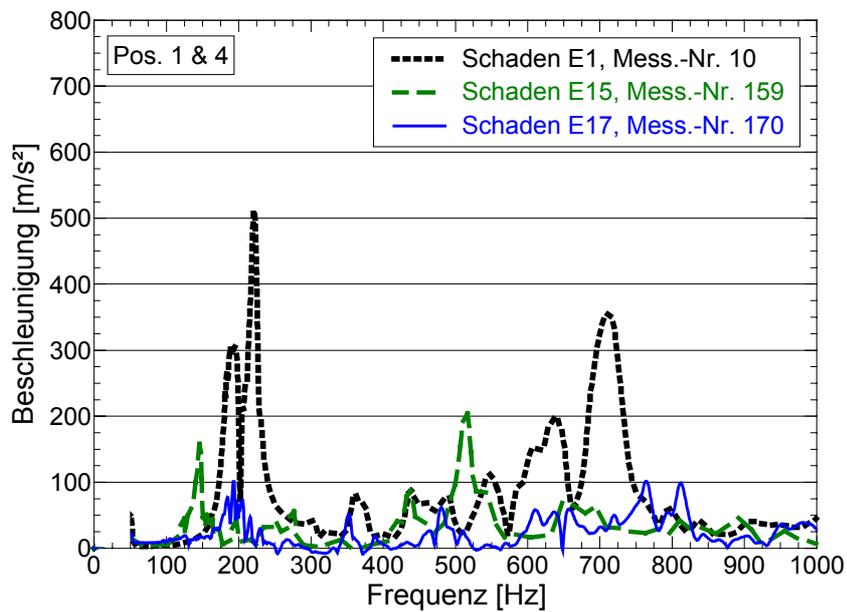


Abbildung 4-18: Frequenzspektren unterschiedlicher Kastenmodelle (E1: Pos. 4, Mess-Nr. 10), (E15: Pos. 1, Mess-Nr. 159), (E17: Pos. 4, Mess-Nr. 170)

Die Unterscheidung der verschiedenen Kastenmodelle ist eindeutig möglich, wobei angemerkt werden muss, dass die Befestigung der Kästen, bedingt durch die unterschiedlichen Bodengeometrien, nicht absolut identisch ist. Trotzdem ist ein vergleichbares freies Schwingen aller Bauteile durch die zentral, am Kastenboden

fixierte Anregung gegeben. Für die angestrebten Vergleichszwecke sind diese Spektren geeignet, da auch sie charakteristische Muster aufweisen. Sie zeigen im Vergleich zum Kastenmodell „Amstel“ (E1) verschobene Frequenzbereiche und eine Neigung zur Resonanz auf, die auch, bedingt durch die etwas abweichende Fixierung, gedämpfter wirkt. Sie eignen sich zwar nicht zum absoluten Vergleich, werden jedoch im Weiteren dem KNN als Fremdkastenspektren zugeführt.

Aus diesem Auszug experimenteller Schadensfallspektren kann gefolgert werden, dass eine Unterscheidung dieser Spektren möglich ist. Die Voraussetzungen für eine Mustererkennung sind damit gegeben. Bei nicht genügender Sensitivität eines einzelnen Messortes ermöglicht in vielen Fällen die Betrachtung mehrerer Messorte eine deutliche Unterscheidung, die auch schon in Abschnitt 4.1.2 anhand von Abbildung 4-8 angesprochen wurde. Dabei sind im einfachsten Fall die Spektren zweier symmetrischer Messorte zu beobachten. Besonders geeignet erscheinen dabei Messpositionen auf der linken und rechten Kastenseite, wie sie die vorangegangenen Abschnitte am Beispiel der Sensorpositionen 1 und 4 diskutieren. Diesen Aspekt bespricht Abschnitt 4.4.2 anhand eines Dual-Sensorsystems im Bezug auf die Klassifizierungsfähigkeit des KNN.

4.3 Klassifizierungsmöglichkeiten der Schwingungsspektren mit dem KNN

Als Grundlage für diesen Abschnitt der vorliegenden Arbeit wurde in den vorangegangenen Abschnitten gezeigt, dass Frequenzspektren der Schwingungsantwort eines Festkörpers zur Unterscheidung von Schadensfällen geeignet sind. Dies wurde sowohl für experimentell gewonnene, als auch für numerisch berechnete Frequenzspektren herausgearbeitet. Bis zu diesem Zeitpunkt wurde der Nachweis der Unterschiedlichkeit der Spektren auf rein empirischem visuellen Weg begangen, d. h. die Messergebnisse wurden als Graphen aufgetragen und die so erhaltenen Frequenzspektren, insbesondere die Höhe und Breite von Peaks auffälliger Frequenzbereiche, miteinander verglichen.

Zur automatischen Sortierung, Unterscheidung und Klassifizierung der Spektren, die jeweils für einen charakteristischen Zustand des Getränkekastens stehen, gilt es nun, ein geeignetes Verfahren zur Mustererkennung zu entwickeln. Besonders aus den in Abschnitt 2.3.4 aufgeführten Eigenschaften künstlicher neuronaler Netze geht hervor, das sich KNN für den Einsatz dieser Anwendung besonders eignen. Dies wird nicht allein ihren grundlegenden Klassifikationsfähigkeiten, sondern besonders auch ihrer Fähigkeit zur Approximation zugeschrieben. Dies ermöglicht sowohl die fehlerfreie Verarbeitung von geringfügigen Fertigungstoleranzen als auch von

geringfügigen Signalschwankungen. Diese Fähigkeiten der KNN werden auch im anschließenden Abschnitt 4.4 zur Neuronumerik genutzt.

Die zentralen Fragen der Netzwerkkonfiguration sind die Topologie und die Art der Datenpräsentation. Dies bedeutet im vorliegenden Fall für das Netzwerk, dass die Anzahl der Eingangsneuronen, der Ausgangsneuronen und der verdeckten Neuronen in der Zwischenschicht bestimmt werden muss. Zudem beeinflusst die Datenpräsentation vor allem die Anzahl der Eingangsneuronen. Sie hängt allerdings auch von der vom KNN benötigten Genauigkeit bzw. Spezifität der Datenvorverarbeitung ab, die die jeweilige KNN-Topologie zur exakten Klassifikation benötigt (vgl. Abschnitt 3.4).

Zu Beginn erfolgt anhand des als Standard-Netzwerk festgelegten 10x5x2-KNN die Beurteilung der Leistungsfähigkeit der Klassifikation des KNN. Zum Einsatz kommen dabei die experimentell gewonnenen Frequenzspektren der Modell-Schadensfälle E1 bis E17 (vgl. Anhang 7.2). Anschließend (vgl. Abschnitt 4.3.2) werden auch im Hinblick auf die neuronumerische Anwendung in Abschnitt 4.4 weitere Netzwerkkonfigurationen diskutiert, welche die Generalisierungsfähigkeiten abschwächen oder erhöhen und die Auswahl des Standard-Netzwerks begründen. Zusätzlich bespricht Abschnitt 4.3.3 die Auswirkung der Datenvorverarbeitung. Abschnitt 4.3.4 erläutert abschließend ein Beispiel der Klassifikation einzelner spezieller Schadensfälle mittels Zusatzausgaben des KNN.

4.3.1 Klassifizierung der Spektren experimenteller Datenpools

Das Hauptaugenmerk richtet sich nachfolgend darauf, Schäden an Getränkekästen zu erkennen und zu beurteilen, ob die Qualität der jeweiligen Klassifikationen ausreichend gut ist und somit angenommen werden kann. Dabei ist zu berücksichtigen, dass die betrachteten Fälle spezielle ausgewählte Modellschäden sind. Der Schadenspool entspricht von seinem Umfang her nicht der Anzahl an Kastenproben, wie sie in industriellen Flaschenabfüllanlagen vorhanden sind. Auch die Verteilung der Schadensfälle ist nicht der realen Häufigkeit und dem realen Durchsatz angepasst.

Als erstes Ergebnis des KNN-Trainings werden spezielle Trainings- und Test-Datensets ebenso wie Prädiktions-Datensets zusammengestellt, die bei der Entwicklung der eingesetzten Netzwerke erprobt wurden und zu erfolgreichen Klassifikationen führten. Das durchschnittliche Trainingsset besteht somit aus ca. 20 % „intakten“ Fällen und 80 % „defekten“ Fällen. Zu den „defekten“ Fällen zählen auch die sogenannten „kleinen“ Schäden (ca. 50 %), d. h. ihre Spektren unterscheiden sich nur

geringfügig von denen der „intakten“ Kästen (vgl. Abbildung 4-16). „Klein“ stellt dabei keine Wertung der Größe des sichtbaren Schadens dar. Diese Fälle verkörpern die Grenzfälle bei der Klassifizierung und erhalten deswegen diesen hohen Anteil im Trainingsdatenpool (vgl. Abschnitt 2.3.4). Der Rest der als „defekt“ zu klassifizierenden Fälle besteht aus „starken“ Schäden sowie fremden Kastenmodellen und den beiden Grenzfällen „alle Ausgabeneuronen = 0“ und „alle Ausgabeneuronen = Maximalwert des Spektrums“, die ebenfalls zur „defekten“ Klasse führen. Diese Fälle werden dem Datenpool zugesetzt, um das KNN gegenüber Grenzfällen zu sensibilisieren und um bei der Verarbeitung von widersprüchlichen, schlechten Datensätzen dem Netz die Generalisierung zu ermöglichen.

Außerdem enthalten die Datenpools keine identischen Datensätze. Sowohl der Testsatz des Trainings als auch der Prädiktionssatz enthalten gleichermaßen neue, als auch im Trainingsatz dem KNN bereits präsentierte Datensätze. Die bereits präsentierten Datensätze entstammen dem Datenpool der „praxisnahen Verrauschung“ experimenteller Datensätze, wie in Abbildung 4-13 dargestellt. Diese Unregelmäßigkeiten sind wichtig, um der Problematik des Auswendiglernens der KNN vorzubeugen.

Für die im Anschluss diskutierten Fälle werden diese Datenpools unverändert verwendet. In der Trainingsphase bestehen sie aus 31, in der Prädiktionsphase aus 143 Datensätzen (Spektren). Tabelle 7-5 im Anhang gibt die spezifische Zusammensetzung und Reihenfolge der Datensätze an. D1 bis D8 geben dabei deren Bezeichnung an. „EXP“ steht für die experimentelle Herkunft der Daten, „NUM“ für die Herkunft aus der numerischen Simulation sowie „EXP/NUM“ für einen Datensatz gemischter Zusammensetzung. Die jeweils vorgenommene Reihenfolge begründet sich in der dadurch erzielbaren Übersichtlichkeit. Auf das KNN-Training und die anschließende Prädiktion hat die Reihenfolge indessen keinen Einfluss, da die Festlegung der Gewichte unabhängig davon („offline“) vorgenommen wird (vgl. Abschnitt 3.5).

Die Beurteilung von Topologie und Netzwerkkonfiguration erweist sich als ein komplexer Themenbereich und wurde bereits in Abschnitt 2.3 diskutiert. Das nachfolgend diskutierte Beispiel demonstriert die Vorgehensweise bis zur Prädiktion.

Das 10x5x2-KNN nimmt dabei das durch Integration auf 10 Frequenzklassen reduzierte Spektrum auf (vgl. Daten-Vorverarbeitungs-Verfahren (DVV) A-1 in Tabelle 3-4). Die Fehlerkurven des KNN-Trainings (Abbildung 4-19) deuten dabei auf die geeigneten Netzwerkparameter. Diese ergeben sich aus der Beurteilung der Rückgabefehler des KNN für die eingesetzten Trainings- und Test-Datensätze. Dabei wird jeweils der „mittlere quadratische Fehler“ (MSE – berechnet mit Gl. (3-7)) und

der „relative absolute Fehler“ (RAE – berechnet mit Gl. (3-8)) betrachtet. Das Minimum bei Zyklus 80 zeigt für dieses Beispiel diesen als Zyklus mit den zweckmäßigsten KNN-Parametern an, da das Minimum des Fehlers der KNN-Ausgabe des Testsets bei einem geringen Fehler des Trainingssets auftritt.

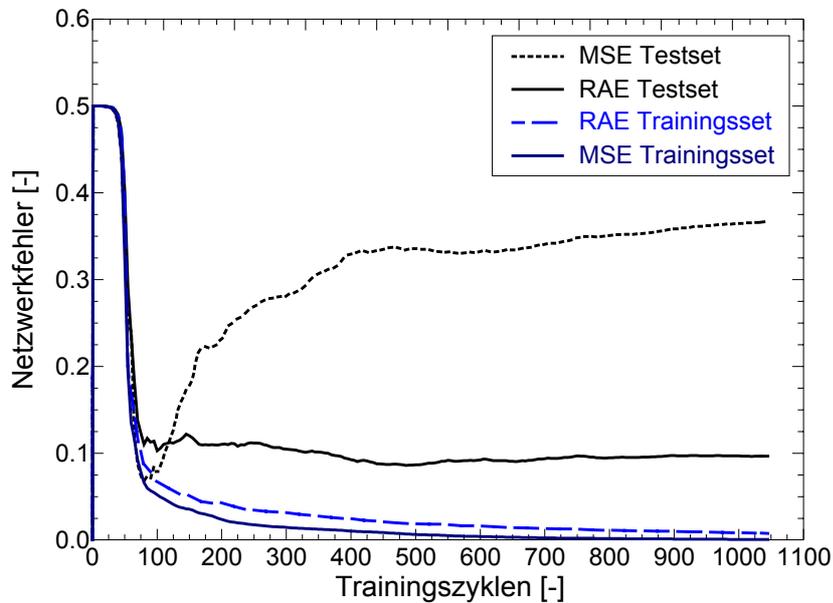


Abbildung 4-19: Beispiel für Fehlerkurve der KNN-Antwort der eingesetzten Trainings- und Testsets; Auftragung des „mittleren quadratischen Fehlers“ (MSE – Gl. (3-7)) und des „relativen absoluten Fehlers“ (RAE – Gl. (3-8)) für den jeweiligen Trainings- bzw. Testzyklus

Zudem erfolgt die Beurteilung der Fehlerraten der Klassifikationsausgabe von Trainings- und Testdatensatz. Diese ergeben sich durch Auswertung des zugehörigen Klassifizierungsdiagramms. Dabei wird die Auftragung der Wertepaare der Ausgangsneuronen für jeden Prüfling dargestellt, wobei jeweils die tatsächliche Vorgabe und die approximierte Ausgabe des KNN angegeben ist. Abbildung 4-20 zeigt hierzu die Ausgaben für den Datenpool D1-EXP (vgl. Tabelle 7-5). Als richtig zugeordnet gelten Paare, die das KNN an seinen Ausgaben der Vorgabe entsprechend zuweist (vgl. Abschnitt 3.5). Die Annäherung erfolgt dabei an die Werte „1“ (Eigenschaft des Neurons trifft zu) und „0“ (Eigenschaft des Neurons trifft nicht zu). Die Grenze der Zuordnung zu einer Klasse liegt bei „0.5“. Ausgaben kleiner „0“ und größer „1“ sind dabei möglich, verursacht durch nicht normierten bzw. skalierten Ausgabeneuronen (vgl. Tabelle 3-5).

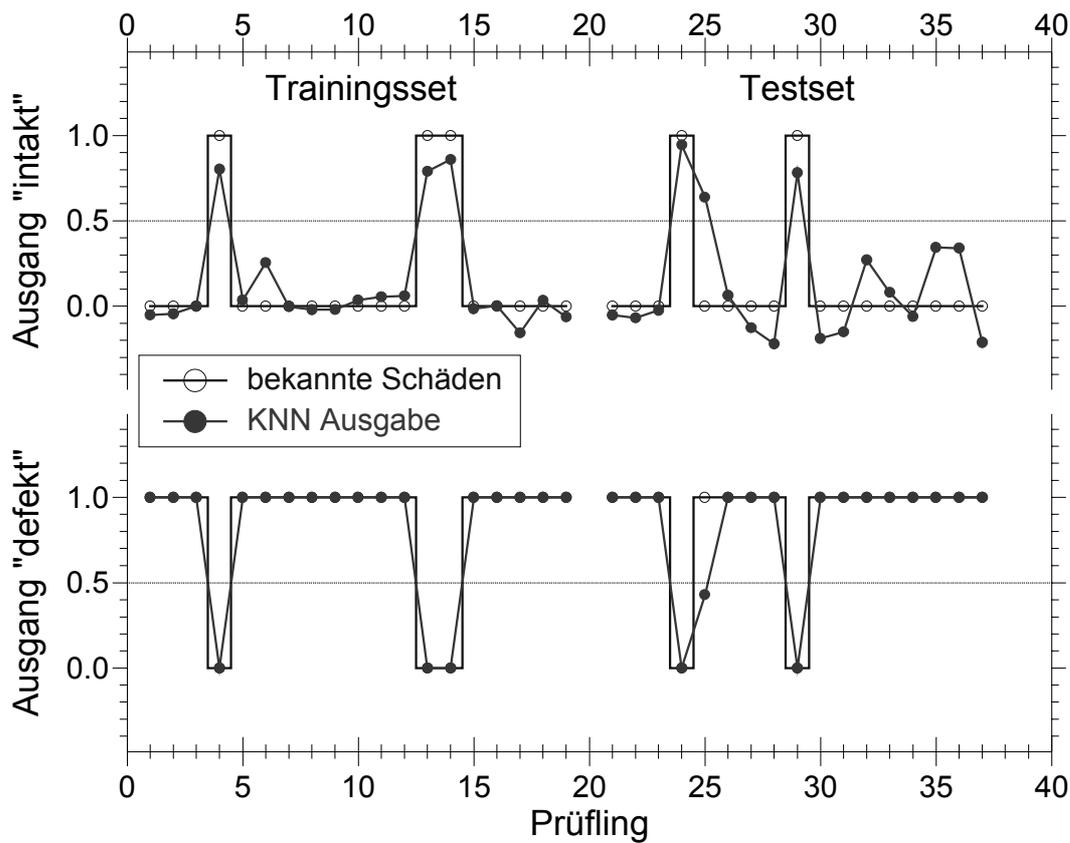


Abbildung 4-20: Gegenüberstellung der KNN-Ausgabe zur jeweiligen Vorgabe; Klassifikationsausgabe der beiden Ausgabeneuronen „defekt“ und „intakt“ des Trainings- und Testsets D1-EXP (DVV: A-1) für das 10x5x2-KNN. Der Wert „1.0“ gibt die Annahme und „0.0“ die Ablehnung der jeweiligen Klassifikation an.

Die in Tabelle 4-1 ausgewiesenen Daten spiegeln die Fehlerraten wider, welche der Häufigkeit von Fehlklassifikationen entsprechen.

Tabelle 4-1: Gesamtfehlerraten für die jeweilige Klassifikation aus Abbildung 4-20

	Fehler bei der Klassifikation	
	intakt	defekt
Trainingsset	0,0 %	0,0 %
„Anzahl“	0	0
Testset	5,9 %	5,9 %
„Anzahl“	1	1

Verwendeter Datenpool: D1-EXP

Daten-Vorverarbeitungs-Verfahren: A-1

Die in Tabelle 4-1 gezeigten Fehlerraten des Trainingssets nehmen eine verschwindend geringe Größenordnung an. Beim Testset bewirkt die kleine Stichprobe einen hohen prozentualen Fehler schon bei einer einzigen Fehlklassifikation. Die abschließende Beurteilung des Trainingserfolgs muss durch einen unabhängigen Prädiktionspool vollzogen werden. Erst diese Ausgabe verdeutlicht die Qualität der Generalisierungsfähigkeit des KNN. In den nachfolgenden Abschnitten wird deshalb bei der Beurteilung der Generalisierungsfähigkeit des KNN gegenüber den eingesetzten Datensätzen grundsätzlich die Ausgabe des Prädiktionspools diskutiert.

Der grundlegende experimentelle Prädiktionsdatenpool D2-EXP (vgl. Anhang Tabelle 7-5) zeigt für die in der Trainingsphase bestimmten Netzwerkparameter ebenfalls eine günstige Approximation der Klassen. D2-EXP setzt dem KNN wiederholt die praxisnah verrauschten 17 Prüflinge (E1 bis E17) vor (vgl. Abbildung 4-13). Es ergeben sich somit 143 Prüflinge für die dargestellte Prädiktionsphase. Dabei zeigt Abbildung 4-21 wiederum die Gegenüberstellung der Ausgabe des KNN zu der bekannten Vorgabe des Datenpools.

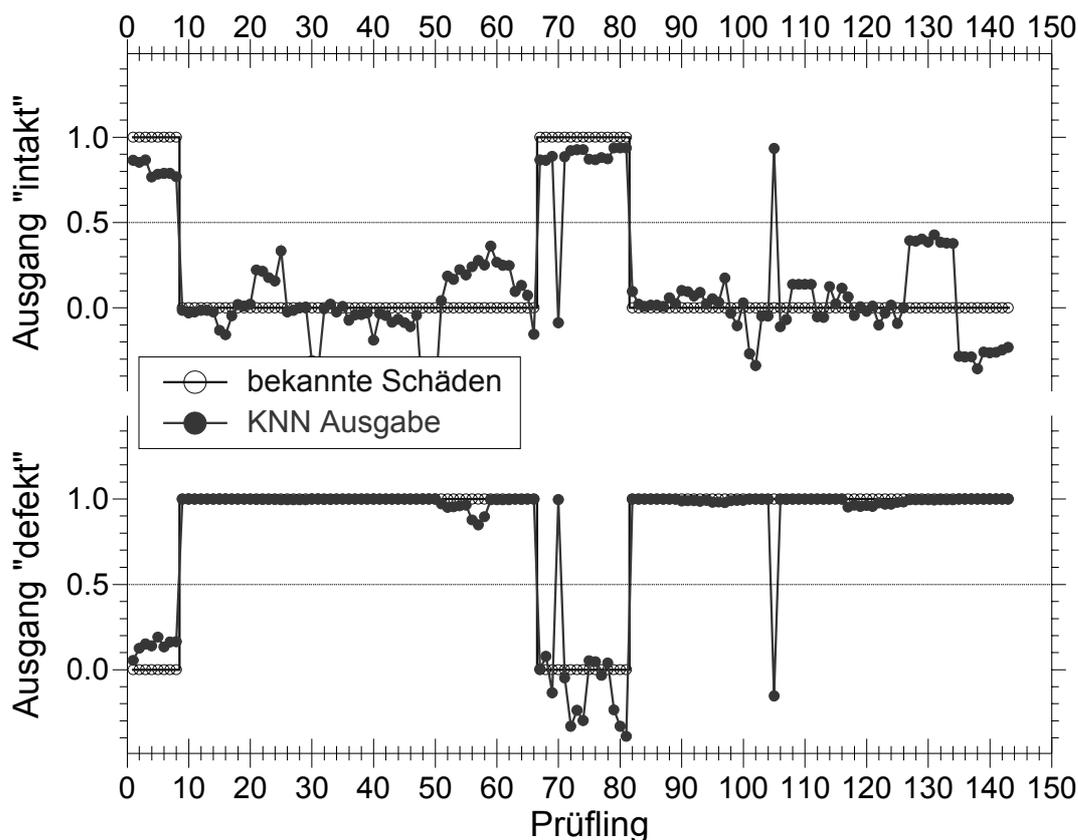


Abbildung 4-21: „intakt-defekt“ Klassifikationsausgabe der Prädiktion von Datensatz D2-EXP (DVV: A-1) für der Topologie 10x5x2. Der Wert „1.0“ gibt die Annahme und „0.0“ die Ablehnung einer Klassifikation an.

Auch hier errechnet sich aus der Häufigkeit der Fehlapproximationen die Fehlerrate für Tabelle 4-2. Die Fehlerrate wird jeweils getrennt für die „intakt“ und „defekt“ Klassifizierung betrachtet. Der Gesamtfehler der Ausgabeklassen und auch der Gesamtfehler der einzelnen Ausgabeneuronen errechnet sich nach Tabelle 3-7.

Tabelle 4-2: Fehlerraten der Prädiktion von Datensatz D2-EXP für die Klassifikationsausgabe von Abbildung 4-21 für der Topologie 10x5x2

Klasse	Entscheidung		
	0 für falsch	1 für richtig	gesamt
intakt	4,3 %	95,7 %	100 %
„Anzahl“	1	22	23
defekt	0,8 %	99,2 %	100 %
„Anzahl“	1	119	120
Gesamt	1,4 %	98,6%	
„Anzahl“	2	141	

Verwendete Datenpools: D1-EXP + D2-EXP

Daten-Vorverarbeitungs-Verfahren: A-1

In der in Abbildung 4-21 dargestellten Klassifikation fallen sowohl die Fehler bei den Prüflingen 70 (E1) und 105 (E9) als auch die unsichere Zuordnung der Prüflinge 127 bis 134 (E16, Fremdkasten) am Ausgang „intakt“ auf. Letztere werden jedoch aufgrund des Ausgangs „defekt“ eindeutig zugeordnet. Auch die Prüflinge 70 und 105 werden in die Klasse „defekt“ eingeordnet. Dies erhöht zwar den Gesamtfehler, ist aber im Hinblick auf die Produktsicherheit erforderlich.

Werden Unzulänglichkeiten des Netzes ausgeschlossen, führt die Interpretation der Ergebnisse dabei zur Feststellung von Problemfällen, die entweder die Ähnlichkeit der Spektren beider Klassen (vgl. Abbildung 4-15) oder die zu großen Abweichungen der „praxisnahen“ Datenaufnahme (vgl. Abbildung 4-13) bedingen. Das Netz kann diese Fälle nicht richtig zuordnen. Eine Lösung hierfür bietet die Verfeinerung der Datenvorverarbeitung, wie sie Abschnitt 4.3.3 diskutiert. Ein weiterer Lösungsansatz ist das Verwenden eines weiteren Sensors (vgl. Abschnitt 4.4.2).

Somit lässt sich zusammenfassen, dass das hier diskutierte KNN die ihm präsentierten Modellschäden sehr gut klassifiziert. Sie decken dabei eine Bandbreite unterschiedlicher Schäden ab. Die Datenvorverarbeitung benötigt kein Vorwissen in Bezug auf Position und Größe zu erwartender Frequenzpeaks im Spektrum. Somit

reicht die Erkenntnis aus, dass geometrische Schäden diese Peaks verändern und dadurch klassifizierbar werden.

Auch die Betrachtung der Ausgabe, ohne sie exakt auf „0“ und „1“ zu normieren, lässt Rückschlüsse bezüglich der Approximationstendenz der jeweiligen Ausgabeknoten zu. Des Weiteren wird bereits hier durch die teilweise abweichenden Ausgaben der beiden Ausgabeneuronen „intakt“ und „defekt“ die Funktion des zweiten, zusätzlichen Ausgabeneurons deutlich (vgl. Abbildung 4-20 und Abbildung 4-21). Beide Ausgabeneuronen approximieren nicht für jeden Prüfling bei jeder Ausgabe identisch. Das eröffnet Spielraum zur weiteren Diskussion der Datenpoolzusammensetzung sowie der Netzwerkkonfiguration und ist hilfreich bei der Einordnung der Generalisierungsfähigkeit des Netzes bezüglich einzelner Grenzfälle. In Abschnitt 4.4 zur Neuronumerik erlangen diese Aspekte weitere Bedeutung.

4.3.2 Auswirkung der Netzwerkgröße

Wie die Literatur zur Anwendung und Konfiguration von KNN diskutiert (vgl. Abschnitt 2.3), erweist es sich als notwendig, nach Konfigurationen zu suchen, die in der Lage sind, die angestrebte Klassifikation zu erreichen. Die Auswahl des oben besprochenen Standard-Netzwerks (10x5x2) begründet die nachfolgende Erörterung. Zur Verdeutlichung zeigt Tabelle 4-3 einen Vergleich von Fehlerraten weiterer, für den vorliegenden Fall denkbarer und sinnvoller Topologien für das Uni-Sensorsystem (vgl. Tabelle 3-6), die aus den Klassifikationsgraphen von Abbildung 4-21 und Abbildung 4-22 ermittelt werden. Zugrunde liegen dabei identische Datenpools (D1-EXP und D2-EXP), die lediglich bezüglich der Ein- und Ausgangsneuronenzahl angepasst wurden. Für jede Topologie wird die beste erzielte Klassifizierung bewertet.

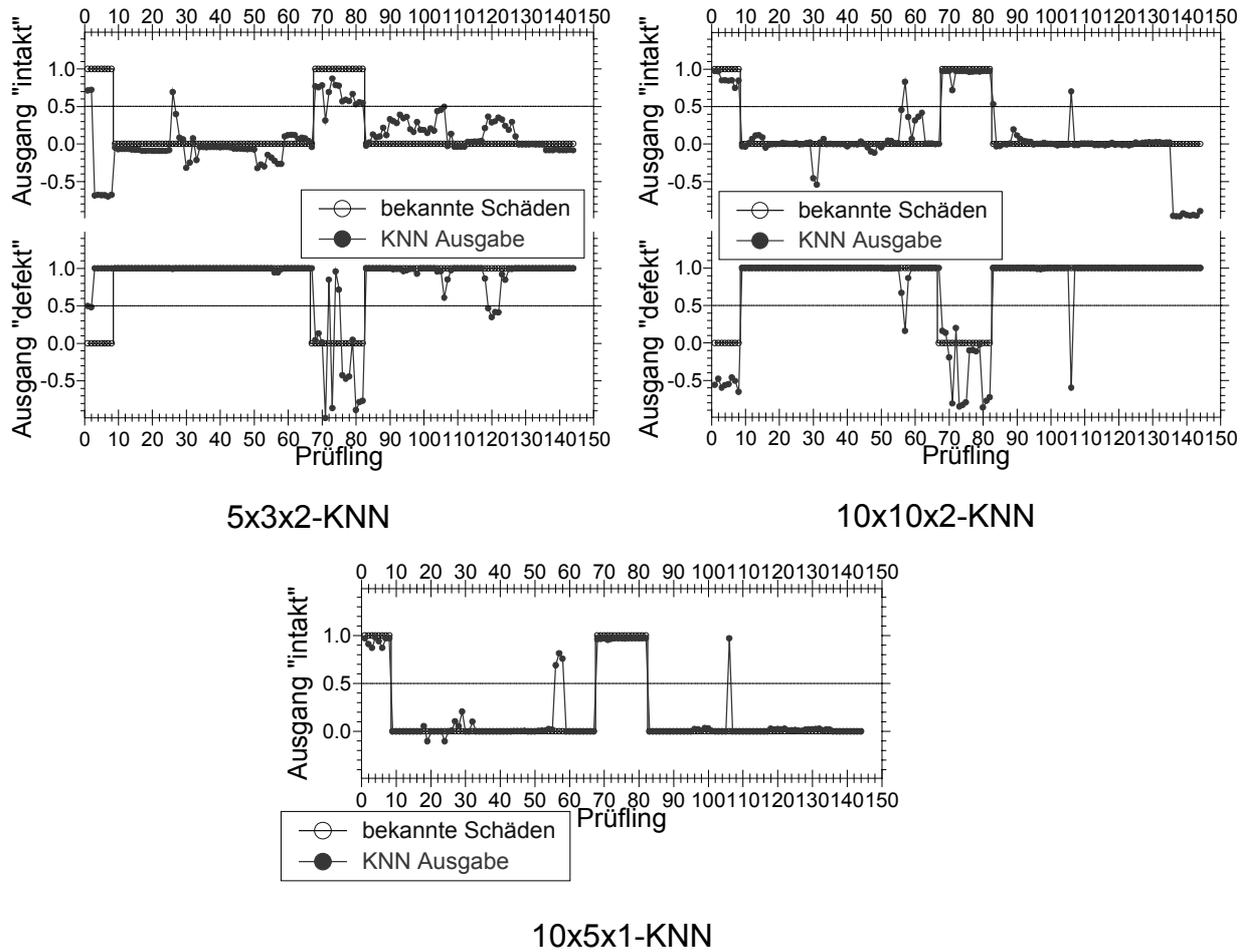


Abbildung 4-22: Klassifikationsdiagramme der Netzwerkausgaben für die Topologien 5x3x2 und 10x10x2 mit den zwei Ausgängen „intakt“ und „defekt“ sowie der einzelnen Ausgabe der 10x5x1-Topologie

Tabelle 4-3: Vergleichende Aufstellung der Fehlerraten der Netzwerke bei der Klassifizierung des Datensatzes D2-EXP der Klassifikationsausgaben von Abbildung 4-21 (für das 10x5x2-KNN) und Abbildung 4-22.

Netztopologie	Fehler der Prädiktion		
	intakt	defekt	Gesamtfehler
5x3x2	43,5 %	5,0 %	11,2 %
10x5x2	4,3 %	0,8 %	1,4 %
10x10x2	0,0 %	1,7 %	1,4 %
10x5x1	2,8 %	--	2,8 %

Verwendete Datenpools: D1-EXP + D2-EXP

Daten-Vorverarbeitungs-Verfahren: A-1

Wie der Vergleich der eingesetzten Grundtopologien (5x3x2, 10x5x2 und 10x10x2) zeigt, stellt die Konfiguration 10x5x2 eine leistungsfähige Form mit hinreichender Klassifizierungsqualität dar. Das 5x3x2-KNN erweist sich im Unterschied hierzu gerade für die „Intakt“-Spektren mit einem Fehler von 43,5 % als nicht ausreichend trainierbar. Dies wird auch in, hier nicht aufgelisteten, erheblichen Abweichungen von Trainings- und Testfehlern deutlich, welche sich mit dem KNN-Code (vgl. Tabelle 3-5) dieser Arbeit nicht weiter verringern lassen.

Das größere 10x10x2-KNN erhöht die Qualität der Klassifizierung nicht explizit und neigt außerdem dazu, übertrainiert zu werden, wie in Abschnitt 2.3.4. beschrieben. Dies verdeutlicht, dass mit zunehmender Komplexität dem KNN die Fähigkeit der Approximation genommen wird [100], die besonders im Hinblick auf mögliche Abweichungen der Spektren aufgrund von Fertigungstoleranzen und der „praxisnahen Platzierung“ des Prüflings benötigt wird.

Die Ausgabe des 10x5x1-KNN zeigt, dass ein Ausgabeneuron, das „0“ für „defekt“ und „1“ für „intakt“ zuordnet, ebenso eine gute Klassifizierung erzielt. Die Unterschiede zum 10x5x2-KNN (2 Ausgabeneuronen) sind nicht signifikant.

Wie oben bereits dargestellt, zeigt sich die 10x5x2-Topologie als geeignet und wird deshalb auch in der vorliegenden Arbeit als Standard-Netzwerk eingesetzt. Der Einsatz zweier Ausgabeneuronen bewirkt zwar keine Verbesserung der Generalisierung des KNN, ist jedoch im Hinblick auf die Klassifizierung in der Neuronumerik (vgl. Abschnitt 4.4) von großer Bedeutung, weil somit eine erweiterte Interpretation der Ausgabe des KNN ermöglicht wird. Denn grundsätzlich besteht die Möglichkeit, dass ein Prüfling von einem Ausgabeneuron richtig und von dem anderen falsch eingeordnet wird. Das Ausgabepaar für einen Prüfling kann dabei die Gewichtung der Annäherung an eine Klasse spezifizieren. D. h., dass eine Bewertung mit Schwerpunkt „mehr intakt“ oder „mehr defekt“ getroffen werden kann. Der Freiraum, der sich dadurch bietet, führt zu spezifisch abgrenzbarer Interpretation der Klassifikation [47, 103]. Auch ermöglicht diese Ausgabe die gezielte Bewertung der Eignung der Datenpools, indem einzelne Daten anhand der Ausgaben als Grenzfälle für eine bestimmte Klasse oder auch als ungeeignet für das gesamte KNN eingestuft werden können. Im vorliegenden Fall führt die verfeinerte Betrachtungsmöglichkeit der doppelten Ausgabe bei der Approximation dazu, dass das 10x5x2-KNN durch gezielte Trainingsdatenauswahl weitaus mehr Abweichungen im Prädiktionsdatensatz dulden kann.

4.3.3 Auswirkung der Daten-Vorverarbeitung auf die Qualität der KNN-Ausgabe

Wie vorangehend bereits dargestellt, wurde das Standard-Netzwerk auf 10 Eingangsneuronen begrenzt, um die Freiheitsgrade des Netzes zu limitieren. Die notwendige Datenreduzierung der Eingangsdatensätze (Frequenzspektren) wurde in Abschnitt 3.4 beschrieben. Tabelle 3-4 listet dabei die eingesetzten Daten-Vorverarbeitungs-Verfahren (DVV) A-1 und A-2 (direktes Antwortsignal) sowie B-1 und B-2 (Übertragungssignal) auf. Da dies im nachfolgenden Abschnitt bei der neuro-numerischen Substitution der Datensätze an Bedeutung gewinnt, werden diese Verfahren vorab miteinander am 10x5x2-KNN verglichen. Tabelle 4-4 dient der Gegenüberstellung der Fehlerraten der vorgenommenen Klassifizierungen, die Abbildung 4-23 darstellt.

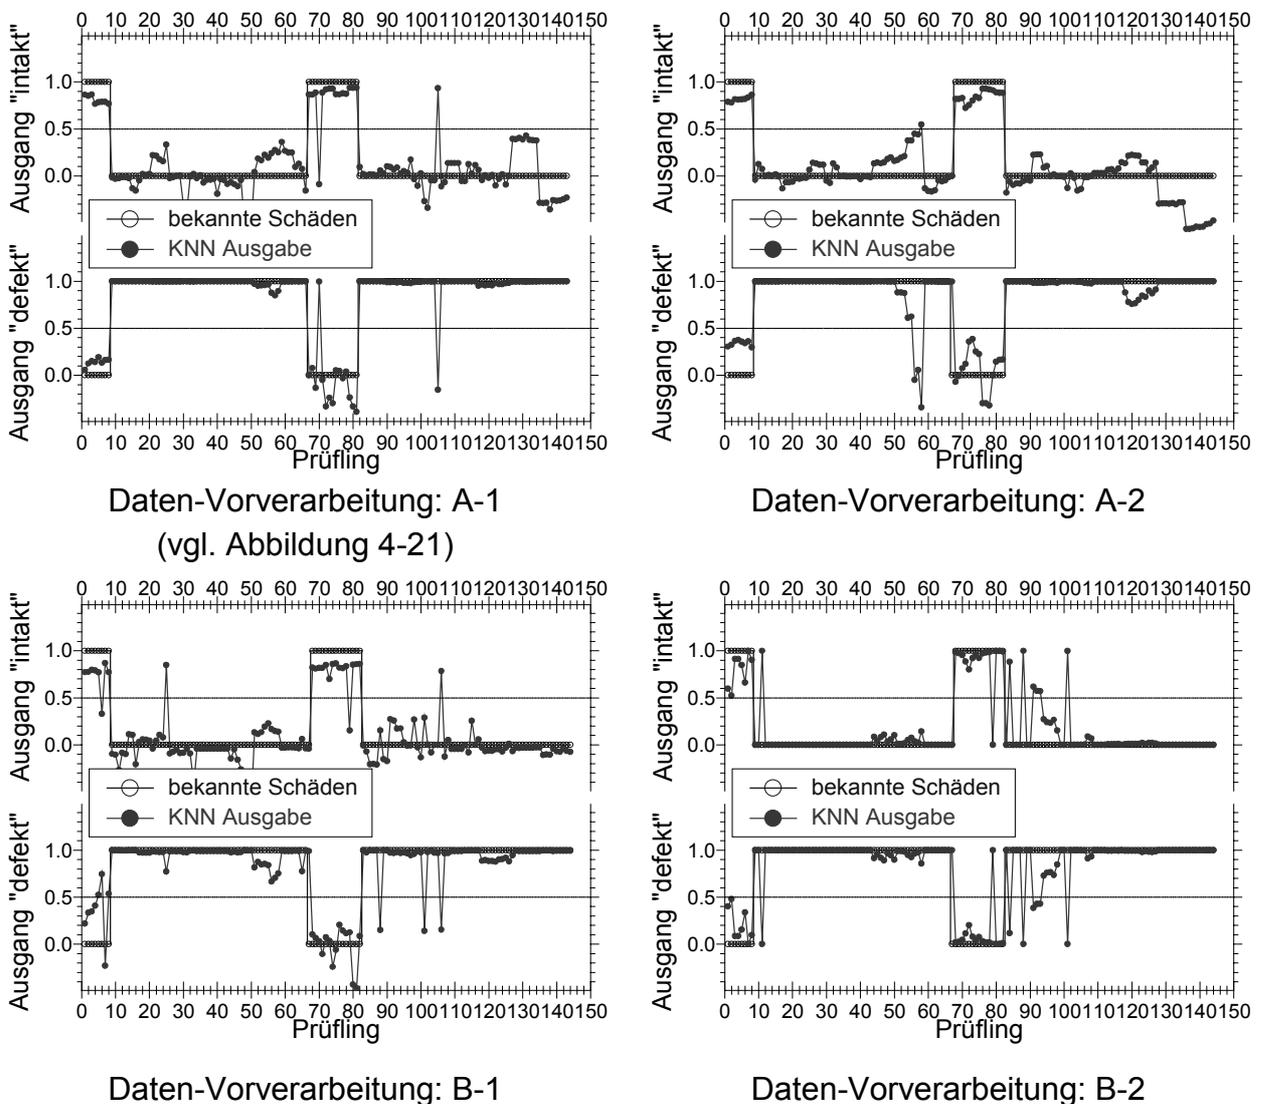


Abbildung 4-23: Klassifikationsausgabe des 10x5x2-KNN für die Daten-Vorverarbeitungs-Verfahren (DVV): A-1, A-2, B-1 und B-2

Tabelle 4-4: Vergleichende Aufstellung der Fehlerraten unterschiedlicher DVV (vgl. auch Tabelle 3-4) für das 10x5x2-KNN gemäß der Auftragung in Abbildung 4-23

Daten-Vorverarbeitung	Fehler der Prädiktion		
	intakt	defekt	Gesamtfehler
A-1	4,3 %	0,8 %	1,4 %
A-2	0,0 %	2,5 %	2,1 %
B-1	8,7 %	3,3 %	4,2 %
B-2	4,3 %	5,8 %	5,6 %

Verwendete Datenpools: D1-EXP + D2-EXP (entsprechend des DVV)

KNN-Topologie: 10x5x2

Die erste Schlussfolgerung hieraus ist, dass diese Aufbereitungen weitgehend gleichwertig sind, wenn rein experimentelle Datensätze verwendet werden. Es zeigt sich hier bereits, dass ein einfaches Aufteilen des Spektrums in 10 Frequenzklassen (vgl. Fehlerraten von A-1 und B-1) dem Anspruch einer adäquaten Datenaufbereitung genügt.

Ebenso ist zu erkennen, dass es bei den beschriebenen, rein experimentellen Datensätzen für die Klassifikation keine entscheidende Rolle spielt, ob deren Information in Form einer Übertragungsfunktion (B-1, B-2) einfließt oder ob, wie bei den Fällen A-1 und A-2, direkt das Antwortsignal herangezogen wird. Die Fehlerraten von B-1 und B-2 erweisen sich nur geringfügig größer. Diese Unterscheidung hat jedoch weiter unten bei einer Berücksichtigung der numerischen Spektren erhebliche Bedeutung, da dort die Anregung explizit vorgegeben werden muss (vgl. Abschnitt 4.4).

Dennoch zeigt der Vergleich der Fehlerraten das Potenzial einer Datenaufbereitung auf, die ohne konkretes Vorwissen um Anzahl, Positionen sowie Amplituden von Frequenzpeaks auskommt. Der Gesamtfehler liegt gemäß Tabelle 4-4 in allen Fällen unter 6 %. Der vermeintliche Nachteil des Unterschlagens der Information spezieller Frequenzpeaks ist bei der Anwendung nur von geringer Bedeutung. Gerade die vorliegenden KNN sind durch ihre Fähigkeit, aus Mustern Funktionen und Klassen zu approximieren, nicht speziell auf diese spezialisierten Informationen angewiesen. Bei Bedarf können allerdings bestimmte, für wichtig erachtete zusätzliche Verfahren zur Datenvorverarbeitung, beispielsweise FFT-Algorithmen, jederzeit die Eingabeinformation ergänzen, um das Netz zu spezifizieren.

Außerdem zeigt sich, dass die Stärken und Schwächen jeder Vorverarbeitung an unterschiedlichen Modellschäden zum Tragen kommen. Die Spezifizierung ist durch die verfeinerte, „geschiftete“ Aufsummierung der Frequenzklassen (A-2, B-2) erhöht. Spektren werden sehr genau zugeordnet, die Generalisierungsfähigkeit vermindert sich jedoch, da mit zunehmender Spezifizierung weniger Abweichungen (z. B. stark verrauschte Spektren) kompensiert werden.

4.3.4 Klassifizierung einzelner spezieller Schadensfälle experimenteller Datenpools

Um zu verdeutlichen, dass das eingesetzte KNN neben der grundlegenden „intakt-defekt“ Klassifizierung auch die Art des Schadensfalls zu approximieren vermag, wird nachfolgend ein Netzwerk beispielhaft vorgestellt, das neben dieser grundlegenden Klassifikation eine zusätzliche Ausgabe spezifischer Schadensfälle ermöglicht. Dabei handelt es sich um Testmuster, wie z. B. einen Griffschaden und einen Seitenschaden. Deren Anzeige erfolgt durch zusätzliche Ausgangsknoten. Sie müssen indessen als Schadensfall im KNN-Training vorkommen. Das Training der zusätzlichen Ausgabeneuronen geschieht ebenfalls im überwachten Lernverfahren. Die Ausgaben sind ebenso als 0-1-Knoten konfiguriert und approximieren eine „1“, wenn der jeweilige Schaden vorliegt. Die reine Sortierung erfordert diese zusätzlichen Informationen zwar nicht, sie dienen jedoch beispielsweise der weiteren statistischen oder betriebswirtschaftlichen Auswertung.

Abbildung 4-24 illustriert die Netzwerkausgabe eines 10x7x5-KNN das zusätzlich zu den Ausgaben „intakt“ und „defekt“ drei separaten Ausgangsneuronen aufweist. Die drei Zusatzausgaben klassifizieren als Teilmengen der Ausgabe „defekt“ die speziellen Zusatzausgaben der Schadensfälle Fremdkasten („Fremd.“), sonstig defekt („sonst def.“) und defekter Griff (def. Griff“). Die Gesamtfehlerrate jeder Zuordnung listet Tabelle 4-5 auf.

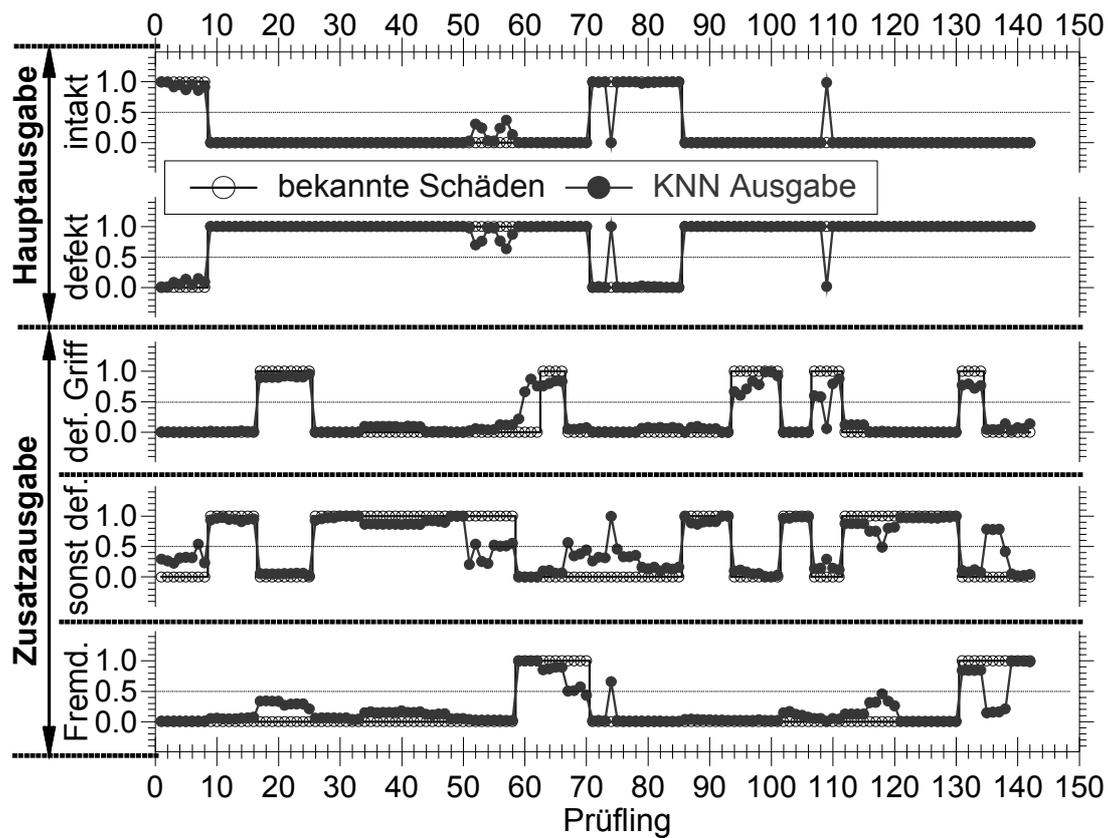


Abbildung 4-24: Beispiel der Ausgabemuster eines 10x7x5-KNN, Prädiktion des Datenpools D2-EXP (DVV:A-1); Zusatzausgabe der Schadensfälle Fremdkasten („Fremd.“), sonstig defekt („sonst def.“) und defekter Griff (def. Griff“) an separaten Ausgangsneuronen.

Tabelle 4-5: Fehlerraten für die Klassifikation der jeweiligen Ausgangsneuronen des Klassifikationsdiagramms in Abbildung 4-24

Netztopologie	Fehler der Prädiktion als Gesamtfehler des jeweiligen Ausgangsneurons				
	Grund-Klassen		Schäden (Zusatzausgabe)		
	intakt	defekt	def. Griff	sonst def.	Fremd.
10x7x5	1,4 %	1,4 %	2,8 %	6,3 %	4,2 %

Verwendete Datenpools: D1-EXP + D2-EXP

Daten-Vorverarbeitungs-Verfahren: A-1

Die Aussortierung eines defekten Prüflings erfolgt auch bei diesem Netzwerk nach dem Ausgang „defekt“. Die Zuordnungen der Ausgabeklassen zeigen darüber hinaus bis auf die Ausgabe der „sonstigen Defekte“ Fehlerraten unter 5 %. Das entspricht

der Qualität der Klassifizierung der vorangegangenen Abschnitte, ist jedoch schlechter als der Fehler (1,4 %) den das Netzwerk zur reinen Aussortierung erzeugt. Das bedeutet, dass innerhalb der Teilmengen der Klasse „defekt“ die Ausgabe des KNN der vorliegenden Konfiguration anfälliger bei Grenzfällen erscheint.

Die Berücksichtigung der Ausgabe „Fremd.“ steht stellvertretend für unterschiedliche Geometrien anderer Modell (Fremdkasten). Diese Zusatzausgabe verdeutlicht auch im Hinblick auf Kapitel 6, dass abweichende Getränkekästen, deren Geometrie auf einer unterschiedlichen Anzahl von Flaschen, unterschiedlichen Formen (2 oder 4 Griffaussparungen), unterschiedlichen Größen (auch teilbare Systeme), etc. beruht, in charakteristischen Frequenzbereichen anders antworten als entsprechend festgelegte Standard-Getränkekästen (vgl. Abbildung 4-18). Um alle diese Kastenmodelle kann das Netzwerk bei der vorgestellten Konfiguration mit entsprechenden Trainingsdatensätzen schnell mittels Zusatzausgaben erweitert werden.

Da statistische Auswertungen der Fehlerhäufigkeiten in Flaschenabfüllanlagen den abgesteckten Rahmen der vorliegenden Arbeit sprengen würde, wird im Nachfolgenden die auf zwei Ausgangsknoten reduzierte Ausgabe „intakt“ und „defekt“ beibehalten. Außerdem betrachtet der Abschnitt 4.4 zur Neuronumerik lediglich die Standard-Datenpools dieser Arbeit, die Tabelle 7-5 beschreibt.

4.4 Neuronumerik

Die Bedeutung der Neuronumerik für die Automation im Sinne der vorliegenden Arbeit (vgl. Abschnitt 1.1.2 und 3.1) erschließt sich aus der Möglichkeit, Trainingsdatensätze für die eingesetzten KNN mit Hilfe numerischer Simulation zu errechnen. Hierdurch sind sowohl die benötigte Anzahl als auch die schwer messbaren Datensätze des Trainingsdatenpools abdeckbar. Dies führt schließlich bis zu einem KNN, das völlig ohne den Einsatz realer, aus experimentellen Vormessungen gewonnener Datensätze parametrierbar wird. Das Mustererkennungssystem zur Schadensdetektion wird im Labor parametriert und anschließend vor Ort mit geringem Zeitaufwand implementiert.

Inwieweit diese Arbeitshypothese zutrifft und inwieweit das bis jetzt in dieser Arbeit konfigurierte System dies ermöglicht, wird nachfolgend diskutiert. Dabei kommt die Konfiguration des KNN zum Einsatz, die in Abschnitt 4.3 anhand der Klassifikation rein experimenteller Datensätze besprochen wurde.

4.4.1 Das Uni-Sensorsystem

Das bisherige Detektionssystem baut auf die Signale eines einzigen Sensors auf („Uni-Sensorsystem“). Dabei sind im experimentellen Teil die Messsignale (Spektren) entsprechend Abschnitt 3.4 aufbereitet und dem KNN eingespeist worden. Für diese Datensätze rein experimentellen Ursprungs ergibt sich dabei eine gute Klassifizierung. Dies gilt auch für Grenzfälle (vgl. Abschnitt 4.3). Die zunehmende Substituierung der verwendeten Spektren mit solchen aus der numerischen Simulation des Schwingungsprozesses führt zu den im nachfolgenden Abschnitt beschriebenen Ansätzen. Besondere Bedeutung haben indessen die vorhandenen, geringfügigen Abweichungen experimenteller und numerischer Quellen, die aufgrund notwendiger Vereinfachungen in der numerischen Simulation der Spektren entstanden sind (vgl. Abschnitt 4.1.3). Somit wird im Folgenden der Frage nachgegangen, inwieweit dabei falsche Klassifikationen auftreten. Außerdem wird überprüft, ob durch geeignete Konfiguration von Netzwerk und auch der Datenvorverarbeitung diese Abweichungen vernachlässigt werden können.

4.4.1.1 KNN trainiert mit Kombinationen experimenteller und numerischer Datenpools

In Abschnitt 4.3 wurde bereits die Zusammensetzung des verwendeten Datenpools angesprochen. Die Zusammenstellung des experimentellen Datenpools bleibt für diesen Abschnitt unverändert. Er wird jedoch mit Datensätzen aus der numerischen Simulation substituiert. D. h., es werden „Intakt“-Spektren experimenteller Herkunft mit „intakten“ aus der Simulation ausgetauscht, experimentelle „Defekte“ mit entsprechenden Schadensfällen aus der Numerik. Dabei lassen sich Aufteilung und Poolzusammenstellung mit denjenigen der experimentellen Datenpools D1-EXP und D2-EXP vergleichen. Eingesetzt werden dabei die validierten „Intakt“-Spektren aus Abschnitt 4.1.2 und zusätzlich einige Spektren, die entsprechend „künstlich verrauscht“ wurden, indem Schadensfälle mit geringfügigen Abweichungen von Dichte, E-Modul, Poissonzahl sowie Dämpfung vorgegeben wurden (vgl. Tabelle 3-1 und Tabelle 7-6). Es wird jeweils die komplette Substitution einer der beiden Klassen „intakt“ bzw. „defekt“ studiert (Tabelle 4-6). Die Substitution lediglich einzelner Schadensfälle wird nicht durchgeführt. Für zielgerichtete Grenzfälle sei jedoch angemerkt, dass die Zuführung spezieller Datensätze deren Klassifikation verbessert.

Tabelle 4-6: Substitution der experimentellen mit numerischen Datensätzen gemäß Tabelle 7-5

	Trainings- /Testsets	Prädiktionssets
I.	- experimentelle Spektren für „defekte“ Fälle - numerische Spektren für „intakte“ Fälle	D2-EXP identisch dem Datenpool der Prädiktionsphase von Abschnitt 4.3
II.	- experimentelle Spektren für „intakte“ Fälle - numerische Spektren für „defekte“ Fälle	D2-EXP identisch dem Datenpool der Prädiktionsphase von Abschnitt 4.3

Die Zusammenstellung der Trainings- bzw. Testsets soll erste Aufschlüsse über die Generalisierungsfähigkeit des mit numerischen Daten trainierten Netzwerkes geben. Die Vorgehensweise begründet sich in den Erkenntnissen des Vergleichs experimenteller und numerischer Datensätze von Abschnitt 4.1.3. Daher ist zu erwarten, dass das KNN beim Einsatz der numerischen Spektren Fehlklassifikationen erzielt. Sie

werden vor allem bei Schadensspektren (Grenzfälle) auftreten, die Abweichungen in Größenordnungen aufzeigen, die zu Ähnlichkeit mit Nachbarklassen führen (vgl. Abschnitt 4.1.2). Ein Beispiel hierzu ist der Griffschaden (vgl. Abbildung 4-15), der von der gegenüberliegenden Seite her detektiert werden soll und dabei Verschiebungen im Frequenzspektrum aufweist, die dieser Größenordnung entsprechen.

Wie nachfolgend ersichtlich, reagiert das KNN dieser Arbeit auf eine Substitution der gesamten „defekten“ Schadensfälle (vgl. Abbildung 4-26) weniger unsicher als auf die Substitution der gesamten „intakten“ Datensätze (vgl. Abbildung 4-25).

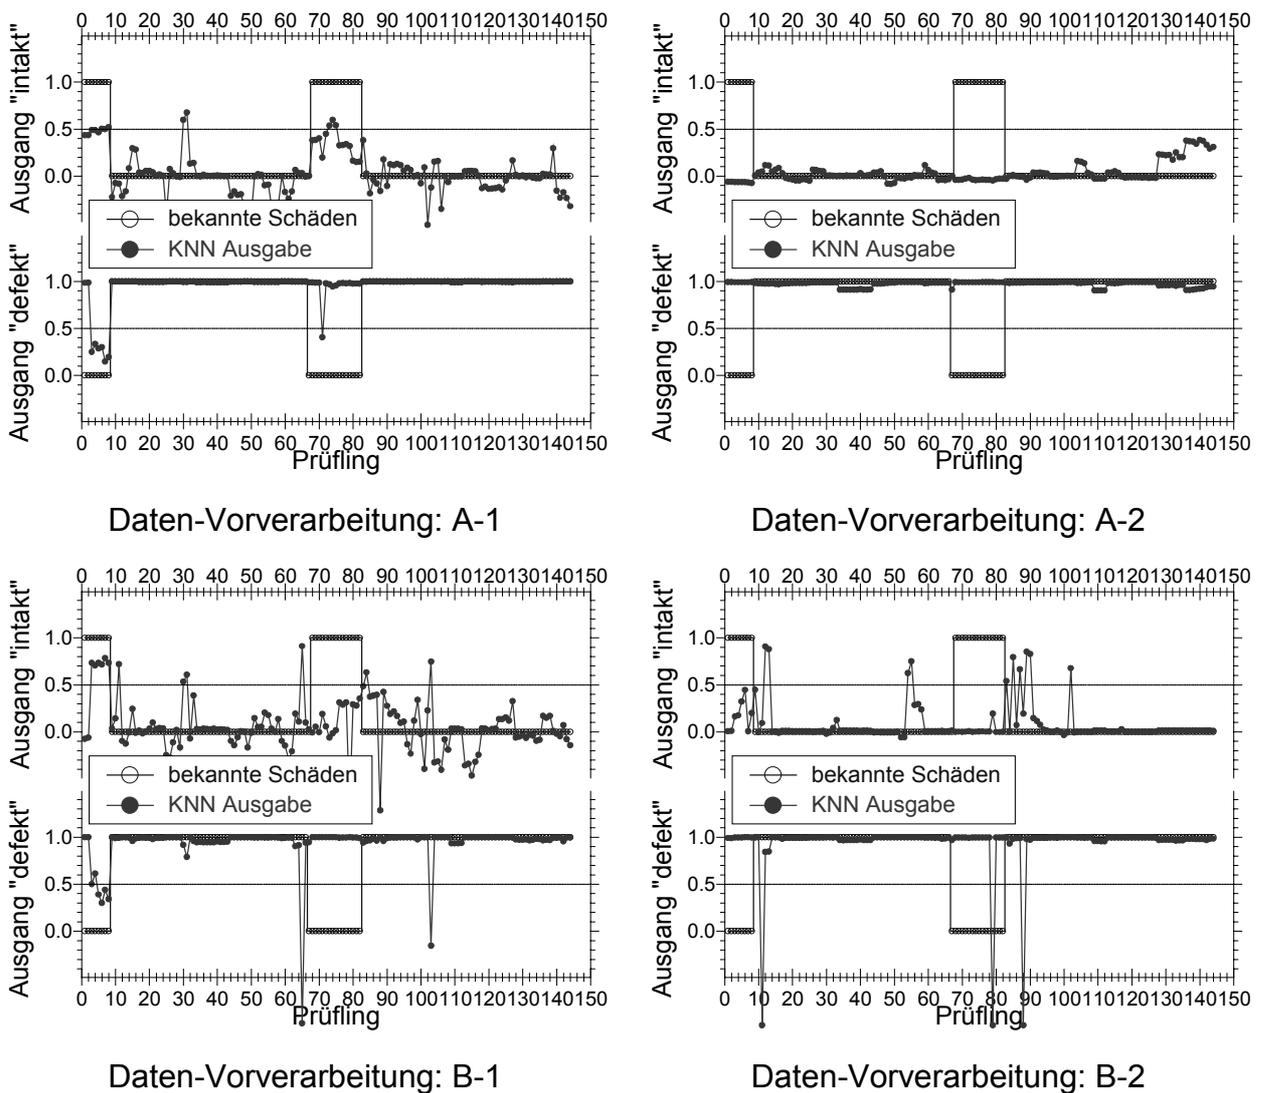


Abbildung 4-25: Klassifikationsausgabe des 10x5x2-KNN für die DVV A-1, A-2, B-1 und B-2 unter Einsatz des Trainingssets D3-EXP/NUM (Substitution der „Intakt“-Spektren mit numerischen Spektren) und des Prädiktionssets D2-EXP

Abbildung 4-25 verdeutlicht, dass mit zunehmender Verfeinerung der Vorverarbeitung (A-1 zu A-2) die Klasse „intakt“ schlechter approximiert wird. Dies gilt besonders

für die Betrachtung der Spektren unter Berücksichtigung ihrer Übertragungsfunktion (B-Verfahren). Da in der Trainingsphase die „defekten“ Datensätze unverändert sind, zeigen diese keine Veränderung zu vorangegangenen Prädiktionen (vgl. Abschnitt 4.3) auf. Die in Tabelle 4-7 ausgewiesenen Fehlerraten unterstreichen dies.

Tabelle 4-7: Vergleichende Aufstellung der Fehlerraten der Prädiktionen von Abbildung 4-25 (Substitution der „Intakt“-Spektren mit numerischen Spektren)

Daten-Vorverarbeitung	Fehler der Prädiktion		
	intakt	defekt	Gesamtfehler
A-1	86,9 %	1,7 %	15,4 %
A-2*	100,0 %	0,0 %	16,8 %
B-1	78,3 %	5,0 %	16,8 %
B-2*	100,0 %	10,0 %	24,5 %

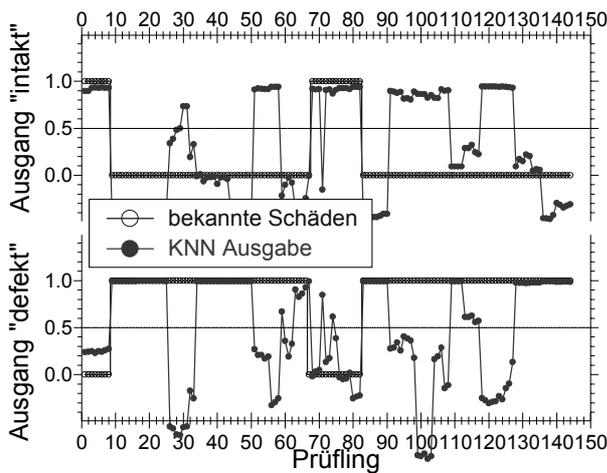
Verwendete Datenpools: D3-EXP/NUM + D2-EXP (entsprechend der DVV)

KNN-Topologie: 10x5x2

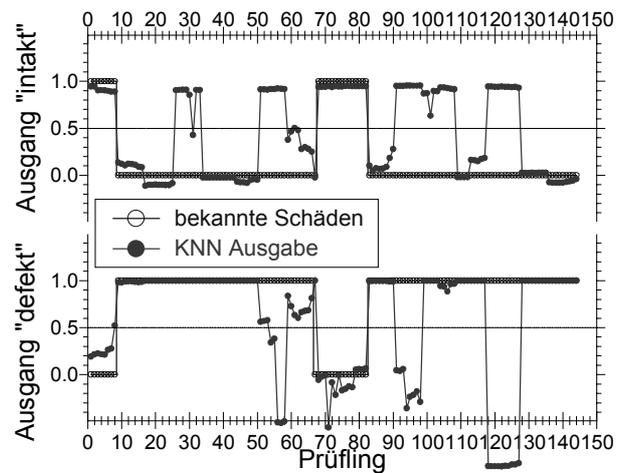
* Dieses Ergebnis ist auf fehlende Generalisierung des KNN zurückzuführen.

Die Betrachtung der Klasse „intakt“ zeigt eindeutig, dass die Substituierung der „Intakt“-Spektren für das vorliegende Netzwerk nicht möglich ist. Die Abweichung der numerisch berechneten und der experimentell ermittelten Spektren erweisen sich als zu groß. Die Überschneidung mit trainierten und somit als „defekt“ klassifizierten Grenzfällen begründet dies.

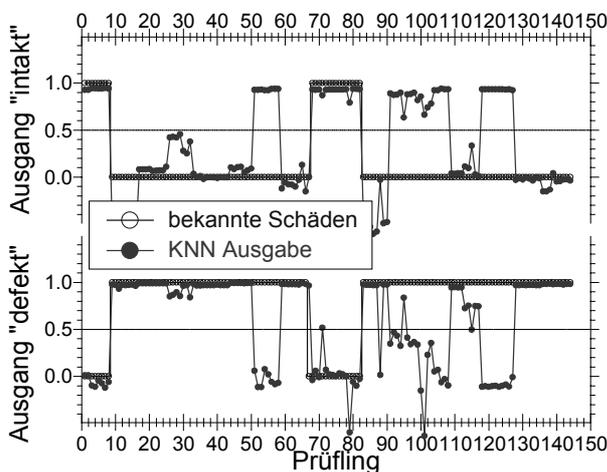
Da die Klasse „defekt“ eine bedeutend größere Anzahl von möglichen Spektren abdeckt, wird nachfolgend die gegensätzliche Substitution der kompletten „defekten“ Datensätze durch entsprechende numerische Datensätze demonstriert (vgl. Abbildung 4-26).



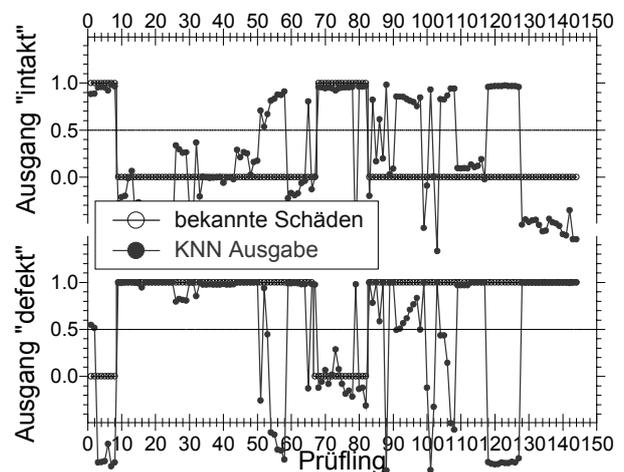
Daten-Vorverarbeitung: A-1



Daten-Vorverarbeitung: A-2



Daten-Vorverarbeitung: B-1



Daten-Vorverarbeitung: B-2

Abbildung 4-26: Klassifikationsausgabe des 10x5x2-KNN für die DVV A-1, A-2, B-1 und B-2 unter Einsatz des Trainingssets D4-EXP/NUM (Substitution der „Defekt“-Spektren mit numerischen Spektren) und des Prädiktionssets D2-EXP

Die Daten in Abbildung 4-26 demonstrieren, dass eine Substitution der Trainingsmuster mit „Defekt“-Spektren der zu klassifizierenden Schadensfälle eine „gezielte“ Verbesserung des Trainingserfolgs mit sich bringt. Jedoch bereitet eine scharfe Abgrenzung von solchen Fällen, deren Frequenzspektren ähnlich dem intakten Getränkekastens sind, mit der zunehmenden Anzahl von Mustern bei der Prädiktion des Testsets Probleme. Dies lässt sich an dem großen Unterschied der Fehlerraten von Tabelle 4-7 und Tabelle 4-8 ablesen. Die problematischen Schäden der „defekt“ substituierten Trainings werden hier deutlich als folgende: teilweise Schaden E7 (Prüfling 26-33), teilweise E13 (Pr. 51-58), E6 (Pr. 90-97), E9 (Pr. 102-107) und E14 (Pr. 117-126). Konkret handelt es sich um den dem Sensor gegenüberliegenden

Griffriß (E6) und um den Riss an der steifen schmalen Seite unterhalb des intakten Griffs (E13, E14), die durch ähnliche Spektren zu Fehlklassifikationen neigen. Die Schäden E7 und E9 (multiple Gefacheschäden) sind für das KNN in dieser Form ebenfalls unbekannt. Gegenüber dem rein experimentellen Datenpool von Abschnitt 4.3.1 verdeutlicht dies, dass die Überschneidungen zwischen diesen Spektren numerischer und experimenteller Herkunft zur unsicheren Prädiktion führt.

Tabelle 4-8: Vergleichende Aufstellung der Fehlerraten der Prädiktionen von Abbildung 4-26 (Substitution der „Defekt“-Spektren mit numerischen Spektren)

Daten-Vorverarbeitung	Fehler der Prädiktion		
	intakt	defekt	Gesamtfehler
A-1	8,7 %	39,2 %	34,3 %
A-2	4,3 %	35,8 %	30,8 %
B-1	4,3 %	31,7 %	27,3 %
B-2	13,0 %	30,8 %	28,0 %

Verwendete Datenpools: D4-EXP/NUM + D2-EXP (entsprechend der DVV)

KNN-Topologie: 10x5x2

Diese Ergebnisse führen zu der Feststellung, dass bei diesem Netzwerk (10x5x2) der Ersatz der experimentellen Daten nur im Falle exakter Übereinstimmung mit den numerischen möglich ist. Da sich dies, wie in Abschnitt 4.1.3 diskutiert, nicht vollständig erreichen lässt, ist diese Anwendung in der vorliegenden Form nur bedingt einsetzbar. Die Problematik der fehlerhaften Klassifizierung in „defekt“ anstelle von „intakt“ und in „intakt“ anstelle von „defekt“ liegt in verstärkter Form vor [103]. Dennoch zeigt die Simulation, dass diese geringfügigen Ungenauigkeiten bei der Betrachtung „starker“ Schäden nicht ins Gewicht fallen, da hier die Hauptpeaks ihre Position und Amplitude in großem Maße verändern (z. B. E10 und E12 der Prüflinge 34-50), so dass deren Klassifikation möglich ist, obwohl das Netz auch dabei manchmal zu Fehlgeneralisierung neigen kann.

Die Klassifikation in der hier diskutierten Form ist für die Neuronumerik zu unsicher. Dennoch ist ersichtlich, dass eine unterstützende Beimischung von Spektren numerischen Ursprungs erfolgversprechend ist, wenn diese gezielt ausgewählt werden.

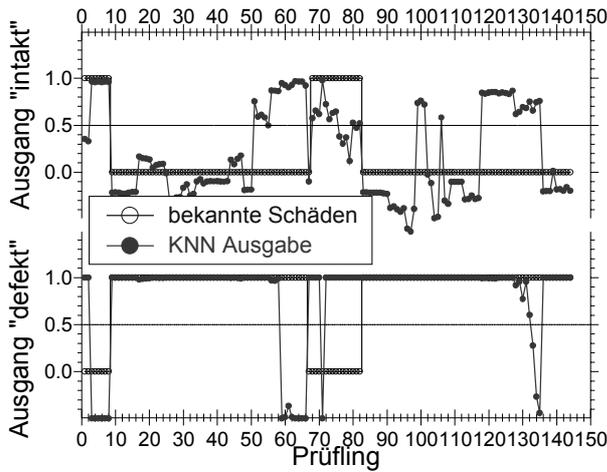
4.4.1.2 KNN trainiert mit rein numerischem Datenpool, Prädiktion mit rein experimentellem Datenpool - vice versa

Der vorangegangene Abschnitt zeigt, dass eine Substitution von Daten numerischen Ursprungs für das Uni-Sensorsystem problematisch ist. Dennoch wird hier in kurzer Form anhand des bereits bekannten Beispiels ein KNN-Training rein numerischer Datensätze mit der Prädiktion experimenteller Datensätze sowie die Prädiktion numerischer Datensätze des mit experimentellen Daten trainierten KNN am unveränderten Netzwerk studiert (vgl. Tabelle 4-9).

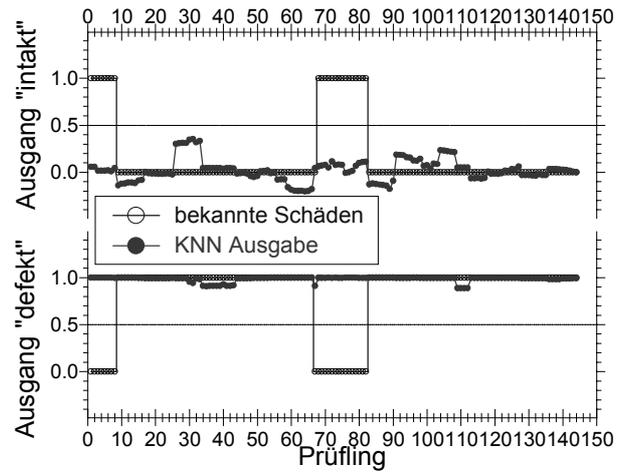
Tabelle 4-9: Substituierten der experimentellen mit numerischen Datensätzen nach Tabelle 7-5

	Trainings- /Testsets	Prädiktionssets
I.	D1-EXP identisch dem Datenpool der Trainingsphase von Abschnitt 4.3	D5-NUM rein numerischer Datensatz
II.	D6-NUM rein numerischer Datensatz	D2-EXP identisch dem Datenpool der Prädiktionsphase von Abschnitt 4.3

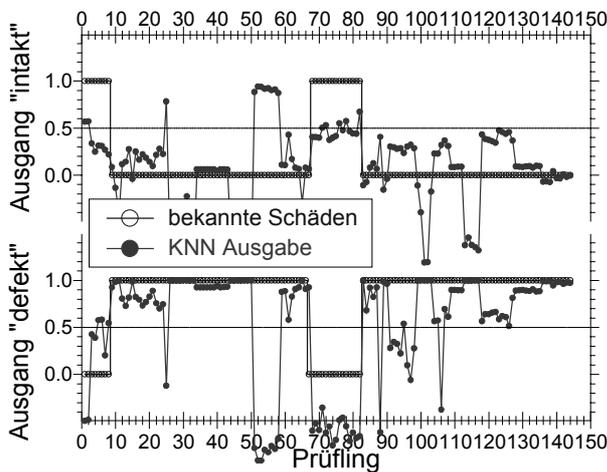
Diese Präsentation erfolgt, um das Netz hinsichtlich seiner Generalisierungsfähigkeit vollständig auszutesten (vgl. Abbildung 4-27). Das bedeutet, dass Grenzfälle hier noch stärker ins Gewicht fallen. Dabei kann nachfolgend neben den zu erwartenden Problemfällen der ähnlichen Spektren auch die Spezifizierung der Datenvorverarbeitung beurteilt werden.



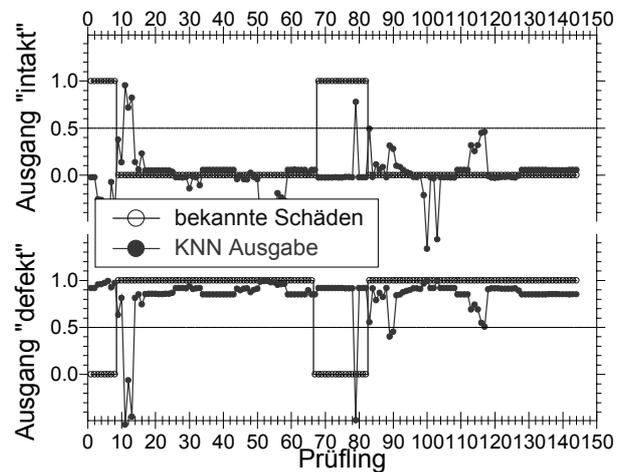
Daten-Vorverarbeitung: A-1



Daten-Vorverarbeitung: A-2



Daten-Vorverarbeitung: B-1



Daten-Vorverarbeitung: B-2

Abbildung 4-27: Klassifikationsausgabe des 10x5x2-KNN für die DVV A-1, A-2, B-1 und B-2 unter Einsatz des Trainingssets D5-NUM und des Prädiktionssets D2-EXP

Die Graphen in Abbildung 4-27 belegen, dass die Methode der geshifteten Datenvorverarbeitung (A-2, B-2) die Spektren für diese neuronumerische Anwendung zu genau unterteilt und damit dem KNN die Generalisierungsfähigkeit nimmt. Sämtliche Spektren werden der Klasse „defekt“ zugeordnet. Bei den Methoden A-1 und B-1 liegt zwar in Grundzügen auch eine „intakt“ Klassifizierung vor, die jedoch nicht zufriedenstellend ist. Dies zeichnet sich ebenso in den Fehlerraten (Tabelle 4-10) ab.

Tabelle 4-10: Vergleichende Aufstellung der Fehlerraten der Prädiktionen von Abbildung 4-27

Daten-Vorverarbeitung	Fehler der Prädiktion		
	intakt	defekt	Gesamtfehler
A-1	69,6 %	31,7 %	37,8 %
A-2*	100,0 %	0,0 %	16,1 %
B-1	69,6 %	15,0 %	23,8 %
B-2*	95,7 %	4,2 %	18,9 %

Verwendete Datenpools: D5-NUM + D2-EXP (entsprechend der DVV)

KNN-Topologie: 10x5x2

* Dieses Ergebnis ist auf fehlende Generalisierung des KNN zurückzuführen.

Der Vollständigkeit halber erfolgt anschließend die Beschreibung der Prädiktion eines rein numerischen Datenpools (D6-NUM) mit dem 10x5x2-KNN, das bereits in Abschnitt 4.3.1 mit rein experimentellen Daten parametrisiert wurde. Nachfolgend illustriert Abbildung 4-28 die Prädiktionsausgabe des numerischen Datenpools. Dabei werden die beiden Vorverarbeitungsverfahren B-1 und B-2 betrachtet. Auf Darstellung der A-Verfahren wird hier verzichtet, da sie vergleichbare unzureichende Ergebnisse liefern. Tabelle 4-11 listet die zugehörigen Fehlerraten auf.

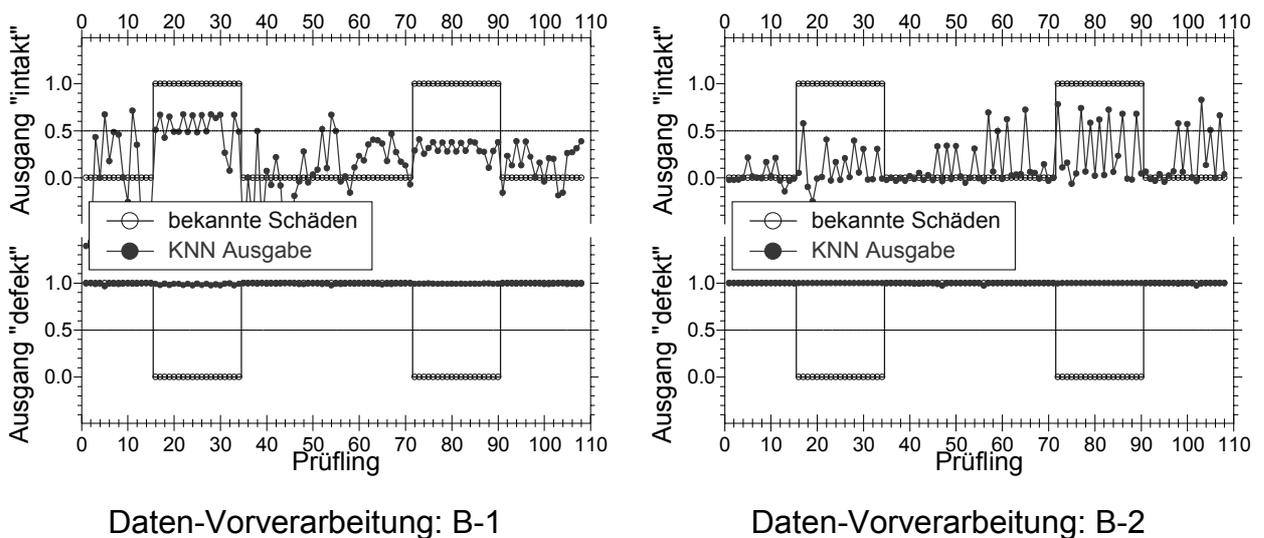


Abbildung 4-28: Klassifikationsausgabe des 10x5x2-KNN für die DVV B-1 und B-2 unter Einsatz des Trainingssets D1-EXP und des Prädiktionssets D6-NUM

Tabelle 4-11: Vergleichende Aufstellung der Fehlerraten der Prädiktionen von
Abbildung 4-28 (A-1 und A-2 ohne Graph)

Daten-Vorverarbeitung	Fehler der Prädiktion		
	intakt	defekt	Gesamtfehler
A-1*	100,0 %	23,9 %	50,5 %
A-2*	100,0 %	11,3 %	42,2 %
B-1*	100,0 %	7,0 %	39,4 %
B-2*	100,0 %	12,7 %	43,1 %

Verwendete Datenpools: D1-EXP + D6-NUM (entsprechend der DVV)

KNN-Topologie: 10x5x2

* Dieses Ergebnis ist auf fehlende Generalisierung des KNN zurückzuführen.

Wenn auch die Zuordnung zur Klasse „defekt“ erkennbar wird, ist die Zuordnung zur Klasse „intakt“ am Ausgang „defekt“ nicht vorhanden. Die Approximation der „intakt“ Ausgabe zeigt zwar bei B-1 (Prüfling 15 bis 33) einige Tendenzen, gehorcht aber weitgehend einer zufällig erscheinenden Ausgabe. Betrachtet man beide Ausgaben zusammen, ist das Training mit dem eingesetzten Datenpool ungenügend. Das KNN kann diese Datensätze in dieser Konfiguration nicht klassifizieren. Hierfür wurde es allerdings auch nicht konfiguriert.

Aus diesem Ergebnis kann gefolgert werden, dass das eingesetzte KNN mit der angewandten Datenvorverarbeitungstechnik nicht mit hinreichender Zuverlässigkeit klassifiziert, wenn die Numerik den vollständigen Trainingsdatensatz darstellt. Die Abweichungen der Spektren experimentellen und numerischen Ursprungs stellen für das Uni-Sensorsystem nur schwer vergleichbare und in den meisten Fällen nicht klassifizierbare Muster dar. Die durchgeführte numerische Simulation ist somit für das reines Uni-Sensorsystem zu ungenau. Das bedeutet für die angestrebte „möglichst einfache“ Modellierung des Systems eine Erhöhung der Komplexität des KNN. Das bedeutet in erster Line eine Veränderung bzw. Vergrößerung der Topologie. Der nachfolgende Abschnitt bietet dazu einen Vorschlag und diskutiert dessen Leistungsfähigkeit.

4.4.2 Das Dual-Sensorsystem

Die im vorangegangenen Abschnitt dargestellte Problematik der fehlenden Generalisierungsfähigkeit des Uni-Sensor-KNN führt zur Diskussion des Einsatzes mehrerer Sensoren. Die bereits in Abbildung 4-8 und Abbildung 4-15 dargestellten Ergebnisse zeigen dabei die Möglichkeit der Ausnutzung eines symmetrischen Effekts auf. Bedingt durch die mechanische Übertragung von Schwingungen im Festkörper weisen die Spektren in Nähe von Schäden dabei stark veränderte Peaks auf. Somit werden Grenzfälle eines Sensors mit Hilfe der Information des zweiten Sensors eindeutig bestimmt. Diesen Effekt kann auch ein KNN lernen.

Zur Durchführung eines dazu notwendigen Trainings, das die Information von zwei Sensoren berücksichtigt, erfolgt eine Erweiterung bzw. ein Umbau der Topologie des bis her eingesetzten KNN. Um die bereits erzielten Erkenntnisse weiterhin zu nutzen, wird nachfolgend die Datenvorverarbeitung sowie die Reduzierung der einzelnen Sensorspektren auf jeweils 10 Eingangsneuronen beibehalten (vgl. Abschnitt 3.4). Der Datensatzpool wird ebenso übernommen, er wird lediglich neu sortiert (vgl. Anhang Tabelle 7-5). Seine Zusammenstellung unterliegt denselben Kriterien wie in Abschnitt 4.3.1 beschrieben. Die Topologie wird schrittweise abgeändert. Wichtig ist, dass nunmehr jeweils 2 Spektren zusammengehörig sind, d. h. die Spektren der jeweils gegenüberliegenden Messorte bilden ein Paar (vgl. Abbildung 3-10, Position 1 und 4).

Bei symmetrischer Auswahl der Messorte verhalten sich ihre Spektren im intakten Kastenfall innerhalb der Fehlergrenzen identisch. Diese Tatsache wird jedoch nachfolgend nicht in Form der Differenz der Spektren genutzt. Die Spektren werden, wie in den vorangegangenen Abschnitten, nach der Datenreduzierung auf die Zahl der Eingangsneuronen direkt dem KNN zugeführt, wie dies bereits mit den einzelnen Spektren im Uni-Sensorsystem erfolgte. Dort zeigt sich bei vielen Fällen, dass die Klassifizierung eines Schadens bei der Betrachtung der einen Seite korrekt erfolgt und die Klassifizierung des anderen gegenüberliegenden Spektrums nicht (vgl. Abbildung 4-15). Bei der Betrachtung beider Klassifizierungen zusammen, muss dies allerdings zur Zuordnung in die „defekte“ Klasse führen. Genau dies soll das Dual-Sensor-KNN ermöglichen.

Um das Grundkonzept des untersuchten 10x5x2-KNN beizubehalten, wird nachfolgend die Generalisierungsfähigkeit von drei daraus modifizierten KNN-Topologien besprochen. Die Modifikationen führen dabei zu zwei komplexeren und einer vereinfachten Konfiguration, wie sie in Tabelle 4-12 aufgelistet und gemäß Tabelle 3-6

aufgebaut sind. Dabei werden zwei bestehende 10x5x2-KNN mittels zusätzlicher verdeckter Neuronenschichten zusammengeführt, um zur Ausgabe eines „intakt“ und eines „defekt“ Neurons zu gelangen. Es ergeben sich so für den Sensor an Pos. 1 die Eingangsneuronen 1 bis 10 und für den Sensor an Pos. 4 die Eingänge 11 bis 20 (vgl. Abbildung 3-10).

Tabelle 4-12: Modifikationen des 10x5x2-KNN zum Dual-Sensor-KNN
(Schematische Abbildungen dazu vgl. Tabelle 3-6)

Topologie	Modifikation
$2 \times (10 \times 5 \times 2) \times 5 \times 2$	Zusammenführung mittels zusätzlicher verdeckter Neuronenschichten
$2 \times (10 \times 5) \times 2$	Reduzierung auf eine verdeckte Schicht
$20 \times 10 \times 2$	Verbindung aller Neuronen zweier aufeinander folgender Schichten

Verwendete Datenpools: D8-NUM + D7-EXP (entsprechend der DVV)

Der Trainingsdatenpool besteht nachfolgend aus Datensätzen rein numerischen Ursprungs (D8-NUM). Dabei erfolgte die Berechnung von numerischen Modellschäden, wie sie Abbildung 7-1 auflistet, und die Zusammenstellung des Datenpools gemäß Tabelle 7-6. Zu dem für alle Topologien eingesetzten Prädiktionsdatensatz (D7-EXP) muss angemerkt werden, dass es aus den Datenpaaren EP1 bis EP9 (vgl. Tabelle 7-2) besteht und wie in Tabelle 7-6 beschrieben, auch Spektrenpaare nicht zeitgleicher Messungen enthält. „Nicht zeitgleich“ bedeutet dabei, dass bei der Zusammenstellung der Prädiktionspaare Signale unterschiedlicher Messchargen verwendet werden, um dadurch die Daten zusätzlich zu verrauschen und Grenzfälle für das KNN zu schaffen. Dabei werden die Datenpaare mit den „künstlichen“ Abweichungen gemäß Abbildung 4-13 zusammengestellt. Außerdem werden die Datenpaare als „links-rechts“ (Prüflinge 1-45) und „rechts-links“ (Prüflinge 46-90) Kombination präsentiert. Dabei wird der einfachste Fall ausgenutzt, in dem ein Kasten um 180° gedreht bereitsteht, der Schaden sich somit auf der gegenüberliegenden Seite befindet und dem KNN als seitenvertauscht präsentiert wird. Als Nebeneffekt wird dadurch der Umfang des Datenpools verdoppelt.

4.4.2.1 Zusammenführung zweier 10x5x2-KNN mittels zusätzlicher verdeckter Neuronenschichten

Vorab muss bemerkt werden, dass alle verdeckten Neuronen dieselbe Funktion haben. Kein Neuron wird speziell normiert oder erhält festgelegte Ausgaben. Somit werden nachfolgend, wie auch in den vorangegangenen Abschnitten, jeweils neue Trainingsphasen durchgeführt und die Netzwerkparameter somit für jeden Anwendungsfall bestimmt.

Den Ausgangspunkt bildet die Zusammenführung zweier bestehender 10x5x2-KNN mittels zwei zusätzlicher verdeckter Neuronenschichten, um wiederum zur Ausgabeform „intakt“ und „defekt“ zu gelangen. Es ergibt sich das $2 \times (10 \times 5 \times 2) \times 5 \times 2$ -KNN, das zwei 10x5x2-„Stränge“ an deren Ausgängen verbindet (vgl. Tabelle 3-6). Diese Maßnahme erhöht die Komplexität des Netzwerkes und es kann dabei zu einem erhöhten Bedarf an Trainingsdatensätzen kommen, wodurch auch die Generalisierungsfähigkeit des KNN beeinflusst wird. Die nachfolgend in Abbildung 4-29 aufgeführten Klassifizierungsgraphen sowie die Gegenüberstellung in Tabelle 4-13 geben Aufschluss über die erlangte Tauglichkeit.

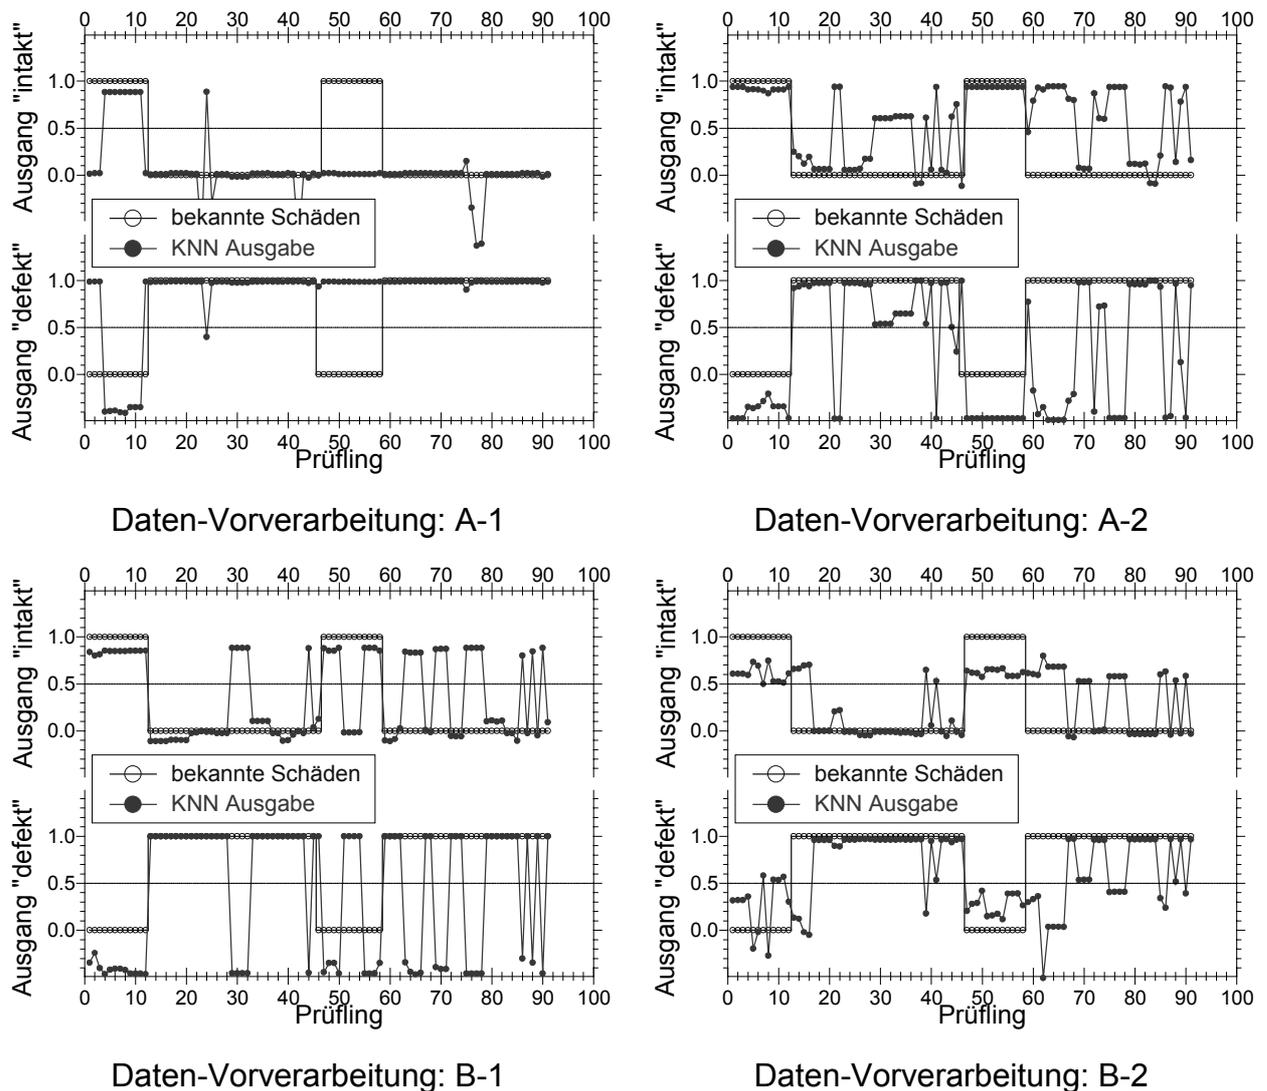


Abbildung 4-29: Klassifikationsausgabe des 2x(10x5x2)x5x2-KNN für die DVV A-1, A-2, B-1 und B-2 unter Einsatz des Trainingssets D8-NUM und des Prädiktionssets D7-EXP

Tabelle 4-13: Vergleichende Aufstellung der Fehlerraten der Prädiktionen von Abbildung 4-29

Daten-Vorverarbeitung	Fehler der Prädiktion		
	intakt	defekt	Gesamtfehler
A-1	66,7 %	1,5 %	18,5 %
A-2	4,2 %	50,0 %	38,0 %
B-1	16,7 %	27,9 %	25,0 %
B-2	16,7 %	36,8 %	31,5 %

Verwendete Datenpools: D8-NUM + D7-EXP (entsprechend der DVV)

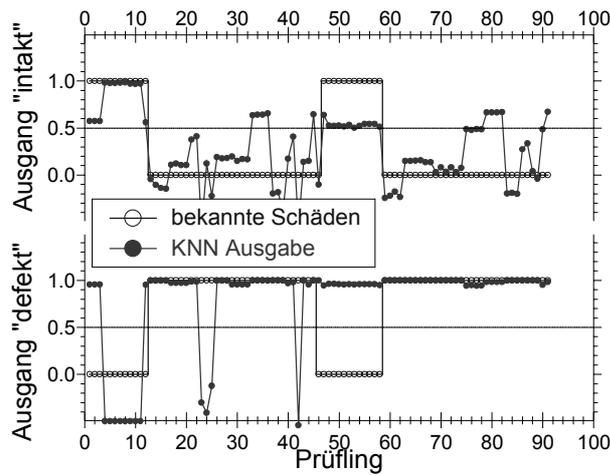
KNN-Topologie: 2x(10x5x2)x5x2

Die Vorverarbeitung gemäß A-1 ergibt in diesem Zusammenhang eine starke Verschiebung hin zur Prädiktion „defekt“ (Fehler 1,5 %). Einen Großteil der „intakten“ Prüflinge ordnet das Netz ebenfalls dort „falsch“ zu. Der große Fehler (66,7 %) resultiert allerdings aus der kleinen Prüflingsanzahl. Im Gegensatz dazu erzielt das KNN mit der Vorverarbeitung A-2 eine gute Prädiktion der Klasse „intakt“ (Fehler 4,2 %) und schlechte Prädiktion für die Klasse „defekt“, wodurch der Gesamtfehler auf 38 % steigt. Die Berücksichtigung des Signals der Übertragungsfunktion (DVV: B-1 und B-2) erbringt dafür keine Verbesserung, auch wenn B-1 relativ ausgeglichen einen Gesamtfehler von 25 % erzielt. Das KNN erweist sich so als lediglich für eine Klasse trainierbar, während die andere Klasse deutliche Fehlklassifikationen auf zeigt.

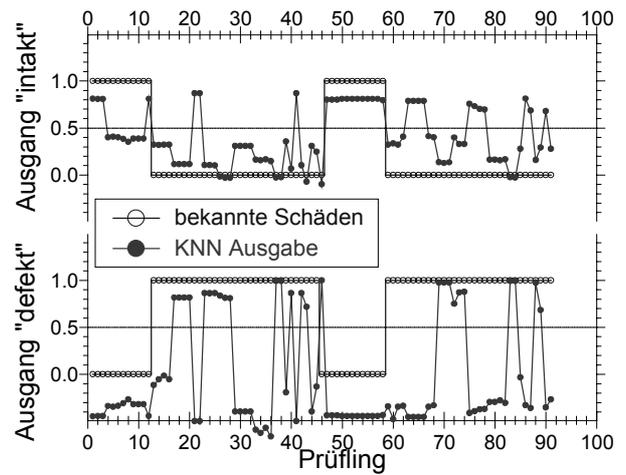
Auch zeigt sich aufgrund der Fehlerhäufung im jeweils rechten Graphenabschnitt (Prüflinge 46-90), dass in der Trainingsphase die Datensätze nicht ausgewogen „links-rechts“ bzw. „rechts-links“ vertauscht sind, wodurch die Klassifizierung negativ beeinflusst wird. Sowohl die numerischen als auch die experimentellen Spektren der jeweiligen Seite sind demnach dem KNN nicht ähnlich genug (vgl. Abbildung 4-8). Das lässt den Schluss zu, dass dieses Netz sehr genau approximiert, dabei jedoch seine Generalisierungsfähigkeit bezüglich unbekannter Fälle verringert.

Eine zusätzliche Erkenntnis erbringt die Beobachtung der als „zeitgleiche“ Aufnahmen dem Netzwerk präsentierten Paare (vgl. Tabelle 7-2). Das KNN erkennt diese Paare in den meisten Fällen, wohingegen „nicht zeitgleiche“ Paare, die zur Verrauschung der Datensätze erstellt und auch dem Datenpool zugesetzt wurden, Fehlklassifikationen hervorrufen (vgl. z. B. für A-2: Pr. 29-32, 51-55, 63-67, 69-71, 75-77). Auch das spiegelt die unzureichende Generalisierungsfähigkeit des KNN wider. Das zu Vergleichszwecken getestet $2x(10x5x2)x3x2$ -KNN lieferte zum vorgestellten $2x(10x5x2)x5x2$ -KNN vergleichbare Ergebnisse und wird im Rahmen dieser Arbeit nicht diskutiert.

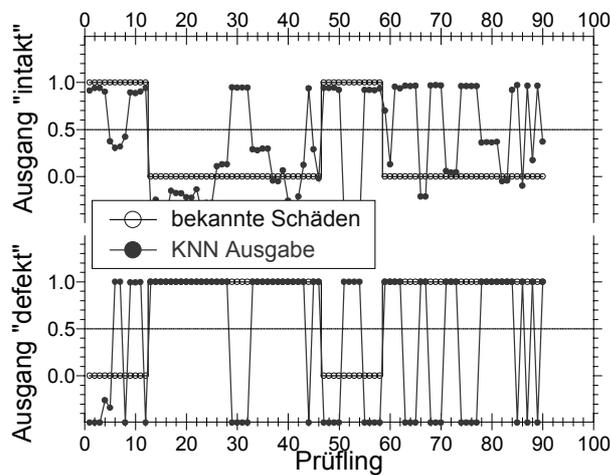
Als Folgerung aus dem diskutierten, hochspezifiziert erscheinenden KNN, das teils die Eigenschaften „defekt“ oder auch „intakt“ ungenau generalisiert, wird die Topologie auf eine verdeckte Schicht verkleinert, um die Generalisierungsfähigkeit zu erhöhen. Die Ausgänge der beiden $10x5x2$ -Stränge der jeweiligen Sensorspektren werden direkt in zwei Ausgangsknoten zusammengeführt. Der Aufbau erfolgt gemäß Tabelle 3-6 zu einem $2x(10x5)x2$ -KNN. Abbildung 4-30 und Tabelle 4-14 zeigen dessen Prädiktionsausgabe.



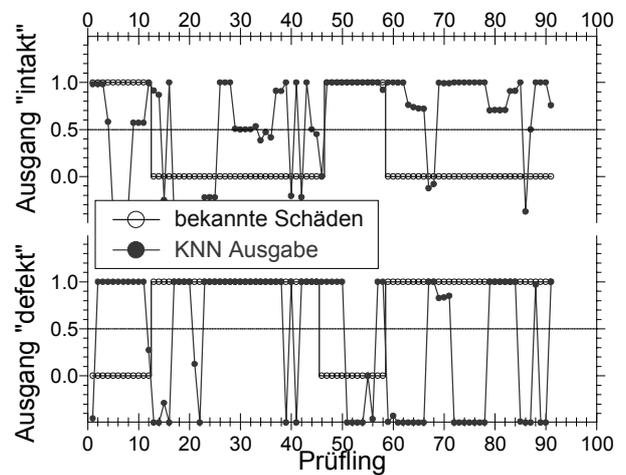
Daten-Vorverarbeitung: A-1



Daten-Vorverarbeitung: A-2



Daten-Vorverarbeitung: B-1



Daten-Vorverarbeitung: B-2

Abbildung 4-30: Klassifikationsausgabe des 2x(10x5)x2-KNN für die DVV A-1, A-2, B-1 und B-2 unter Einsatz des Trainingssets D8-NUM und des Prädiktionssets D7-EXP

Tabelle 4-14: Vergleichende Aufstellung der Fehlerraten der Prädiktionen von Abbildung 4-30

Daten-Vorverarbeitung	Fehler der Prädiktion		
	intakt	defekt	Gesamtfehler
A-1	20,8 %	20,6%	20,7 %
A-2	33,3 %	58,8 %	52,2%
B-1	41,7 %	33,8 %	35,9 %
B-2	70,8 %	63,2 %	65,2 %

Verwendete Datenpools: D8-NUM + D7-EXP (entsprechend der DVV)

KNN-Topologie: 2x(10x5)x2-KNN

Es fällt auch in Abbildung 4-30 auf, dass außer bei A-1 die bereits des Öfteren als problematisch eingestuften Prüflinge (EP7 - Seitenriss (Pr. 29-32, 75-77), EP3 - Griffschaden (Pr. 17-20, 61-64)) nicht richtig klassifiziert werden, obwohl einige ihrer Nachbarn, die identische Schadensfälle verkörpern, erkannt werden. Beim Betrachten der Datenpoolzusammenstellung (vgl. Tabelle 7-6) wird wiederum deutlich, dass es sich dabei um Spektrenpaare handelt, deren Zusammenstellung mit „nicht zeitgleich“ aufgenommenen Spektren erwirkt wurde. Durch die beschriebene „künstliche Ungenauigkeit der Spektren“ (vgl. Abbildung 4-13) ist dies als ein dem Netz vorgesetzter Schaden interpretierbar. Somit steht die Klassifikation im Gegensatz zur Vorgabe und führt zur falschen Zuordnung.

Für den Fall A-1 jedoch ermöglicht die direkte Verwendung der Signale eine im Vergleich zu den anderen Vorverarbeitungsverfahren als „gut“ erscheinende Klassifizierung mit einem Gesamtfehler unter 21 %. So erweisen sich hier die Ergebnisse, verglichen mit denen des größeren $2 \times (10 \times 5 \times 2) \times 5 \times 2$ -KNN, dessen Klassifikationsausgabe Abbildung 4-29 darstellt, als minderwertiger. Es deutet hier besonders darauf hin, dass dieses $2 \times (10 \times 5) \times 2$ -KNN im Ganzen betrachtet weniger generalisiert, als vielmehr spezifiziert und nur einige spezielle Muster erkennt.

Als mögliche Ursache erweist sich dabei, die auf zwei Stränge fixierte Netztopologie. So widmet sich als Konsequenz hierauf der nachfolgende Abschnitt dem Studium eines Netzwerkes, das die beiden bisher getrennt gehaltenen Sensorstränge ($10 \times 5 \times 2$ und 10×5) bereits bei der Eingabe verbindet.

4.4.2.2 Modifizierung des zweisträngigen Dual-Sensor-KNN zu einem einsträngigen $20 \times 10 \times 2$ -KNN

Der vorangegangene Abschnitt 4.4.2.1 diskutiert die Hypothese, dass eine Verkleinerung der Netzwerkgröße die Generalisierungsfähigkeit des KNN erhöht, die sich aber in der untersuchten zweisträngigen Topologie als zu spezifiziert erweist. In Anbetracht dessen erscheint es vorteilhaft, die Neuronen einer Schicht vollständig mit der nachfolgenden zu vernetzen, d. h. die der beiden Stränge, um somit durch eine Verallgemeinerung der Topologie die Komplexität des KNN etwas zu erhöhen. Dazu wird ein $20 \times 10 \times 2$ -KNN eingesetzt (vgl. Tabelle 3-6). Die Resultate der Prädiktion dieses KNN präsentieren Abbildung 4-31 und Tabelle 4-15.

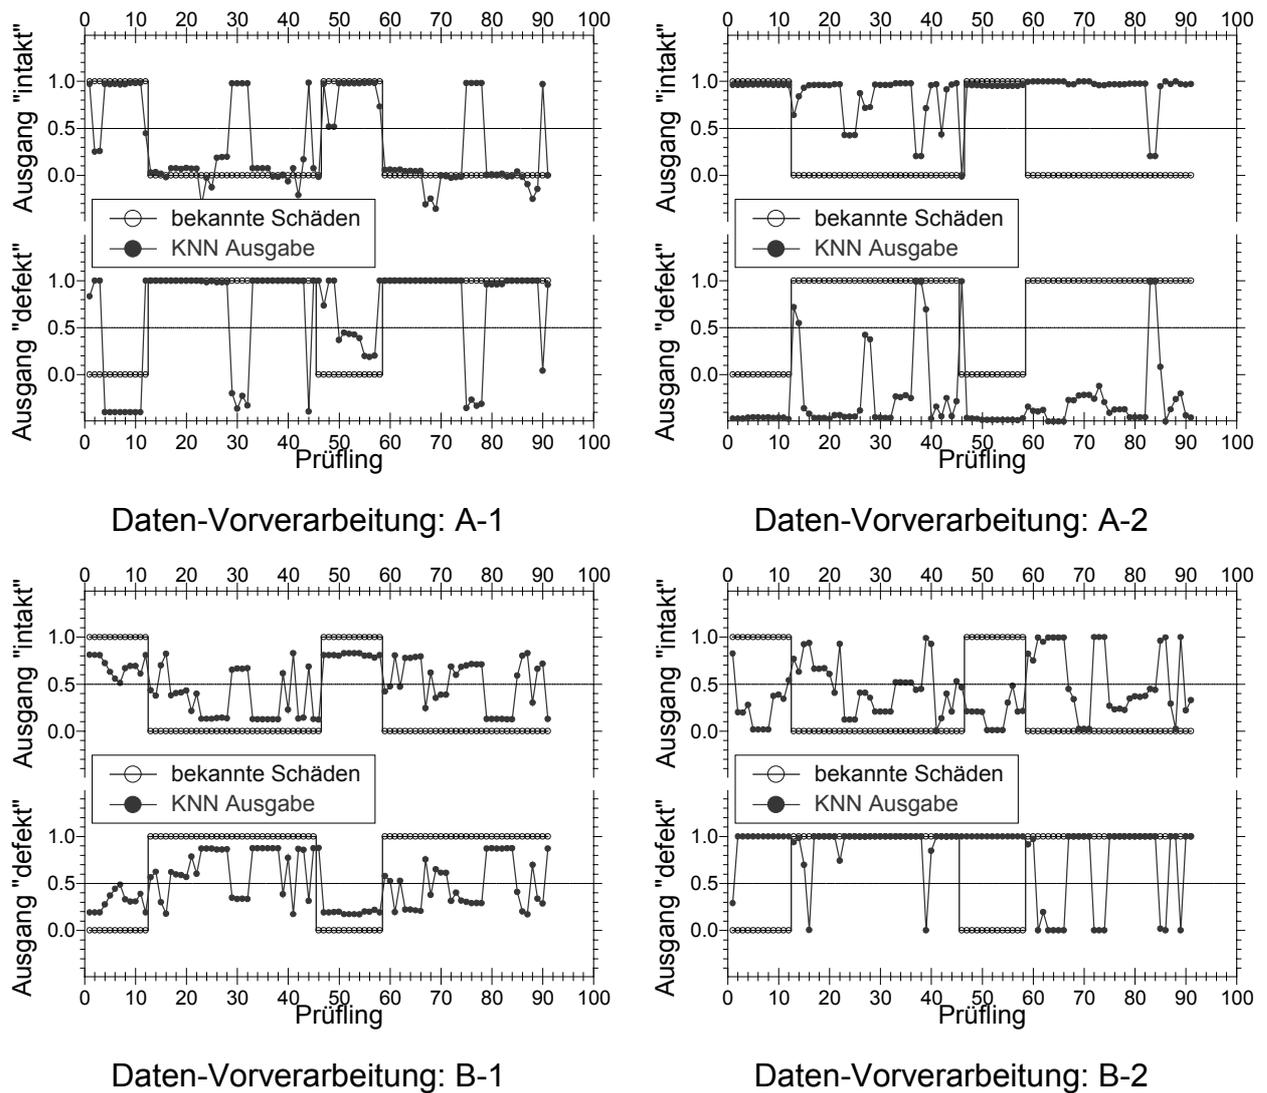


Abbildung 4-31: Klassifikationsausgabe des 20x10x2-KNN für die DVV A-1, A-2, B-1 und B-2 unter Einsatz des Trainingssets D8-EXP und des Prädiktionssets D7-NUM

Tabelle 4-15: Vergleichende Aufstellung der Fehlerraten der Prädiktionen von Abbildung 4-31

Daten-Vorverarbeitung	Fehler der Prädiktion		
	intakt	defekt	Gesamtfehler
A-1	37,5 %	14,7 %	20,6 %
A-2	4,2 %	92,6 %	69,6 %
B-1	4,2 %	39,7 %	30,4 %
B-2	95,8 %	44,1 %	57,6 %

Verwendete Datenpools: D8-NUM + D7-EXP (entsprechend der DVV)

KNN-Topologie: 20x10x2

Die Auftragungen in Abbildung 4-31 demonstrieren erneut, dass die feineren Vorverarbeitungsverfahren (A-2, B-2) zu sehr schlechten Prädiktionen führen (Fehler einzelner Klassen > 90 %). Auch das Verfahren B-1 liefert einen Gesamtfehler von 30,4 % und für die Klassifikation „defekt“ schlechte Werte (Fehler 39,7 %).

Das Vorverarbeitungsverfahren A-1 ermöglicht allerdings bei einem Gesamtfehler von 20,6 % eine Prädiktion der Klasse „defekt“ mit einem vergleichbar geringen Fehler von 14,7 %, wobei lediglich der bereits bekannte Problemfall EP7 (kleiner Seitenriss) in der Klasse „defekt“ falsch zugeordnet wird (Prüflinge 29-32, 44 und 75-78, 90). Im Unterschied zu den anderen Vorverarbeitungen hat A-1 keine Probleme mit dem zweiten bekannten Grenzfall EP3 (Griffriss, Pr. 17-20 und 61-64). Dabei ist es auch unbedeutend, ob der Schaden als LS-RS (Prüflinge 17-20) oder als RS-LS Kombination (Prüflinge 61-64) präsentiert wird. Der große Fehler der „intakt“ Klassifizierung bei A-1 (Fehler 37,5 %) begründet sich in der kleinen Testmenge, so dass der Fehler bereits bei wenigen falsch klassifizierten Prüflingen (Pr. 1-3, 11 und 45-48) stark ansteigt. Die Auswertung des Graphen (DVV A-1) von Abbildung 4-31 zeigt dazu jedoch, dass diese fehlerhaften Datenpaare alle „nicht zeitgleich“ aufgenommen sind. Gerade diese Erkenntnis führt zu der Feststellung, dass das Netzwerk unverrauschte Daten sehr gut klassifiziert, jedoch Probleme bei übermäßig verrauschten Datensätzen aufweist. Die Generalisierungsfähigkeit ist also vorhanden, auch wenn sie begrenzt ist.

Der Vergleich zur Klassifikationsausgabe des $2 \times (10 \times 5 \times 2) \times 5 \times 2$ -KNN (DVV A-1 aber auch B-1) zeigt nur eine geringfügige Abweichung der Generalisierungsfähigkeit auf. Somit scheint für zukünftige Anwendungen das kompaktere $20 \times 10 \times 2$ -KNN besser geeignet, da es durch seine verallgemeinerte Topologie einfacher adaptierbar ist.

Als Folgerung der Netzwerkverkleinerung und anschließenden Verschmelzung der Stränge zeigte sich, dass in Anbetracht der vorhandenen Abweichungen der Simulation das Netzwerk bei höherer Spezifizierung seine Generalisierungsfähigkeit vermindert. In der vorliegenden Konfiguration ist es jedoch gelungen, die Leistungsfähigkeit des KNN zu optimieren. Dies wird, wie die vorangegangenen Untersuchungen zeigten, zum einen durch eine einfache Datenreduzierung (Aufteilen des Spektrums in Frequenzklassen: DVV A-1) und zum anderen durch eine Verallgemeinerung (Verschmelzen der Sensorstränge der des vorderen KNN-Abschnitts) der KNN-Topologie erreicht.

4.5 Folgerungen zum Einsatz der Neuronumerik zur Schadenserkennung an Getränkekästen

Zusammenfassend lässt sich über den Einsatz der Neuronumerik in der vorliegenden Arbeit sagen, dass mit ihr die Konfiguration eines leistungsfähiges Schadenserkennungssystems ermöglicht wird. Die grundlegende Generalisierungsfähigkeit mit numerischen Datensätzen trainierter KNN demonstriert und belegt die Klassifikation von Datensätzen rein experimentellen Ursprungs (Folgerung aus Abschnitt 4.3). Das neuronumerischen Systems zeigt dabei bei der Konfiguration steigende Zuverlässigkeit mit der Anzahl der Sensoren und der Verallgemeinerung der Topologie bei nicht spezialisierter Datenvorverarbeitung (Folgerung aus Abschnitt 4.4). Dies bedeutet gerade unter Berücksichtigung der aufgezeigten Problematik, der Abweichungen der Frequenzspektren numerischer und experimenteller Herkunft, dass besonders der Einsatz von KNN zur Mustererkennung dieser Spektren prädestiniert ist. Durch ihre Generalisierungsfähigkeit erlauben die KNN, die Ursachen der Abweichungen als weitgehend vernachlässigbar zu betrachten, da sie geeignete Klassen approximieren.

Als Ursachen der Abweichungen der Frequenzspektren erweisen sich dabei zum einen auf Seite der experimentellen Untersuchungen Fehler aufgrund von Positionierungsungenauigkeiten von Sensoren und Getränkekästen, die nur mit höherem apparativen Aufwand minimierbar sind. Zum anderen entstehen sie aufgrund von Fertigungstoleranzen und Materialalterung. Auf Seite der numerischen Simulation bedingen vor allem Vereinfachungen in der Simulationsmethode bei numerischen Standardsequenzen, wie es SOL103 bzw. SOL111 (MSC/NASTRAN) sind, aber auch einheitliche Materialparameter für das gesamte Modell, die Abweichungen von numerischen zu experimentellen Spektren. Besonderen Einfluss hat auch die Güte der Vermaschung, die sich beim Einsatz von Netzgeneratoren und den damit verbundenen Fehlern durch einfach handhabbare Elemente (Tetraederelemente) ergibt.

Die Gegenüberstellung numerischer und experimenteller Fehlerquellen untermauert den Einsatz von KNN zur Mustererkennung. Dabei besteht im Gesamtsystem ein enger Zusammenhang mit der Datenpräsentation, also der Vorverarbeitung und Datenreduzierung auf die Netzwerkeingänge. So zeigt sich, dass bei größeren Netzen die Abweichung der Spektren, also bei vielen Überschneidungen der Klassen und Grenzfällen, eine geringere Genauigkeit der Vorverarbeitung nötig ist. Auch behandelt das KNN diese Datensätze generalisierender, wenn die Spezifität des

KNN gering ist, also die Topologie nicht zu komplexe Ausmaße annimmt. So verdeutlicht Abschnitt 4.4.2.2, dass ein einfaches, verallgemeinertes Netzwerk die neuronumerische Datenpräsentation und somit die vorhandenen Abweichungen sehr gut zuordnen kann.

Im Einzelnen werden nachfolgen die Aspekte „Datenpool“, „Datenvorverarbeitung“ und „Topologie“ im Bezug auf ihre Folgen für die Generalisierungsfähigkeit des KNN dieser Arbeit genauer besprochen.

Datenpool

Bei einer intensiveren Beurteilung des gewählten Datenpools und der beinhalteten Modell-Schadensfälle kristallisieren sich die Grenzfälle „Griffriss“ (E6, N7) und „Seitenriss“ (E13, N8) heraus. Sie verdeutlichen dabei die Diskussion der Trennschärfe bzw. Generalisierungsfähigkeit des KNN. Der übrige Pool deckt, wenn auch nicht erschöpfend, so doch einige in der Praxis vorkommende Beschädigungen ab.

Die so beispielhafte immer wiederkehrende Betrachtung der herausgestellten Grenzfälle „Griffriss“ und „Seitenriss“ zeigt deutlich, dass das KNN diesen in rein experimenteller Anwendung exakte richtige Klassifikation ermöglicht. In der Neuronumerik jedoch klassifiziert das KNN gerade diese Grenzfälle unsicherer, da hier die Abweichung zwischen berechneten und gemessenen Spektren an Bedeutung gewinnt. Die Erweiterung auf das Dual-Sensorsystem ermöglicht jedoch, dies zu verbessern. Sie zeigt besonders, dass es mit zwei Sensoren den „Griffriss“ eindeutig zuordnet. Die Detektion des „Seitenrisses“ bleibt jedoch weiter teilweise unsicher. Auch hier würde ein weiterer Sensor auf der Seitenmitte benötigt, möglicherweise auch ein vergleichbares Sensorpaar. Diese zusätzlichen oder alternativen Positionen sind im Rahmen dieser Arbeit nicht erschöpfend untersucht worden, sind jedoch im Hinblick auf die bereits erzielten Erkenntnisse durch spezifische Ausrichtung der Sensitivität des Systems als detektierbar zu erwarten. Allerdings deutet die bereits erlangte Sensitivität der diskutierten Positionen darauf hin, dass auf keinen Fall für jeden neuen Schadensfall ein zusätzlicher Sensor eingeführt werden muss, wenn der Datenpool auf problematische Grenzfälle ausgerichtet ist. In weiterführende Anwendungen sollte deshalb bei der Zusammenstellung des Datenpools besonders Wert auf die Art und Häufigkeit tatsächlich auftretender Schäden im Mehrwegkreislauf gelegt werden, um reale Problemfälle besser eingrenzen zu können.

Eine weitere, wichtige Erkenntnis zur Datenpoolzusammensetzung verdeutlicht die numerische Substitution von experimentellen Spektren „defekter“ Kästen. Sie erweist

sich als äußerst leistungsfähig. Ihre Funktionalität beruht auf der Existenz „intakter“ experimenteller Frequenzspektren, die grundlegend zur Validierung des numerischen Systems benötigt werden. Die „Defekt“-Spektren sind anschließend simulierbar und zum Training des KNN einsetzbar. Dabei muss nicht jeder einzelne Schaden validiert werden. Geringfügige Abweichungen und Ungenauigkeiten stören die Klassifizierung in „intakt“ und „defekt“ nicht. Sie fördern meist sogar die Generalisierungsfähigkeit des KNN für unbekannte Fälle.

Datenvorverarbeitung

Voraussetzung bei der Konfiguration des Netzes ist, dass das Trainingsdatenset die zu klassifizierenden Muster abdeckt und auch Grenzfälle berücksichtigt. Bei der Datenvorbereitung für den Netzwerkeingang ist darauf zu achten, dass nicht hier bereits dem KNN die Möglichkeit des Generalisierens genommen wird. Dies kann geschehen, indem die Informationsreduzierung zuviel „Expertenwissen“ voraussetzt, und nicht der Parametrierung des Netzwerkes durch das Training überlässt. Die Approximations- und Generalisierungsbreite des Netzes würde dadurch bereits erheblich eingeschränkt.

Das führt bei den Verfahren dieser Arbeit dazu, dass die Datenreduzierung auf 10 Eingangsknoten durch Integration von Frequenzklassen eine feine, spezifische Klassifizierung erlaubt, die je nach Aufteilung, Gewichtung und Berücksichtigung von Übertragungssignalen eine stärkerer verallgemeinernde Wirkung auf das KNN hat. Auch muss festgestellt werden, dass das als Übertragungsfunktion bezeichnete Vorverarbeitungs-Verfahren auf die Spezifität des Systems wenig Einfluss hat. Es bewirkt für die Klassifikation lediglich eine genauere Validierung der numerischen „Defekt“-Spektren, da deren Anregungsfunktion, aufgrund nicht vollständiger Abkopplung des schwingenden Kastens von der Anregung, abweichend zu „Intakt“-Spektren sein kann. Die Position von Maxima im Spektrum ändert sich dabei jedoch nicht. Da der Klasse „defekt“ alle nicht eindeutig zugeordneten Spektren zugewiesen werden, beeinflussen Abweichungen in der Simulation „Defekt“-Spektren das Ergebnis nur geringfügig. Die wichtigsten Kriterien zur korrekten Sortierung stellen die „Intakt“-Spektren sowie die einiger Grenzfälle dar. Der Bedarf hierfür wird durch die Simulation abgedeckt. Das einfache Aufteilen der Spektren in 10 Frequenzklassen gleicher Breite (A-1) ermöglicht dem KNN dabei die beste Generalisierung. Ein Einsatz spezifischer Verfahren, wie die Betrachtung einzelner spezieller Peaks oder auch der Einsatz von FFT-Algorithmen, ist in Anbetracht der erörterten Ungenauigkeiten sowie der Betrachtung nicht expliziter Frequenzbandausschnitte nicht für die Steigerung der Generalisierungsfähigkeit des KNN geeignet. Diese

Verfahren sind jedoch bei Modifizierung der Methode zu Anregungsmethoden wie „Rauschen“ oder „Schock“ als spezifische Ansatzpunkte nicht zu vernachlässigen, obgleich auch denkbar ist, dass diese Aufgaben durch das vorgestellte KNN übernommen werden.

Topologie

Das Netz selber ist nicht zu komplex zu wählen, da dies eine Spezifizierung zu Spezialfällen hin zur Folge hat. Dies entspricht einem „Auswendiglernen“ bestimmter Fälle. So nimmt die Generalisierungsfähigkeit des Netzwerkes teilweise deutlich ab. Eine Reduzierung der Ausgabe auf nur einen Ausgabeknoten vereinfacht die absolute Entscheidung zur Sortierung und somit den Praxiseinsatz. Es nimmt jedoch bei der Konfiguration des Netzwerkes jede Möglichkeit, die Generalisierungsfähigkeit des Netzes auf schnelle Art und Weise zu beurteilen.

Die hier eingesetzte Technik mit zwei Ausgangsneuronen zeigt dagegen deutlich, ob das Netzwerk seine Ausgabe in Richtung „intakt“ oder in Richtung „defekt“ spezialisiert. Das bedeutet, dass auf der einen Seite die Übereinstimmung zu bekannten Mustern genau beurteilbar wird, während auf der anderen Seite starke Verallgemeinerung zugelassen wird. Zuordnungen wie „mehr intakt“ oder „mehr defekt“ werden möglich.

Das Ergebnis der Generalisierung des neuronumerisch trainierten KNN zeigt deutlich, dass beim Uni-Sensorsystem einige Grenzfälle nicht erkannt werden können. Der Ausbau zum Dual-Sensorsystem mittels einfachem Zusammenschluss über zusätzliche verdeckte Neuronenschichten verringert dieses Problem teilweise. Die Modifizierung dieses zweisträngigen Netzwerkes zu einem einfach aufgebauten KNN (vollständig verbundene Neuronenschichten, ausschließlich vorwärts gerichtete Neuronen, nur eine verdeckte Schicht) stabilisiert die Klassifizierung und untermauert damit die Hypothese, dass ein in möglichst geringem Maße spezifiziertes Netzwerk eingesetzt werden sollte.

Soll das Netzwerk dennoch weiter ausgebaut werden (d. h. mehr als zwei Sensoren), um spezielle Grenzfälle zu detektieren, ist die Modifikation des 20x10x2-KNN durch Hinzufügen weiterer Eingangsneuronen unproblematisch. Allerdings ist der Einsatz von mehr als etwa 8 physischen Sensoren für den Praxiseinsatz fraglich und sollte in jedem Fall mit der Notwendigkeit realer Schadenshäufigkeiten abgestimmt werden. Ergibt sich dabei die Notwendigkeit weiterer zusätzlicher Sensoren, ist auch eine flächendeckende optische Aufnahme mittels beispielsweise Laser-Vibrometern

denkbar. Dazu eignen sich in erster Annahme Messpunkte im Abstand von 3 bis 5 cm [136].

Als Zusammenfassung der Schlussfolgerung kann somit angemerkt werden, dass das Netz bereits in einfacher Konfiguration sehr gute Ausgaben erzielt und nur wenigen Grenzfällen unsicher zuordnet. Bemerkenswert ist besonders, dass das Dual-Sensor-KNN viele Abweichungen von numerischen und experimentellen Spektren duldet. Es wird deutlich aufgezeigt, dass der eingeschlagene Lösungsweg zur Mustererkennung seine Wirkungsweise anhand der Leistungsfähigkeit, d. h. des Qualität der Klassifizierungsergebnisse, des Systems begründet.

Als zentrale Schlussfolgerung lässt sich festhalten, dass in der vorgestellten Arbeit mit steigender subjektiver Genauigkeit („Expertenwissen“) der Daten die objektive Genauigkeit („Generalisierungsfähigkeit“) des KNN abnimmt, teilweise sogar deutlich. Zur Datenvorverarbeitung muss dabei das mathematisch mögliche im Bezug auf die Genauigkeit, die dem KNN genügt, nicht ausgeschöpft werden.

5 Zusammenfassung

Die vorliegende Arbeit setzt die Methode der Neuronumerik erstmals zur Schadenserkennung an Getränkekästen ein. Dabei wird ein Verfahren vorgestellt, das auf der mechanischen Signalausbreitung in Festkörpern aufbaut. Die Systemantwort nach dynamischer Anregung gilt als Kriterium zur Schadensklassifizierung. Unterschiedliche Geometrien, also auch Schadensfälle, lassen sich dabei im Übertragungssignal erkennen. Die Mustererkennung, d. h. die Klassifizierung von Schäden, übernimmt dabei ein künstliches neuronales Netz (KNN). Dieses ist gerade durch seine Fähigkeit zu Generalisieren besonders geeignet, auch Fertigungstoleranzen und Positionierungsfehler zu tolerieren und dennoch die Getränkekästen in „intakt“ und „defekt“ zu klassifizieren. Die numerische Simulation wird zu Beginn zur Auslegung und Validierung des Verfahrens für eine experimentelle Pilotanlage zur Aufnahme von Frequenz-Antwort-Spektren von Getränkekästen eingesetzt. Als zentrales Ziel dieser Anwendung kommen im validierten System bei der Parametrierung des KNN Datensätze numerischen Ursprungs zum Einsatz. Diesen Vorgang bezeichnet die vorliegende Arbeit als Neuronumerik.

Der generelle Grundgedanke der Neuronumerik, oder auch eines neuronumerischen Systems, ist weitreichender darzulegen. Hiermit werden alle Verfahren beschrieben, in denen die konventionellen Methoden der numerischen Simulation wichtiger Bestandteil sind und außerdem kognitive Algorithmen, im Besonderen KNN, zentrale Aufgaben übernehmen. Allen diese Aufgaben ist gemein, dass KNN in der Lage sind, Rechenschritte zu substituieren, die besonders aufwändig, zeitintensiv oder nur näherungsweise berechenbar sind. Aufgrund ihrer Fähigkeit, Funktionen abzubilden und zu generalisieren, liefern entsprechend konfigurierte KNN dabei weiterverwertbare Ausgaben.

Das Eigenschwingungsverhalten sowie die Frequenz-Antwort-Spektren an diskreten Punkten eines Getränkekastens werden unter Anwendung der Finite-Elemente-Methode (FEM) numerisch berechnet. Eingesetzt wird dazu die Software MSC/NASTRAN sowie der Pre- und Postprozessor MSC/PATRAN. Als Modell wird die CAD-Geometrie eines Getränkekastenherstellers eingelesen und mit Hilfe zehnknotiger, tetraederförmiger Elemente diskretisiert. Zur Simulation des Systems werden die vom Getränkekastenhersteller zur Verfügung gestellten Materialwerte eingesetzt.

Die experimentelle Pilotanlage zur Schwingungsprüfung basiert auf der vertikalen Anregung eines zentral am Boden fixierten Getränkekastens mittels eines elektro-

dynamischen Shakers. Die Steuerung übernimmt ein handelsüblicher Computer. Dieser dient sowohl der Ansteuerung der Prüfanlage mittels einer gleitenden Sinusschwingung von 50 bis 1000 Hz, als auch der Messwerterfassung der Frequenz-Antwort-Signale des Getränkekastens, die mit Hilfe von Beschleunigungsaufnehmern ermittelt werden. Der Computer übernimmt des Weiteren die Aufgabe der Mustererkennung zur Schadensklassifizierung mittels KNN. Als Trainingsalgorithmus wird Resilient Propagation (RPROP) eingesetzt. Die Grundkonfiguration des KNN stellt ein feedforward gerichtetes Multi-Layer-Perzeptron (MLP) mit einer verdeckten Schicht und zwei Ausgabeneuronen dar. Zur Datenreduktion der zu klassifizierenden Frequenz-Antwort-Spektren wird die Integration von Frequenzklassen eingesetzt. Es werden dabei sowohl das direkte Messsignal als auch das Signal der Übertragungsfunktion auf je zehn Eingangsneuronen reduziert.

Berechnungen mit veränderten Materialparametern zeigen die Sensitivität der Frequenz-Antwort-Spektren. Sie illustrieren auch die Sensitivität bezüglich geometrischer Veränderungen, die im vorliegenden Fall Schäden verkörpern. Dabei werden ausgewählte Modellschäden untersucht. Die Simulation führt außerdem zur Auswahl geeigneter Sensorpositionen. So weisen die Ergebnisse der Finite-Elemente Simulationen die beiden Griffleisten der schmalen Seite als besonders sensitive Messorte aus. Diese werden, auch im Hinblick auf den Praxiseinsatz wegen ihrer Lage beim Transport von Getränkekästen auf dem Förderer, als zweckmäßig erachtet.

Der Vergleich von Frequenzspektren experimentellen und numerischen Ursprungs verdeutlicht die Übereinstimmung der Hauptpeaks, die jedoch besonders aufgrund einiger Vereinfachungen in der Simulation (Vernetzung mit Tetraederelementen, einheitliche Materialparameter für das gesamte Modell) geringfügige Abweichungen in der Höhe einzelner Amplituden aufweisen. Die Spektren beider Quellen dokumentieren die Unterscheidbarkeit der verschiedenen Schadensfälle.

Die Untersuchung unterschiedlicher KNN-Topologien weisen eine Netzwerkgröße von 10 Eingangsneuronen, 5 verdeckten Neuronen und 2 Ausgangsneuronen (10x5x2-KNN) als besonders leistungsfähig aus, um die Modellschäden experimenteller Datensätze in „intakt“ und „defekt“ zu klassifizieren. In diesem Kontext kommt der Datenvorverarbeitung eine besondere Bedeutung zu. Eine Reduzierung der Frequenz-Antwort-Spektren auf die 10 Eingangsneuronen durch Aufteilen des Spektrums des direkten Messsignals in Frequenzklassen und deren Integration ermöglicht dem KNN die geforderte Generalisierungsfähigkeit.

Die Substitution der zum Training des KNN eingesetzten Datenpools mit Datensätzen aus der numerischen Simulation beeinflusst deutlich die KNN-Ausgabe.

Einzig eine gezielte Substitution der als „defekt“ zu klassifizierenden Trainingsdatensätze mit numerischen ermöglicht die korrekte Klassifizierung experimenteller Modellschäden.

Die Modifizierung der Netzwerktopologie unter Berücksichtigung der bereits eingesetzten Datenvorverarbeitung ermöglicht auch den Einsatz eines Multi-Sensor-Systems. Dieses besteht aus zwei Sensoren, die symmetrisch auf einander gegenüberliegenden Griffleisten zentral angeordnet sind. Schrittweises Modifizieren dieser erprobten Netzwerktopologie und Zusammenführen der verdeckten Neuronenschichten führt zu einem Gesamt-KNN (20x10x2-KNN), das für das Dual-Sensor-System ebenfalls eine Klassifizierung in „intakt“ und „defekt“ erlaubt. Diese Konfiguration ermöglicht eine Klassifizierung im Sinne der Neuronennumerik, indem ein komplett mit numerischen Datensätzen trainiertes und parametrisiertes KNN die „intakt-defekt“ Klassifizierung der experimentellen Modellschäden ausgibt. Für den vorliegenden Fall bedeutet dies auch, dass das KNN die Abweichung zwischen numerischer Simulation und realer Messung ausgleicht. Lediglich Grenzfälle werden teilweise falsch zugeordnet.

Die symmetrische Anordnung des Sensorpaares erhöht die Generalisierungsfähigkeit des KNN bezüglich der neuronumerischen Datenpoolzusammenstellung und der enthaltenen Grenzfälle deutlich. Der Erfolg der Klassifizierung der experimentellen Frequenz-Antwort-Spektren durch das mit numerischen Datensätzen parametrisierte KNN gründet sich zudem auf der Datenreduzierung, deren Anwendung ohne spezifische Auswahl bestimmter Frequenzbänder auskommt. Dies ermöglicht eine Anwendung ohne spezifisches Vorwissen („Expertenwissen“) und verhindert eine Spezialisierung des KNN auf wenige Fälle.

6 Ausblick

In dieser Arbeit konnte die Eignung und Leistungsfähigkeit der Schwingungsanalyse zur Schadensdetektion von Getränkekästen belegt werden. Die Mustererkennung mit künstlichen neuronalen Netzen erweist sich dabei als starkes Instrument zur Klassifikation von Schäden. Die numerische Simulation der Schwingungen des Getränkekastens verdeutlicht zusätzlich ihre immense Bedeutung hinsichtlich der Anlagenauslegung sowie der neuronumerischen Konfiguration komplexer Systeme.

Eine weiterführende Beurteilung der Tauglichkeit des Systems auf alle Mehrwegpackmittel (Pfandsysteme) - sei es auf Seite der Getränkeindustrie als Nutzer oder auf Seite der Kastenhersteller - hätte den Rahmen der vorliegenden Arbeit jedoch gesprengt. Die entwickelte Methode besticht aber gerade durch ihr hohes Potenzial. Letzteres umfasst auch die Möglichkeit der Erkennung von Fremdkästen sowie Recyclatgehalten und gealterten Getränkekästen. Auch Schäden bei Glasflaschen in leerem oder befülltem Zustand lassen sich potenziell diagnostizieren. Des Weiteren scheint die Sensitivität der Methode offensichtlich die Detektion grober Fremdkörper in Glasflaschen zu ermöglichen.

Bei der Umsetzung dieser weiterführenden Gedanken muss allerdings beachtet werden, dass praxisnahe Detektionszeiten sowie eine Integration in Flaschenabfüllanlagen einige Modifikationen am Modellsystem erfordern. Einige Kommentare und Überlegungen, die sich während der vorliegenden Arbeit angesammelt haben, werden abschließend kurz erläutert.

Das Anregungsverfahren erweist sich dabei als wichtigster Punkt. In der vorliegenden Form werden bei einer Minimierung der Laufzeit des Sinussweeps etwa 5 bis 10 s benötigt, um einen Prüfling zu beurteilen. Industriell zeigt sich dies als unzureichend, da ein Testzyklus < 1 s angestrebt werden muss. Dies entspricht dem Durchsatz von einem Kasten mit 20 Flaschen bei einer Ausbringung von 72.000 0,5 l-Flaschen pro Stunde. Es besteht allerdings die Möglichkeit ein derartiges Aufkommen in 2 oder mehr Förderstränge aufzuteilen, um eine Erhöhung der Zeit für einen Testzyklus zu erreichen.

Technisch verlangt dies die Modifikation der Anregung hin zur Stoß- bzw. Schockanregung. Es ist aber auch die Anregung durch ein Rauschen bzw. ein Randomsignal denkbar. Die Systemantworten enthalten bei derartigen Anregungen die gleichen strukturspezifischen, charakteristischen Informationen der Eigenformen. Sie

sind dann allerdings in überlagerter Form vorhanden. Auch ist bei der Schockanregung möglicherweise eine Fixierung des Kastens nicht mehr erforderlich.

Die Veränderung der Anregung bedeutet für die numerische Simulation der mechanischen Schwingungen der Prüflinge, dass das verwendete Verfahren („Lösungssequenzen“) angepasst bzw. das Modell modifiziert werden muss. Dazu bietet allerdings der eingesetzte FE-Code MSC/NASTRAN ausreichende Möglichkeiten, welche die Simulation von Schock- oder Rausch-Anregung erlauben.

Außerdem erweist sich im Hinblick auf die Integrierbarkeit und die Handhabbarkeit des Detektionssystems in bestehende Flaschenabfüllanlagen kontaktlose Messtechnik als erforderlich, da gerade mit berührungslosen Sensoren der notwendige Taktzyklus < 1 s erreicht werden kann. Das könnte beispielsweise durch faseroptische Laser-Vibrometer geschehen.

Die Klassifikation von Schäden mittels KNN bei unterschiedlicher Anregung und Detektion erfordert keine grundlegende Änderung der Konfiguration. Es ist allerdings möglich, dass einige zusätzliche Merkmale des Spektrums Berücksichtigung finden müssen. Dabei kann es sich um die Betrachtung von Abklingzeiten, Amplitudenhöhen, dominierenden Frequenzgängen, aber auch weiteren Verfahren zur Auswertung von Messsignalen und Datenmengen handeln, wie z. B. Fast-Fourier-Transformation (FFT), Partial Least Square (PLS) oder Principal Component Analysis (PCA).

Zur Absicherung der Modelle wird erwartet, dass mit zunehmender Anzahl von Sensorpositionen eine erhebliche Erhöhung der Zuverlässigkeit der Klassifikation des KNN erreicht wird. Gerade der „Scan“ mehrerer Messpunkte oder ganzer Seiten mittels „Laser-Vibrometer“ ermöglicht vollständigere Auswertungen. Auf diese Weise ließe sich die Zahl der nicht unterscheidbaren Grenzfälle deutlich minimieren. Die Erhöhung der Informationsgewinnung durch Auswerten des Schwingungsverhaltens räumlich verteilter Referenzpunkte schafft die Grundlage zur Verstärkung der Sensitivität des Systems gegenüber Alterung und Mikrorissen. Dies ergänzt das skizzierte Potenzial des entwickelten Verfahrens erheblich.

7 Anhang

7.1 NASTRAN Solution-Files zur Modal-Analyse SOL103 und zur Frequency-Response-Analyse SOL111

Dieser Teil des Anhangs besteht zunächst aus den Code-Listings eines Solution-Files zur MSC/NASTRAN „Modal-Analyse“ SOL103 und zur „Frequency-Response-Analyse“ SOL111, wie sie in der vorliegenden Arbeit verwendet wurden. Die komplette GRID und Maschen-Auflistung (CTETRA) liegen in separaten Files vor, so dass auf ihre Darstellung verzichtet wird. Es erscheint an dieser Stelle auch nicht angebracht den Code, dessen „Cards“ und seinen Lösungsvorgang zu kommentieren. Dazu wird auf den MSC/NASTRAN Quick Reference Guide [135] und Kommentare verwiesen.

SOL103 – Normal-Modes-Analysis

```

$ NASTRAN input file created by the MSC MSC/NASTRAN input file
$ translator ( MSC/PATRAN Version 8.5 and direct input) on 2002
$ for Solver Version V2001
$
$ ASSIGN OUTPUT2 = 'Mode_2a_xx.op2', UNIT = 12, FORM = UNFORMATTED
$
ASSIGN SCR3021='/ptmp/ta131ah/SCR3051' STATUS=UNKNOWN
ASSIGN SCR3022='/ptmp/ta131ah/SCR3052' STATUS=UNKNOWN
ASSIGN SCR3023='/ptmp/ta131ah/SCR3053' STATUS=UNKNOWN
ASSIGN SCR3024='/ptmp/ta131ah/SCR3054' STATUS=UNKNOWN
INIT SCRATCH SCR300=(SCR3051(6GB),SCR3052(6GB),SCR3053(6GB),
SCR3054(8GB))
$
$. . . . .__R.2. . . . .3. . . . .4. . . . .5. . . . .6. . . . .7. . . . .8. . . . .9. . . . .+ . . . . .__R
$
$ Direct Text Input for File Management Section
$ Normal Modes Analysis, Direct Formulation, Database
SOL 103
TIME 99999
$ Direct Text Input for Executive Control
CEND
$
SET 1 = 92353,93091, ...
SEALL = ALL
SUPER = ALL
TITLE = MSC/NASTRAN job created on Juli-01 at Bureau
ECHO = NONE
MAXLINES = 999999999
$
$ Direct Text Input for Global Case Control Data
$
SUBCASE 1
$ Subcase name : normal_modes
  SUBTITLE=normal_modes
  METHOD = 777
  SPC = 888
  VECTOR(PLOT, SORT1, REAL)=ALL
$

```

```

$ Direct Text Input for this Subcase
$
$....__R.2.....3.....4.....5.....6.....7.....8.....9.....+.....__R
$
BEGIN BULK
$
PARAM      POST      -1
PARAM      PATVER     3.
PARAM      AUTOSPC    YES
PARAM      PRGPST     NO
PARAM      COUPMASS   -1
PARAM      K6ROT      0.
PARAM      WTMASS     1.
PARAM      G          0.05
PARAM      NOCOMPS    -1
PARAM      PRTMAXIM   YES
PARAM      GRDPNT     0
$
$ Methoden
$
EIGRL      777      1.          6          0
$
$ ridgid body Element fasst alle GRID's der Halterung zusammen in 1234567
$....__R.2.....3.....4.....5.....6.....7.....8.....9.....+.....__R
$
RBE2      5000012 1234567 123      1684      2557      2597      4057      6167      +   ZGAA
+   ZGAA 6168      6169      6174      6932      6933      6936      8271      10622     +   ZGAB
...
+   ZGAN 111875   113460   113902   114196   117053   118917   119600   119988   +   ZGAO
+   ZGAO 121705   121706   121707   123696   123951
$
$ Loads for Load Case
$
SPCADD     888      999
$
SPC1       999      2          1234567
$
$....__R.2.....3.....4.....5.....6.....7.....8.....9.....+.....__R
$
$ Elements and Element Properties for region : Kasten_Property
$
PSOLID     1          1          0
$
$ Material Record : Material1 - Polyethylen (PE)
$ Description of Material : "hein2430" -> SchoellerWavinSystems
$
MAT1       1          1.6+3          .419      962.-12
$
$ Pset: "Kasten_Property" will be imported as: "psolid.1"
$
$ =====
$ Zuerst die GRID's!! --> alle Grid's, Schaeden beziehen sich auf sie!!!
$
INCLUDE 'OERGgrid10.bdf'
$
$ -----
$ das ist der Schwerpunkts-Grid fuer RBE2
$
GRID       1234567          0.      -10.      0.
$
$....__R.2.....3.....4.....5.....6.....7.....8.....9.....+.....__R
$
$ =====
$ Dann der massakrierte intakte Kasten (NUR!! ELM's)
$
$ ist minus alle unteren Schaeden
$

```

```
INCLUDE 'Fragment_0201.bdf'
$
$ -----
$ Dann alles was doch ganz sein soll, Schaeden muessen ausgeblendet werden!!
$ -----
$
$ *** Griff LS-Mitte fehlt ***
$
INCLUDE 'Oergtet10_asso_1.bdf'
$
$ -----
$
$ *** Griff RS fehlt komplett ***
$
INCLUDE 'Oergtet10_asso_3.bdf'
$
$ -----
$
$ *** Riss Griff Mitte links ***
$
INCLUDE 'Oergtet10_asso_5.bdf'
$
$ -----
$
$ *** Riss breite Seite oben links halb ***
$
INCLUDE 'Oergtet10_asso_8.bdf'
$
$ -----
$
$ *** Eck links unten hinten fehlt teilweise ***
$
INCLUDE 'Oergtet10_asso_9.bdf'
$
$ -----
$
$ *** Riss Griff LS links ***
$
INCLUDE 'Oergtet10_asso_10.bdf'
$
$ -----
$
$ *** Riss schmale Seite LS links unterhalb Griffriiss ***
$
INCLUDE 'Oergtet10_asso_10b.bdf'
$
$ -----
$
$ *** Riss Boden links ***
$
INCLUDE 'Oergtet10_asso_12.bdf'
$
$ -----
$
$ *** Riss Boden in der Naehe der Mitte ***
$
INCLUDE 'Oergtet10_asso_13.bdf'
$
$ -----
$
$ *** Riss Boden rechts ***
$
INCLUDE 'Oergtet10_asso_14.bdf'
$
$ -----
$
$ *** Riss Gefache links ***
```

```

$
INCLUDE 'Oergtet10_asso_15.bdf'
$
$ -----
$
$ *** Riss Gefache Mitte links ***
$
INCLUDE 'Oergtet10_asso_16.bdf'
$
$ -----
$
$ *** Riss Gefache rechte Haelfte ***
$
INCLUDE 'Oergtet10_asso_17.bdf'
$
$ =====
$
$....__R.2.....3.....4.....5.....6.....7.....8.....9.....+....__R
$
ENDDATA
$

```

SOL111 – Frequency-Response-Analysis

```

$ NASTRAN input file created by the MSC MSC/NASTRAN input file
$ translator ( MSC/PATRAN Version 8.5 and direct input) on 2002
$ for Solver Version V2001
$
$ ASSIGN OUTPUT2 = 'SCH_10erTET_xx.op2', UNIT = 12, FORM = UNFORMATTED
$
ASSIGN SCR3021='/ptmp/ta131ah/SCR3221' STATUS=UNKNOWN
ASSIGN SCR3022='/ptmp/ta131ah/SCR3222' STATUS=UNKNOWN
ASSIGN SCR3023='/ptmp/ta131ah/SCR3223' STATUS=UNKNOWN
ASSIGN SCR3024='/ptmp/ta131ah/SCR3224' STATUS=UNKNOWN
INIT SCRATCH SCR300=(SCR3221(6GB),SCR3222(6GB),SCR3223(6GB),
SCR3224(8GB))
$
$....__R.2.....3.....4.....5.....6.....7.....8.....9.....+....__R
$
$ Direct Text Input for File Management Section
$ Frequency Response Analysis, Direct Formulation, Database
SOL 111
TIME 99999
$ Direct Text Input for Executive Control
CEND
$
$ Nodes for group :
SET 1 = 92353,93091, ...
SET 2 = 94076,104835,1234567, ... ,102270,94085
SET 3 = 104573,104700,104835, ... ,64453
$
SEALL = ALL
SUPER = ALL
TITLE = MSC/NASTRAN job created on Juli-01 at Bureau
ECHO = NONE
MAXLINES = 999999999
$
$ Direct Text Input for Global Case Control Data
$
SUBCASE 1
$ Subcase name : frequency_response
  SUBTITLE=frequency_response
  METHOD = 777
  FREQUENCY = 1
  SPC = 888

```

```

DLOAD = 222
$ DISPLACEMENT (SORT2,REAL)=1
ACCELERATION (SORT2,REAL)=3
$ VELOCITY (SORT2,REAL)=1
$
$ Direct Text Input for this Subcase
$
$. . . . __R.2. . . . .3. . . . .4. . . . .5. . . . .6. . . . .7. . . . .8. . . . .9. . . . .+ . . . . __R
$
BEGIN BULK
$
PARAM PATVER 3.
PARAM AUTOSPC YES
PARAM PRGPST NO
PARAM COUPMASS -1
PARAM K6ROT 0.
PARAM WTMASS 1.
PARAM G 0.075
PARAM NOCOMPS -1
PARAM PRTMAXIM YES
PARAM LFREQ 0.001
$ PARAM HFREQ 3000.
PARAM GRDPNT 0
$
$ Methoden
$
EIGRL 777 1010. 230 0
FREQ1 1 49.8951 1.0376 960
$
$ ridgid body Element fasst alle GRID's der Halterung zusammen in 1234567
$. . . . __R.2. . . . .3. . . . .4. . . . .5. . . . .6. . . . .7. . . . .8. . . . .9. . . . .+ . . . . __R
$
$
RBE2 5000012 1234567 123 1684 2557 2597 4057 6167 + ZGAA
+ ZGAA 6168 6169 6174 6932 6933 6936 8271 10622 + ZGAB
. . .
+ ZGAN 111875 113460 113902 114196 117053 118917 119600 119988 + ZGAO
+ ZGAO 121705 121706 121707 123696 123951
$
$ Loads for Load Case : frequency_response
$
SPC1 888 2 1234567
$
RLOAD1 222 201 111 ACCE
$
$. . . . __R.2. . . . .3. . . . .4. . . . .5. . . . .6. . . . .7. . . . .8. . . . .9. . . . .+ . . . . __R
$
SPCD 201 1234567 2 7.5+4
$
$ Referenced Dynamic Load Tables
$ Dynamic Load Table : frequency_dependent_load
$
$. . . . __R.2. . . . .3. . . . .4. . . . .5. . . . .6. . . . .7. . . . .8. . . . .9. . . . .+ . . . . __R
$
$ --- Steuerung: -> Platte ---
TABLED1 111 + ZTAA
+ ZTAA 0. 0.24 50. 0.24 105. 0. 145. 0.533 + ZTAB
. . .
+ ZTAI 820. 0.8 845. 0.867 870. 0.853 900. 0.827 + ZTAJ
+ ZTAJ 915. 0.8 1000. 0.68 3000. 0.68 ENDT
$. . . . __R.2. . . . .3. . . . .4. . . . .5. . . . .6. . . . .7. . . . .8. . . . .9. . . . .+ . . . . __R
$
$ Direct Text Input for Bulk Data
$ Elements and Element Properties for region : Kasten_Property
$
PSOLID 1 1 0
$

```

```
$ Material Record : Material1 - Polyethylen (PE)
$ Description of Material : "hein2430" -> SchoellerWavinSystems
MAT1      1      1.6+3      .419      962.-12
$
$ Pset: "Kasten_Probertry" will be imported as: "psolid.1"
$
$ =====
$ Zuerst die GRID's!! --> alle Grid's, Schaeden beziehen sich auf sie!!!
$
INCLUDE 'OERGgrid10.bdf'
$
$ -----
$ das ist der Schwerpunkts-Grid fuer RBE2
$
GRID      1234567      0.      -10.      0.
$
$ ....__R.2.....3.....4.....5.....6.....7.....8.....9.....+....__R
$
$ =====
$ Dann der massakrierte intakte Kasten (NUR!! ELM's)
$
$ ist minus alle unteren Schaeden stand 2.1.2002
$
INCLUDE 'Fragment_0201.bdf'
$
$ -----
$ Dann alles was doch ganz sein soll, Schaeden muessen ausgeblendet werden!!
$ -----
$
$ *** Griff LS-Mitte fehlt ***
$
INCLUDE 'Oergtet10_asso_1.bdf'
$
$ -----
$
$ *** Griff RS fehlt komplett ***
$
INCLUDE 'Oergtet10_asso_3.bdf'
$
$ -----
$
$ *** Riss Griff Mitte links ***
$
INCLUDE 'Oergtet10_asso_5.bdf'
$
$ -----
$
$ *** Riss breite Seite oben links halb ***
$
INCLUDE 'Oergtet10_asso_8.bdf'
$
$ -----
$
$ *** Eck links unten hinten fehlt teilweise ***
$
INCLUDE 'Oergtet10_asso_9.bdf'
$
$ -----
$
$ *** Riss Griff LS links ***
$
INCLUDE 'Oergtet10_asso_10.bdf'
$
$ -----
$
$ *** Riss schmale Seite LS links unterhalb Griffriess ***
$
```

```
INCLUDE 'Oergtet10_asso_10b.bdf'
$
$ -----
$
$ *** Riss Boden links ***
$
INCLUDE 'Oergtet10_asso_12.bdf'
$
$ -----
$
$ *** Riss Boden in der Naehе der Mitte ***
$
INCLUDE 'Oergtet10_asso_13.bdf'
$
$ -----
$
$ *** Riss Boden rechts ***
$
INCLUDE 'Oergtet10_asso_14.bdf'
$
$ -----
$
$ *** Riss Gefache links ***
$
INCLUDE 'Oergtet10_asso_15.bdf'
$
$ -----
$
$ *** Riss Gefache Mitte links ***
$
INCLUDE 'Oergtet10_asso_16.bdf'
$
$ -----
$
$ *** Riss Gefache rechte Haelfte ***
$
INCLUDE 'Oergtet10_asso_17.bdf'
$
$ =====
$
$ ....__R.2.....3.....4.....5.....6.....7.....8.....9.....+.....__R
$
$ Referenced Coordinate Frames
$
ENDDATA
$
```

7.2 Tabellarische Aufstellungen zu Positionen eingesetzter Schadensfälle, KNN-Datenpools und deren Zusammensetzung

Tabelle 7-1: Tabellarische Auflistung der eingesetzten Schadensfälle (reale Modellschäden am Kasten)

Die absichtlich verzerrten Wiederholungsmessungen bewirken eine Abweichung von $\pm 5\%$ bei den Spektren (vgl. Abbildung 4-13) gemäß der Tabelle 7-4.

Schadensfall (Nr.)	Sensorposition laut Tabelle 7-4	Messung (Nr.)	Beschreibung
E1	RS	0, 3 –10, 15 –20, 27-29	intakt (unbeschädigt)
E2	LS	11 – 14, 21 - 26	intakt (unbeschädigt)
E3	RS	30 - 39	Gefacheschaden
E4	LS	40 - 49	Gefacheschaden
E5	LS	50 – 59	Griffriss LS
E6	RS	60 – 69	Griffriss LS
E7	LS	70 – 79	multiple Schäden (Gefache, Mittelgriff)
E8	RS	83 - 89	multiple Schäden (Gefache, Mittelgriff)
E9	RS	90 – 99	Griff LS + Mitte fehlt
E10 *	LS	100 – 109	Griff LS + Mitte fehlt
E11	RS	110 – 120	multiple Schäden (Griffe, Seiten)
E12	LS	121 – 129	multiple Schäden (Griffe, Seiten)
E13	LS	130 – 139	Seitenschaden RS (unter intaktem Griff)
E14	RS	140 – 149	Seitenschaden RS (unter intaktem Griff)
E15	LS	150 – 159	Fremdkasten „Bindi“ Griffriss RS
E16	RS	160 – 169	Fremdkasten „Bindi“ Griffriss RS
E17	LS/RS nicht unterschieden	170 - 179	Fremdkasten „Dachs“ (intakt)

* freies Sensorrauschen aufgrund fehlendem Bauteil (Schaden)

Die Messung einzelner Seiten stellt jeweils einen eigenen Schadensfall für das Uni-Sensor-KNN dar.

LS: linke Seite (Abbildung 7-1) – entspricht Sensorposition 1 (Abbildung 3-10)

RS: rechte Seite (Abbildung 7-1) – entspricht Sensorposition 4 (Abbildung 3-10)

Tabelle 7-2: Liste von zeitgleichen Messpaaren für Dual-Sensor-KNN aus
Tabelle 7-1

Schadensfall (Nr.)	zusammengestellt aus (LS-RS -Paare)	Messung (Nr.)
EP1	E1 + E2	11&10, 19&21, 20&22, 26&27
EP2	E3 + E4	37&40, 38&41, 39&42
EP3	E5 + E6	59&60
EP4	E7 + E8	79&83
EP5	E9 + E10	100&99
EP6	E11 + E12	121&119, 122&120
EP7	E13 + E14	139&140
EP8	E15 + E16	159&160
EP9	E17 + E17	170&171

Diese Paare sind auch seitenvertauscht einsetzbar und verdoppeln somit die Anzahl der Schadensfälle.

„Verrauscht“ werden sie, indem Messungen aus den zeitgleichen Paaren mit nicht-zeitgleichen ersetzt werden.

Zusammenstellung als LS-RS-Paare gemäß Pos. 1 und 4 nach Abbildung 3-10.

Tabelle 7-3: Tabellarische Auflistung der eingesetzten Schadensfälle (numerische Modellschäden in der CAD-Geometrie), unverrauscht, berechnet mit den Parametern von Tabelle 3-1, vgl. auch Abbildung 7-1 und Abbildung 7-2 (Schadensposition verdeutlicht anhand der Darstellung des inversen Fragments).

Schadensfall (Nr.)	Schaden laut Abbildung 7-2 (Nr.)	Simulation (Nr.) (LS + RS)	Beschreibung (Parametervariation)
N1	--	1a, 1b, 1c, 1d, 1e, 2a	intakt (Variation der Parameter: G_N , v , E , ρ)
N2	2	3	fehlendes Griffstück LS (G_N : 5%; 7,5%)
N3	3	4	fehlender Griff RS (G_N : 5%; 7,5%)
N4	4	5	Riss Mittelgriff (G_N : 5%; 7,5%)
N5	5	8	Riss breite Seite (G_N : 5%; 7,5%)
N6	6	9	fehlende Kastenecke (G_N : 5%; 7,5%)
N7	7	10	Riss am Griff LS (G_N : 5%; 7,5%)
N8	8	10b	Riss Seite LS (G_N : 5%; 7,5%)
N9	9	12	Bodenschaden (G_N : 5%; 7,5%)
N10	10	13	Bodenschaden (G_N : 5%; 7,5%)
N11	11	14	Bodenschaden (G_N : 5%; 7,5%)
N12	12	15	Gefacheschaden (G_N : 5%; 7,5%)
N13	13	16	Gefacheschaden (G_N : 5%; 7,5%)
N14	14	17	Gefacheschaden (G_N : 5%; 7,5%)
N15	7 + 8	18	N7 + N8 (G_N : 5%; 7,5%)
N16	5 + 6 + 7 + 8	19	N5 + N6 + N7 + N8 (G_N : 5%; 7,5%)
N17	9 + 10 + 11	20	N9 + N10 + N11 (G_N : 5%; 7,5%)

Fortsetzung Tabelle 7-3

Schadensfall (Nr.)	Schaden laut Abbildung 7-2 (Nr.)	Simulation (Nr.) (LS + RS)	Beschreibung (Parametervariation)
N18	12 + 13 + 14	21	N12 + N13 + N14 (G _N : 5%; 7,5%)
N19	17 + 18	22	N17 + N18 (G _N : 5%; 7,5%)
N20	2 + 4 + 7	23	N2 + N4 + N7 (G _N : 5%; 7,5%)
N21	Fragment ohne alle Schäden	24, 24a	Fragment (G _N : 5%; 7,5%)
N22	6 + 7 + 8	“o910b10”	N6 + N7 + N8 (G _N : 5%; 7,5%)

G_N: Dämpfungsfaktor

v: Poissonzahl

E: E-Modul

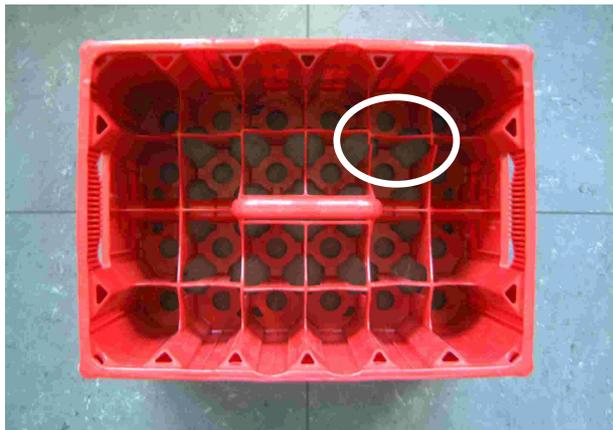
ρ: Dichte

LS: linke Seite (Abbildung 7-1) – entspricht Sensorposition 1 (Abbildung 3-10)

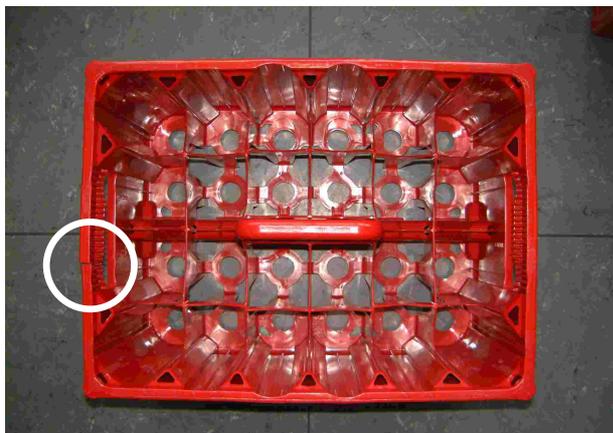
RS: rechte Seite (Abbildung 7-1) – entspricht Sensorposition 4 (Abbildung 3-10)

Tabelle 7-4: Modellschäden am realen Getränkekasten, Abbildungen der Fälle E3 bis E17 gemäß Tabelle 7-1 in Draufsicht und perspektivischer Ansicht (ISO); weißen eingekreist sind die Stellen an denen physische Schäden vorhanden sind

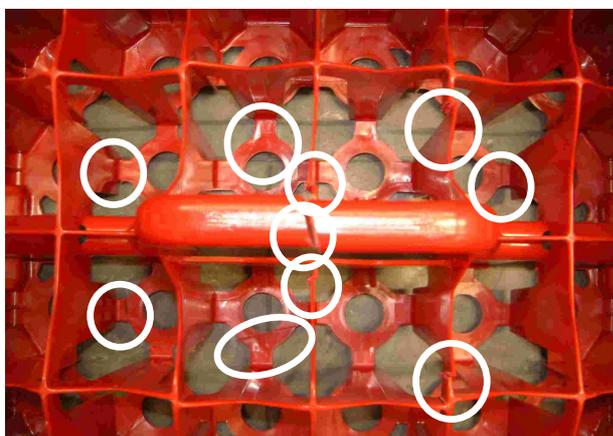
Draufsicht	perspektivische Ansicht (ISO)
------------	-------------------------------



Schadensfälle E3, E4



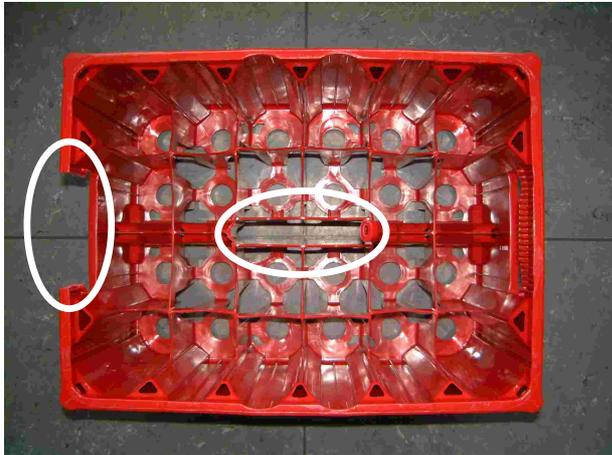
Schadensfälle E5, E6



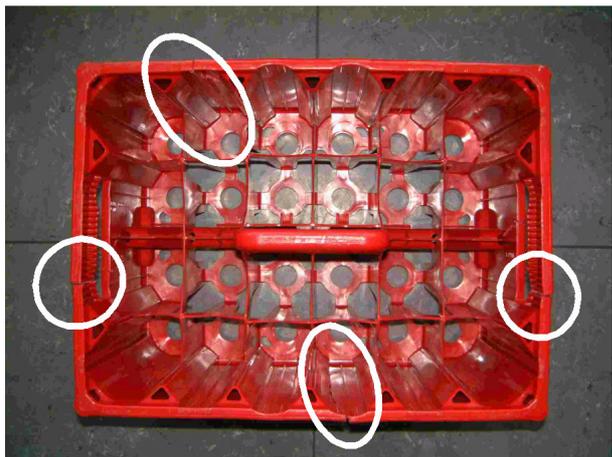
Schadensfälle E7, E8

Fortsetzung Tabelle 7-4

Draufsicht	perspektivische Ansicht (ISO)
------------	-------------------------------



Schadensfälle E9, E10



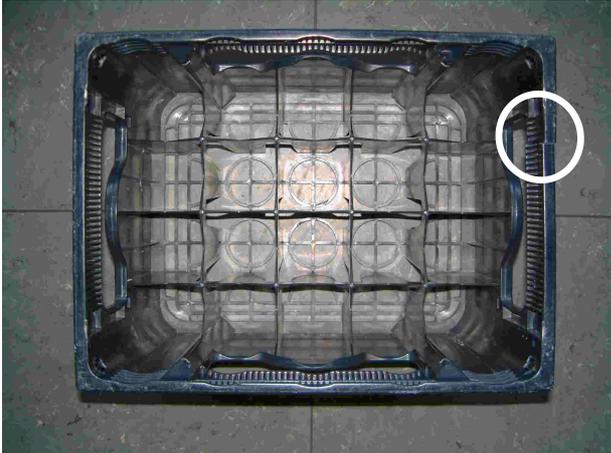
Schadensfälle E11, E12



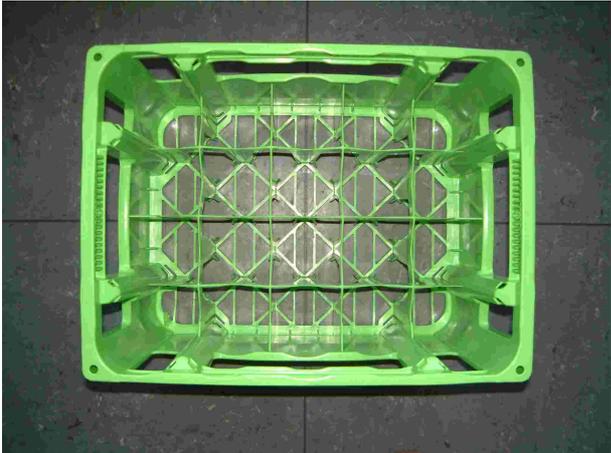
Schadensfälle E13, E14

Fortsetzung Tabelle 7-4

Draufsicht	perspektivische Ansicht (ISO)
------------	-------------------------------



Schadensfälle E15, E16



Schadensfall E17

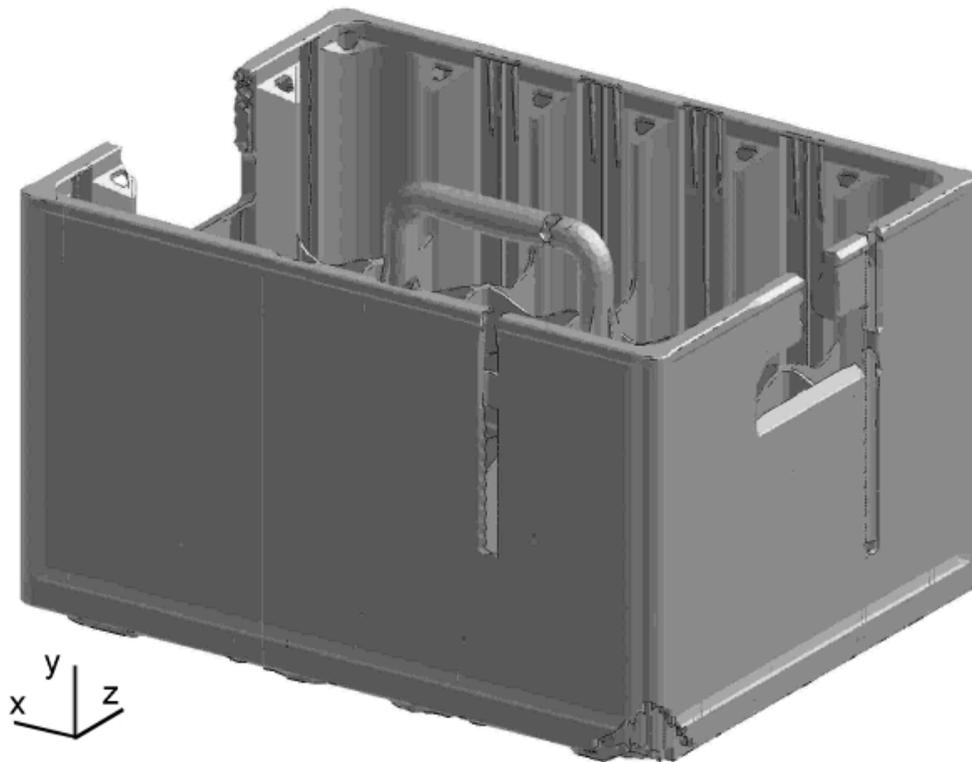


Abbildung 7-1: Fragment (N21) der Modellschäden am CAD-Kasten, Bezeichnung an den fehlenden Elementen in Abbildung 7-2

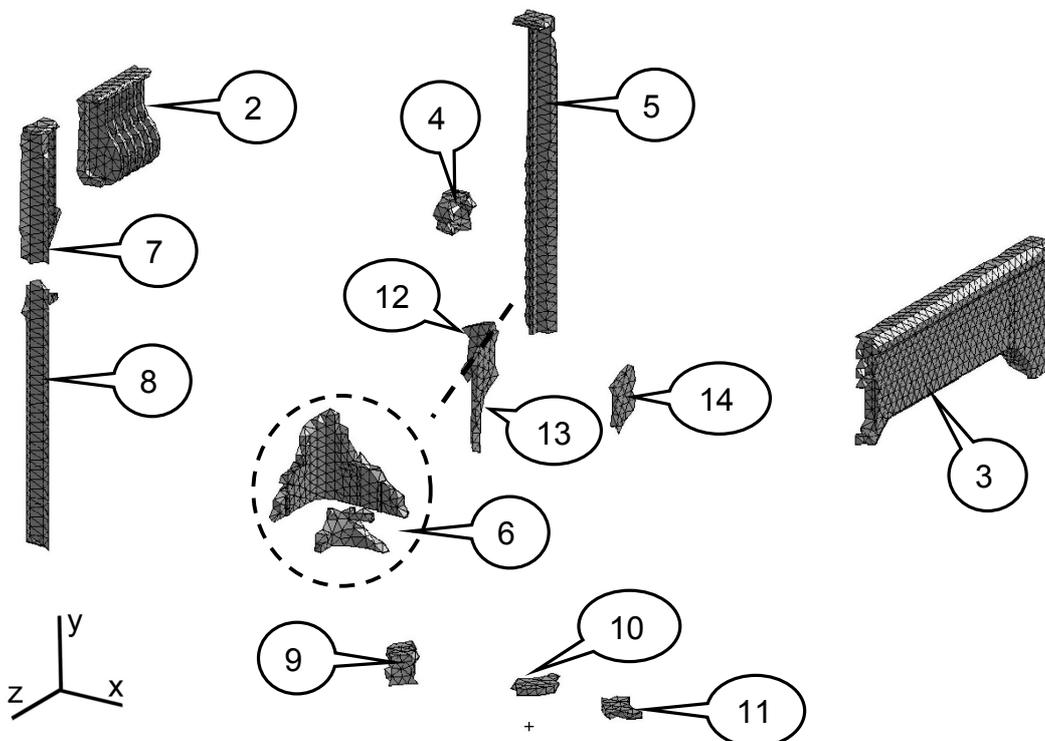


Abbildung 7-2: Inverse Darstellung von Abbildung 7-1 der Modellschäden am CAD-Getränkekasten mit Bezeichnung ihrer Schadensnummer

Tabelle 7-5: Tabellarische Auflistung der eingesetzten Trainings-/Testsets, sowie der zugehörigen Prädiktionssets; Zusammensetzung vgl. Tabelle 7-6

Bezeichnung	Inhalt	Verwendung (Setposition gemäß der Reihenfolge im Datenpool Tabelle 7-6)
Uni-Sensor-KNN		
D1-EXP	rein experimenteller Datensatz	1-19 Trainingsset 20-31 Testset
D2-EXP	rein experimenteller Datensatz	1-143 Prädiktionsset
D3-EXP/NUM	experimentelle Spektren für „defekte“ Fälle; numerische Spektren für „intakte“ Fälle	1-16 Trainingsset 17-31 Testset
D4-EXP/NUM	experimentelle Spektren für „intakte“ Fälle; numerische Spektren für „defekte“ Fälle	1-16 Trainingsset 17-31 Testset
D5-NUM	rein numerischer Datensatz	1-16 Trainingsset 17-31 Testset
D6-NUM	rein numerischer Datensatz	1-108 Prädiktionsset
Dual-Sensor-KNN		
D7-EXP	rein experimenteller Datensatz	1-92 Prädiktionsset
D8-NUM	rein numerischer Datensatz	1-37 Trainingsset 38-61 Testset

Tabelle 7-6: Zusammenstellung der KNN Datenpools (Prüflingsnummer entsprechend der Position in der im Datenpool aufgeführten Reihenfolge, Schadensnummern entsprechend Tabelle 7-1 bis Tabelle 7-3)

Datenpool	Schadensnummern in eingesetzter Reihenfolge
D1-EXP	E4, E5, E7, E2, E12, E13, min.-Dummy, 2xE15, E3, 2xE6, 2xE1, E8, max.-Dummy, E9, E11, E14, E4, E7, E12, E2, E13, E3, E8, E9, E1, 3xE9
D2-EXP	8xE2, 8xE4, 9xE5, 8xE7, 8xE10, 7xE12, 8xE13, 8xE15, 15xE1, 8xE3, 8xE6, 5xE8, 5xE9, 9xE11, 10xE14, 8xE16, 9xE17
D3-EXP/NUM	E4, E5, E7, N1(G _N :5%;LS), E12, E13, min.-Dummy, 2xE15, E3, 2xE6, 2xN1(G _N :5%;LS/G _N :7,5%;E-2,5%;LS), G7, E8, max.-Dummy, E9, E11, E14, E4, E7, E12, N1(G _N :5%;RS), E13, E3, E8, E9, N1(G _N :7,5%;RS), 3xE9
D4-EXP/NUM	N7(G _N :7,5%;LS), N8(G _N :7,5%;LS), N11(G _N :7,5%;LS), N14(G _N :7,5%;LS), E2, N22(G _N :7,5%;LS), max.-Dummy, N18(G _N :7,5%;LS), N19(G _N :7,5%;LS), 2xE1, N20(G _N :7,5%;LS), min.-Dummy, N5(G _N :7,5%;LS), N7(G _N :7,5%;RS), N2(G _N :7,5%;RS), N17(G _N :7,5%;LS), N12(G _N :5%;LS), N20(G _N :5%;LS), E2, N4(G _N :5%;LS), N6(G _N :5%;LS), N8(G _N :5%;RS), E1, N9(G _N :5%;RS), N19(G _N :5%;RS), N2(G _N :5%;RS), N5(G _N :5%;RS)
D5-NUM	N7(G _N :7,5%;LS), N8(G _N :7,5%;LS), N11(G _N :7,5%;LS), N14(G _N :7,5%;LS), N1(G _N :5%;LS), N22(G _N :7,5%;LS), max.-Dummy, N18(G _N :7,5%;LS), N19(G _N :7,5%;LS), 2xN1(G _N :5%;LS/G _N :7,5%;E-2,5%;LS), N20(G _N :7,5%;LS), min.-Dummy, N5(G _N :7,5%;LS), N7(G _N :7,5%;RS), N2(G _N :7,5%;RS), N17(G _N :7,5%;LS), N12(G _N :5%;LS), N20(G _N :5%;LS), N1(G _N :7,5%;RS), N4(G _N :5%;LS), N6(G _N :5%;LS), N8(G _N :5%;RS), N1(G _N :5%;RS), N9(G _N :5%;RS), N19(G _N :5%;RS), N2(G _N :5%;RS), N5(G _N :5%;RS)
D6-NUM	LS: N7(G _N :5%), N7(G _N :7,5%), N8(G _N :5%), N8(G _N :7,5%), N9(G _N :5%), N9(G _N :7,5%), N10(G _N :7,5%) N11(G _N :7,5%), N12(G _N :5%), N12(G _N :7,5%), N13(G _N :5%), N14(G _N :7,5%), N15(G _N :5%), N15(G _N :7,5%), N16(G _N :7,5%), N1(G _N :7,5%;E-2,5%), N1(G _N :5%;E-2,5%), N1(G _N :7,5%;E+2,5%), N1(G _N :5%;E+2,5%), N1(G _N :7,5%), N1(G _N :7,5%;v-5%), N1(G _N :5%;v-5%), N1(G _N :7,5%;v+5%), N1(G _N :5%;v+5%), N1(G _N :7,5%;ρ-0,4%), N1(G _N :5%;ρ-0,4%), N1(G _N :7,5%;ρ+0,4%), N1(G _N :5%;ρ+0,4%), N1(G _N :6,25%), N1(G _N :5%), N1(G _N :8,75%), N1(G _N :10%), N1(G _N :7,5%), N1(G _N :5%), N7(G _N :7,5%), N8(G _N :7,5%), N15(G _N :7,5%), N6(G _N :7,5%), N22(G _N :7,5%), N17(G _N :7,5%), N18(G _N :7,5%), N19(G _N :5%), N19(G _N :7,5%), N20(G _N :5%), N20(G _N :7,5%), max.-Dummy, min.-Dummy, N3(G _N :5%), N3(G _N :7,5%), N4(G _N :5%), N4(G _N :7,5%), N5(G _N :5%), N5(G _N :7,5%), N6(G _N :5%), N6(G _N :7,5%), RS: dieselbe Reihenfolge der Datensätze wie bei LS, nur gegenüberliegende Sensorposition (N3 durch N2 ersetzt)

Fortsetzung Tabelle 7-6

Datenpool	Schadensnummern in eingesetzter Reihenfolge
D7-EXP	EP1, 2xEP1(nzg), 2xEP1, 3xEP1(nzg), EP1, 3xEP1(nzg), 3xEP2, EP2(nzg), EP3, 3xEP3(nzg), EP4, EP4(nzg), 2xEP5, EP5(nzg), 2xEP6, EP6(nzg), EP7, 3xEP7(nzg), EP8, 3xEP8(nzg), 2xEP9(nzg), EP2(nzg), EP3(nzg), EP4(nzg), EP5(nzg), EP6(nzg), EP7(nzg), EP8(nzg), min.-Dummy, max.-Dummy, zuzüglich aller seitenvertauschten Paare (d. h. EP1 bis EP8 gemäß Tabelle 7-2 werden auch als RS-LS-Paare in den Pool aufgenommen.)
D8-NUM	Trainingspaare sind nach LS und RS sortiert. G _N : 7,5 & LS - RS: N7, N8, N9, N10, N11, N12, N13, N14, N15, N16, N1(E-2,5%), N1(E+2,5%), N1, N7, N8, N15, N6, N22, N1(v-5%), N1(v+5%), N1(ρ-0,4%), N1(ρ+0,4%), N1(G _N :6,25%), N1(G _N :5%), N1(G _N :8,75%), N1(G _N :10%), N17, N18, N19, N20, N21, N1, N2, N3, N4, N5, N6, G _N : 5 & LS – RS: N7, N8, N9, N12, N15, N1(E-2,5%), N1(E+2,5%), N1(v-5%), N1(v+5%), N1(ρ-0,4%), N1(ρ+0,4%), N1(G _N :6,25%), N1(G _N :5%), N1(G _N :8,75%), N1(G _N :10%), N19, N20, N21, N1, N2, N3, N4, N5, N6

G_N: Dämpfungsfaktor

v: Poissonzahl

E: E-Modul

ρ: Dichte

LS: linke Seite (Abbildung 7-1) – entspricht Sensorposition 1 (Abbildung 3-10)

RS: rechte Seite (Abbildung 7-1) – entspricht Sensorposition 4 (Abbildung 3-10)

nzg: nicht zeitgleiche Messung von 2 Sensorpaaren (d. h. ±5% Abweichung laut Abbildung 4-13 möglich)

8 Literatur

8.1 Publikationen

Reviewed Papers

Zacharias, J.; Hartmann, Ch.; Delgado, A.: Damage Detection on Crates of Beverages by Artificial Neural Networks Trained with Finite-Element-Data. Submitted to: Computer Methods in Applied Mechanics and Engineering. May (2003).

Zacharias, J.; Hartmann, Ch.; Delgado, A.: Application of Neuro-Numerics for Damage Recognition on Crates of Beverages. Neural Network World 12 (2002), Nr. 6, S. 621/633.

Sonstige Papers

Zacharias, J.; Hartmann, Ch.; Delgado, A.: Automatische Aussortierung defekter Getränkekästen mittels Neuronumerik. Der Weihenstephaner 68 (2000), Nr. 4, S. 163/167.

Reviewed Conference Papers

Zacharias, J.; Hartmann, Ch.; Delgado, A.: Damages Recognition on Crates of Beverages by Artificial Neural Networks Trained with Data Obtained from Numerical Simulation. Proceedings of ICCS 2002 (International Conference on Computational Science) - Amsterdam, The Netherlands. In: Sloot, P.M.A.; Tan, C.J.K; Dongarra, J.J.; Hoekstra, A.G. (Eds.): Computational Science – ICCS 2002. Berlin: Springer-Verlag Vol. 2329 (2002), Part 1, S. 980/989.

Zacharias, J.; Hartmann, Ch.; Delgado, A.: Recognition of Damages on Crates of Beverages by an Artificial Neural Network. Proceedings of eunite 2001 (European Symposium on Intelligent Technologies, Hybrid Systems and their Implementation on Smart Adaptive Systems) - Tenerife, Spain. In: eunite 2001 – Final Programme & Proceedings (Abstracts + CD). Aachen: Verlag Mainz (2001), S. 69/76.

Sonstige Tagungen

Zacharias, J.: Online Detektion defekter Gebinde mittels Neuronumerik. Wissenschaftszentrum Weihenstephan: Handbuch zum 36. Technologischen Seminar. Weihenstephan 2003, S. 37.1/37.6.

Zacharias, J.: Schadenserkennung an Getränkekästen mittels Neuronumerik. Wissenschaftszentrum Weihenstephan: 22. Bayerisch-Tirolerisches Mechanik-Kolloquium. Weihenstephan 2002.

8.2 Literaturverzeichnis

- 1 O'Neill, T.: Dressed to Fill: Producing and Filling PET Bottles. Heidelberg: PETplanet Publisher 2001.
- 2 Foitzik, B.: Abfüllanlagen für die Getränkeindustrie: Konzepte, Techniken, Trends – Bibliothek der Technik. Bd. 200. Landsberg/Lech: Verlag Moderne Industrie 2000.
- 3 Weisser, H.: Entwicklungstendenzen in der Lebensmittel-Verpackungstechnik. Chemie Ingenieur Technik 72 (2000), Nr. 6, S. 934/935.
- 4 Weisser, H.: Meilensteine in der Abfülltechnik im 20. Jahrhundert. Brauwelt 139 (1999), Nr. 51/52, S. 2428/2430.
- 5 Vey, S.: Anlagenplanung in Brauereien und Getränkeabfüllbetrieben unter Verwenden von Standardsoftware. Dissertation. TU München 2000.
- 6 Rädler, T.: Modellierung und Simulation von Abfülllinien. Dissertation. TU München 1999.
- 7 Schaefer, H.: Kasten- und Flaschensortierung in Mineralwasserbetrieben – ein Problem ohne Ende? Der Mineralbrunnen 45 (1995), Nr. 6, S. 212/217.
- 8 Rädler, Th.: Cost Factors Related to Integrating Sorting Systems. Brauwelt International 14 (1996), Nr. 3, S. 224/229.
- 9 Lotz, M.: Einsatz von Sortieranlagen. Freising-Weihenstephan: TU München, Lehrstuhl für Brauereianlagen und Lebensmittel-Verpackungstechnik. 2. Flaschenkellerseminar, 1995.
- 10 Flad, W.; Vey, S.: Planung von Flaschenabfüllanlagen. Brauwelt 134 (1994), Nr. 13/14, S. 552/558.
- 11 Klein, F.: Leergutsortierung in der Getränketechnik. Getränketechnik 8 (1992), S. 46/52.
- 12 Brosch, B.: Knifflige Flaschensortierung. Brauwelt 140 (2000), Nr. 33/34, S. 1341/1344.
- 13 Kremkow, C.: Die Stabilität von Flaschenkästen nach längerer Gebrauchsdauer. Brauwelt 126 (1986), Nr. 3, S. 47/53.
- 14 Anonymus: Wie kann ein aktueller Flaschenkeller aussehen? Brauwelt 140 (2000), Nr. 13/14, S. 509/510.
- 15 Broesele, T.: Trockenteil in der Getränkeabfüllung. Brauwelt 136 (1996), Nr. 12, S. 570/575.
- 16 Johnstone, J.: Small Pack Inspection Technology. Ferment 12 (1999), Nr. 3, S. 33/44.

- 17 Nakazawa, K.; Iwasaki, I.; Yamashita, I.: Development of Damage Detection Systems for Container. Proceedings of the 1995 IEEE IECON (1995), Part 2, S. 1160/1163.
- 18 Aas, K.; Eikvil, L.; Bremnes, D.; Norbryhn, A.: Automatic Classification of Bottles in Crates. In: Proceeding of the SPIE – The International Society of Optical Engineering Vol. 2423 (1995), S. 108/117.
- 19 Magee, M.; Weniger, R.; Wenzel, D.; Pirasteh, R.: Recognition of Containers Using Multidimensional Pattern Classifier. In: Proceeding of the SPIE – The International Society of Optical Engineering Vol. 1825 (1992), S. 33/45.
- 20 Chen, H.; Aye, T.M.; Kim, D.H.; Latchinian, J.; Brown, V.A.; Kostrzewski, A.; Savant, G.; Jansson, T.; Pergantis, C.: Real-time Holographic Non-destructive Inspection System with Automatic Defect Classification. In: Proceeding of the SPIE – The International Society of Optical Engineering Vol. 3029 (1997), S. 109/116.
- 21 Jansen, R.; Krabs, A.: Automatic Identification in Packaging – Radio Frequency Identification in Multiway Systems. Packaging Technology and Science 12 (1999), Nr. 5, S. 229/234.
- 22 Hoppe, D.: Ein akustisches Resonanzverfahren zur Klassifikation von Füllständen. Technisches Messen 66 (1999), Nr. 6, S. 244/247.
- 23 Vargas, E.; Ceres, R.; Martin, J.M.; Calderon, L.: Ultrasonic Sensor for Liquid-Level Inspection in Bottles. Sensors and Actuators A61 (1997), S. 256/259.
- 24 Mattone, R.; Divona, M.; Wolf, A.: Intelligent Sensing for Automatic Sorting in Industrial Processes. In: EUFIT 98 - 6th European Congress on Intelligent Techniques and Soft Computing (1998), Part 2, S. 1399/1402.
- 25 Firmin, C.; Hamad, D.; Postaire, J.-G.; Zhang, R.D.: Gaussian Neural Networks for Glass Bottles Inspection: A Learning Procedure. International Journal of Neural Systems 8 (1997), Nr. 1, S. 41/46.
- 26 Milvang, O.; Olafsdotir, J.B.: Discriminating Crates from Colour Images. Proceedings of the 8th Scandinavian Conference on Image Analysis. NOBIM Norwegian Soc (1993), S. 659/664.
- 27 Anonymus: Automation der Leergutkastenkontrolle. Brauwelt 139 (1999), Nr. 15, S. 665.
- 28 Lotz, M.; Grabrucker, R.; Vogelpohl, H.: Projektieren von Sortieranlagen. Der Weihenstephaner 61 (1993), Nr. 1, S. 54/58.
- 29 Steindreischer, R.: Sortierung differenter Kästen. Neue Verpackung 32 (1979), Nr. 5, S. 543/544.
- 30 Rouillard, V.; Sek, M.A.: A Frequency Domain Technique for Maintaining Resonance Condition During Sine Dwell Vibration Testing of Packages. Packaging Technology and Science 13 (2000), Nr. 6, S. 227/232.
- 31 Weigl, T.G.; White, M.S.: The Effect of Pallet Connection Stiffness, Deck Stiffness and Static Load Level on the Resonant Response of Pallet Decks to

- Vibration Frequency Occurring in the Distribution Environment. *Packaging Technology and Science* 12 (1999), Nr. 2, S. 47/55.
- 32 Pitman, K.G.M.; Knight, M.R.; Grime, D.A.: Identification of Fractured Containers. UK Patent Application GB 2100432A. 1982.
 - 33 Karalekas, D.; Rapt, D.; Papakaliatakis, G.; Tsartolia, E.: Numerical and Experimental Investigation of Deformational Behaviour of Plastic Containers. *Packaging Technology and Science* 14 (2001), Nr. 5, S. 185/191.
 - 34 Doebling, S.W.; Farrar, C.R.; Prime, M.B.: A Summary Review of Vibration-Based Damage Identification Methods. *The Shock and Vibration Digest* 30 (1998), Nr. 2, S. 91/105.
 - 35 Salawu, O.S.: Detection of Structural Damage Through Changes in Frequency: a Review. *Engineering Structures* 19 (1997), Nr. 9, S. 718/723.
 - 36 Schmidt, R.: Die Anwendung von Zustandsbeobachtern zur Schwingungsüberwachung und Schadensfrüherkennung auf mechanische Konstruktionen. *Fortschritt-Berichte VDI. Reihe 11 Nr. 109.* Düsseldorf: VDI-Verlag 1988.
 - 37 Nauerz, A.; Fritzen, C.-P.: Model Based Damage Identification Using Output Spectral Densities. *Journal of Dynamic Systems, Measurement and Control* 123 (2001), Nr. 12, S. 691/698.
 - 38 Lee, J.: Free Vibration Analysis of Delaminated Composite Beams. *Computers and Structures* 74 (1999), Nr. 2, S. 121/129.
 - 39 Nowak, A.S.; Kim, S.; Stankiewicz, P.R.: Analysis and Diagnostic Testing of a Bridge. *Computers and Structures* 77 (2000), Nr. 1, S. 91/100.
 - 40 Wenzel, H.; Pichler, D.; Schedler, R.: Ambiente Schwingungsmessungen zur System- und Schadenserkenung an Tragwerken. *Bauingenieur* 74 (1999), Nr. 3, S. 115/123.
 - 41 Paya, B.A.; Esat, I.I.; Badi, M.N.M.: Artificial Neural Network Based Fault Diagnostics of Rotating Machinery Using Wavelet Transforms as a Preprocessor. *Mechanical Systems and Signal Processing* 11 (1997), Nr. 5, S. 751/765.
 - 42 Silva, R.G.; Reuben, R.L.; Baker, K.J.; Wilcox, S.J.: Tool Wear Monitoring by Neural Network and Expert System Classification of a Feature Set Generated from Multiple Sensors. *Mechanical Systems and Signal Processing* 12 (1998), Nr. 2, S. 319/332.
 - 43 Dalpiaz, G.; Riviola, A.: Condition Monitoring and Diagnostics in Automatic Machines: Comparison of Vibration Analysis Techniques. *Mechanical Systems and Signal Processing* 11 (1997), Nr. 1, S. 53/73.
 - 44 Zöllner, R.: Methoden der Nichtlinearen Dynamik zur Zustandsanalyse technischer Systeme. Dissertation. TH Darmstadt 1997.
 - 45 Strackeljan, J.: Klassifikation von Schwingungssignalen mit Methoden der unscharfen Mustererkennung. Dissertation. TU Clausthal 1993.
 - 46 Niemann, H.: Klassifikation von Mustern. Berlin: Springer-Verlag 1983.

-
- 47 Doering, A.: Optimierung der Merkmalsrepräsentation und Klassifikatorstruktur bei der Lösung von Mustererkennungsaufgaben mit Neuronalen Netzen. Fortschritt-Berichte VDI. Reihe 10 Nr. 541. Düsseldorf: VDI-Verlag 1998.
 - 48 Babel, W.: Einsatzmöglichkeiten neuronaler Netze in der Industrie: Mustererkennung anhand überwachter Lernverfahren – mit Beispielen aus der Verkehrs- und Medizintechnik. Renningen-Malmsheim: Expert Verlag 1997.
 - 49 Tsou, P.; Herman Shen, M.-H.: Structural Damage Detection and Identification Using Neural Networks. AIAA Journal 32 (1994), Nr. 1, S. 176/183.
 - 50 Bishop, C.M.: Neural Networks for Pattern Recognition. Oxford: Oxford University Press 1995.
 - 51 Wu, X.; Ghaboussi, J.; Garrett, J.H.: Use of Neural Networks in Detection of Structural Damage. Computers and Structures 42 (1992), Nr. 4, S. 649/659.
 - 52 Araujo dos Santos, J.V.; Mota Soares, C.M.; Mota Soares, C.A.; Pina, H.L.G.: A Damage Identification Numerical Model Based on the Sensitivity of Orthogonality Conditions and Least Square Techniques. Computers and Structures 78 (2000), Nr. 1/3, S. 283/291.
 - 53 Wang, Z.; Lin, R.M.; Lim, M.K.: Structural Damage Detection Using Measured FRF Data. Computer Methods in Applied Mechanics and Engineering 147 (1997), Nr. 1/2. S. 187/197.
 - 54 Visintainer, R.H.; Aslani, F.: Shake Test Simulation Using MSC/NASTRAN. MSC Users' Conference. USA. June (1994), S. 1/21.
 - 55 Alampalli, S.: Effects of Testing, Analysis, Damage, and Environment on Modal Parameters. Mechanical Systems and Signal Processing 14 (2000), Nr. 1, S. 63/74.
 - 56 Inman, D.J.; Minas, C.: Matching Analytical Models with Experimental Modal Data in Mechanical Systems. Control and Dynamic Systems 37 (1990), S. 327/363.
 - 57 Yagawa, G.; Okuda, H.: Neural Networks in Computational Mechanics. Archives of Computational Methods in Engineering 4 (1996), Nr. 3, S. 435/512.
 - 58 Worden, K.; Tomlinson, G.R.; Lim, W.; Sauer, G.: Modeling and Classification of Non-Linear Systems Using Neural Networks – II. A Preliminary Experiment. Mechanical Systems and Signal Processing 8 (1994), Nr. 4, S. 395/419.
 - 59 Soliman, H.H.; Elfattah, A.I.; Hamady, N.A.; Nour Eldin, H.A.: Classification of Flat Product-Defects Using Neural Networks Concepts. Computer Applications in Industry 1 (1992), S. 5/8.
 - 60 Hermans, L.; Van der Auweraer, H.: Modal Testing and Analysis of Structures under Operational Conditions: Industrial Applications. Mechanical Systems and Signal Processing 13 (1999), Nr. 2, S. 193/216.
 - 61 Masri, S.F.; Nakamura, M.; Chassiakos, A.G., Caughey, T.K.: Neural Network Approach to Detection of Changes in Structural Parameters. Journal of Engineering Mechanics 122 (1996), Nr. 4, S. 350/360.

-
- 62 Marwala, T.; Hunt, H.E.M.: Fault Identification Using Finite Element Models and Neural Networks. *Mechanical Systems and Signal Processing* 13 (1999), Nr. 3, S. 475/490.
 - 63 Stavroulakis, G.E.; Antes, H.: Neural Crack Identification in Steady State Elastodynamics. *Computer Methods in Applied Mechanics and Engineering* 165 (1998), Nr. 1/4, S. 129/146.
 - 64 Liu, S.W.; Huang, J.H.; Sung, J.C.; Lee, C.C.: Detection of Cracks Using Neural Networks and Computational Mechanics. *Computer Methods in Applied Mechanics and Engineering* 191 (2002), Nr. 25/26, S. 2831/2845.
 - 65 Fritzen, C.-P.; Jennewein, D.: Damage Detection Based on Model Updating Methods. *Mechanical Systems and Signal Processing* 12 (1998), Nr. 1, S. 163/186.
 - 66 Elkordy, M.F.; Chang, K.C.; Lee, G.C.: Neural Networks Trained by Analytically Simulated Damage States. *Journal of Computing in Civil Engineering* 7 (1993), Nr. 2, S. 130/145.
 - 67 Kudva, J.N.; Munir, N.; Tan, P.W.: Damage Detection in Smart Structures Using Neural Networks and Finite-Element-Analyses. *Smart Materials and Structures* 1 (1992), Nr. 2, S. 108/112.
 - 68 Benning, R.; Becker, T.; Delgado, A.: Principal Feasibility Studies Using Neuro-Numerics for Prediction of Flow Fields. In: *Neural Processing Letters* 16 (2002), S. 1/15.
 - 69 Zacharias, J.; Hartmann, Ch.; Delgado, A.: Application of Neuro-Numerics for Damage Recognition on Crates of Beverages. *Neural Network World* 12 (2002), Nr. 6, S. 621/633.
 - 70 Zacharias, J.; Hartmann, Ch.; Delgado, A.: Damages Recognition on Crates of Beverages by Artificial Neural Networks Trained with Data Obtained from Numerical Simulation. *Proceedings of ICCS 2002 – Amsterdam*. In: Sloot, P.M.A.; Tan, C.J.K.; Dongarra, J.J.; Hoekstra, A.G. (Eds.): *Computational Science – ICCS 2002*. Berlin: Springer-Verlag Vol. 2329 (2002), Part 1, S. 980/989.
 - 71 Benning, R.; Becker, T.; Delgado, A.: Initial Studies of Predicting Flow Fields with an ANN Hybrid. *Advances in Engineering Software* 32 (2001), S. 895/901.
 - 72 Delgado, A.; Nirschl, H.; Becker, T.: First Use of Cognitive Algorithms in Investigations under Compensated Gravity. *Microgravity Sci. Technol.* IX (1997), Nr. 3, S. 185-193.
 - 73 Li, S.: Global Flexibility Simulation and Element Stiffness Simulation in Finite Element Analysis with Neural Networks. *Computer Methods in Applied Mechanics and Engineering* 186 (2000), Nr. 1, S. 101/108.
 - 74 Levin, R.I.; Lieven, N.A.J.: Dynamic Finite Element Model Updating Using Simulated Annealing and Genetic Algorithms. *Mechanical Systems and Signal Processing* 12 (1998), Nr. 1, S. 91/120.

-
- 75 Atalla, M.J.; Inman, D.J.: On Model Updating Using Neural Networks. *Mechanical Systems and Signal Processing* 12 (1998), Nr. 1, S. 135/161.
 - 76 Zgonc, K.; Achenbach, J.D.: A Neural network for Crack Sizing Trained by Finite Element Calculations. *Non-Destructive Testing and Evaluation International* 29 (1996), Nr. 3, S. 147/155.
 - 77 Zacharias, J.; Hartmann, Ch.; Delgado, A.: Recognition of Damages on Crates of Beverages by an Artificial Neural Network. *Proceedings of eunite 2001 - Tenerife, Spain*. In: *eunite 2001 – Final Programme & Proceedings (Abstracts + CD)*. Aachen: Verlag Mainz (2001), S. 69/76.
 - 78 Zacharias, J.; Hartmann, Ch.; Delgado, A.: Automatische Aussortierung defekter Getränkekästen mittels Neuronumerik. *Der Weihenstephaner* 68 (2000), Nr. 4, S. 163/167.
 - 79 Sitton, G.: *MSC/NASTRAN Basic Dynamic Analysis User's Guide*. The McNeal-Schwendler Corporation. Los Angeles, USA 1997.
 - 80 Rieg, F.; Hackenschmidt, R.: *Finite Elemente Analyse für Ingenieure*. München: Carl Hanser Verlag 2000.
 - 81 Gawehn, W.: *Finite-Elemente-Methoden*. 3. Aufl. Braunschweig: Vieweg-Verlag 1988.
 - 82 Klein, B.: *FEM Grundlagen und Anwendungen*. 4. Aufl. Braunschweig: Vieweg-Verlag 2000.
 - 83 Müller, G.: *Die Finite-Element-Methode in der Baustatik*. Düsseldorf: Werner-Verlag 1993.
 - 84 Hagedorn, P.; Otterbein, S.: *Technische Schwingungslehre – Lineare Schwingungen diskreter mechanischer Systeme*. Berlin: Springer-Verlag 1987.
 - 85 Ewins, D.J.: *Modal Testing: Theory and Practice*. Vol. 7. Taunton, England: Research Studies Press LTD 1992.
 - 86 Wittenburg, J.: *Schwingungslehre*. Bd. 1. Berlin: Springer-Verlag 1996.
 - 87 Jürgler, R.: *Maschinendynamik: Lehrbuch mit Beispielen*. 2. Aufl. Düsseldorf: VDI-Verlag 1996.
 - 88 Rank, E.; Halfmann, A.; Rücker, M.: Integrierte Modellierungs- und Berechnungssoftware für den konstruktiven Ingenieurbau: Systemarchitektur und Netzgenerierung. *Bauingenieur* 75 (2000), S. 60/66.
 - 89 Rank, E.; Rücker, M.; Schweingruber, M.: Automatische Generierung von Finite Element-Netzen. *Bauingenieur* 69 (1994), S. 373/379.
 - 90 George, P.L.: *Automatic Mesh Generation – Application to Finite Element Methods*. Paris: J. Wiley & Sons 1991.

-
- 91 Entekin, A.: Accuracy of MSC/NASTRAN First- and Second- Order Tetrahedral Elements in Solid Modeling for Stress Analysis. Proceedings of the MSC Aerospace Users' Conference. USA. MSC-Library (1999), S. 1/8.
 - 92 Arden, K.E.: Evaluation of MSC's Parabolic Tetrahedron Finite Element. Proceedings of MSC Word Users' Conference. USA. MSC-Library (1994), S. 1/16.
 - 93 Stockwell, A.E.: A Verification Procedure for MSC/NASTRAN Finite Element Models. NASA Contractor Report 4675 (1995), S. 1/18.
 - 94 Pamidi, P.R.; Reymond, M.: Improvements to Dynamic Analysis in MSC/NASTRAN. Proceedings of the MSC Worldwide Automotive Conference. USA (2000), S. 1/22.
 - 95 Zell, A.: Simulation Neuroner Netze. Bonn: Addison-Wesley 1994.
 - 96 Patterson, D.W.: Künstliche neuronale Netze – Das Lehrbuch. München: Prentice Hall Verlag 1996.
 - 97 Gallant, S.I.: Neural Network Learning and Expert Systems. Massachusetts Institute of Technology 1994.
 - 98 Joerding, W.H.; Meador, J.L.: Encoding a Priori Information in Feedforward Networks. Neural Networks 4 (1991), Nr. 5, S. 847/856.
 - 99 Becker, T.M.: Management of Bioprocesses by Means of Modelling and Cognitive Tools. Habilitation. TU München 2001.
 - 100 Swingler, K.: Applying Neural Networks – A Practical Guide. San Diego: Academic Press Inc. 1996.
 - 101 Rafiq, M.Y.; Bugmann, G.; Easterbrook, D.J.: Neural Network Design for Engineering Applications. Computers and Structures 79 (2001), S. 1541/1552.
 - 102 Schürmann, J.: Pattern Classification – A Unified View of Statistical and Neural Approaches. New York: John Wiley & Sons Inc. 1996.
 - 103 Fugate, M.L.: Vibration-Based Damage Detection Using Statistical Process Control. Mechanical Systems and Signal Processing 15 (2001), Nr. 4, S. 707/721.
 - 104 Lang, K.J.; Witbrock, M.J.: Learning to Tell Two Spirals Apart. In: Touretzky, D.; Hinton, G.; Sejnowski, T. (eds.): Proceedings of the 1988 Connectionist Models Summer School. San Mateo, USA: Morgan Kaufman Publishers (1988), S. 52/60.
 - 105 Masters, T.: Practical Neural Network Recipes in C++. San Diego: Academic Press 1993.
 - 106 Szepesvári, C.; Lörincz, A.: Neurocontrol I: Self - Organizing Speed - Field Tracking. Neural Network World 6 (1996), Nr. 6, S. 875/896.
 - 107 Hirose, Y.; Koichi, Y.; Shimpei, H.: Backpropagation Algorithm which Varies the Number of Hidden Units. Neural Networks 4 (1991), Nr. 1, S. 61/66.

-
- 108 Armstrong, W.W.; Dwelly, A.; Liang, J.; Lin, D.; Reynolds, S.: Some Results Concerning Adaptive Logic Networks. Dept. of Computing Science. The University of Alberta, Canada 1991.
 - 109 Riedmiller, M.: RPROP – Description and Implementation Details, Technical Report. Institut für Logik, Komplexität und Deduktionssysteme. Universität Karlsruhe 1994.
 - 110 Carl, S.: Klassifikation landwirtschaftlicher Kulturen aus ERS - 1 SAR Satellitendaten mit Hilfe Neuronaler Netze. Dissertation. TU München 1996.
 - 111 Freeman, J.A.: Neural Networks: Algorithms, Applications and Programming Techniques. Massachusetts: Addison – Wesley 1992.
 - 112 Rumelhart, D.E.; McClelland, J.L.: Parallel Distributed Processing: Explorations in the Microstructure of Cognition. Vol. 1: Massachusetts: The MIT Press 1986.
 - 113 Haykin, S.: Neural networks. Englewood Cliffs, USA: Macmillan Publishing Company Inc. 1994.
 - 114 Rojas, R.: Theorie der neuronalen Netze – Eine systematische Einführung. Berlin: Springer-Verlag 1993.
 - 115 Stein, R.: Selecting Data for Neural Networks. AI Expert (1993), Nr. 2, S. 42/47.
 - 116 Ahmad, S.; Tesauro, G.: Scaling and Generalization in Neural Networks: a Case Study. In: Touretzky, D.; Hinton, G., Sejnowski, T. [eds.]: Proceedings of the 1988 Connectionist Models Summer School, Morgan Kaufman Publishers, San Mateo, CA (1988), S. 3/10.
 - 117 Cichocki, A.; Unbehauen, R.: Neural Networks for Optimization and Signal Processing. Stuttgart: John Wiley & Sons Ltd & B.G. Teubner 1993.
 - 118 Friedman, J.H.: An Overview of Predictive Learning and Function Approximation, In: Cherkassy, V., Friedman, J.H.; Wechsler, H. (eds.): From Statistics to Neural Networks – Theory and Pattern Recognition Applications. Berlin: Springer-Verlag 1994.
 - 119 Smith, M.: Neural Networks for Statistical Modelling. New York: Van Nostrand Reinhold 1993.
 - 120 Ye, X.; Li, T.: Edge – Preserving Vector Quantization Using a Neural Network. Proceedings of SPIE – The International Society for Optical Engineering Vol. 2898 (1996), S. 210/216.
 - 121 Reeder, B.M.; Gough, M.P.: Application of Artificial Neural Networks for Spacecraft Instrument Data Compression. Microprocessors and Microsystems. 20 (1996), Nr. 5, S. 285/295.
 - 122 Barschdorff, D.; Becker, D.: Neuronale Netze als Signal- und Musterklassifikatoren. Technisches Messen 57 (1990), Nr. 11, S. 437/444.
 - 123 Schoeller Wavin Systems Services GmbH. Oberhaching, Deutschland 2002.
 - 124 Schmiedl, H.: Handbuch der Kunststoffprüfung: die mechanischen Eigenschaften von Polymer-Werkstoffen. München: Carl Hanser Verlag 1992.

-
- 125 Retting, W.: Mechanik der Kunststoffe. München: Carl Hanser Verlag 1991.
 - 126 Giesecke, P.: Dehnungsmeßstreifentechnik – Grundlagen und Anwendungen in der industriellen Meßtechnik. Braunschweig: Verlag Vieweg 1994.
 - 127 Tichý, J.; Gautschi, G.: Piezoelektrische Meßtechnik – Physikalische Grundlagen, Kraft-, Druck- und Beschleunigungsaufnehmer, Verstärker. Berlin: Springer-Verlag 1980.
 - 128 Baker, R.: Eine Einführung in die Schwingungsprüfung. Ling Dynamik Systems Ltd. Ismaning 1998.
 - 129 Boller, H.: Schwingungsprüfung mit elektrodynamischen Schwingerregern (Folge 1-6). VFI – Der Versuchs und Forschungsingenieur (1996), Nr. 2, S. 24/27.
 - 130 Endevco: Handbuch der Schock- und Schwingungstechnik. Heidelberg: Weber Druck GmbH 1992.
 - 131 TIRA Maschinenbau GmbH. Schalkau, Deutschland 1999.
 - 132 National Instruments Services. Mönchengladbach, Deutschland 2001.
 - 133 MSC/Software Corporation. Santa Ana, USA 2002.
 - 134 Reynier, M.: Sensors Location for Updating Problems. Mechanical Systems and Signal Processing 13 (1999), Nr. 2, S. 297/314.
 - 135 MSC/NASTRAN Quick Reference Guide. Version 70.5. Vol. 7. The MacNeal-Schwendler Corporation. Los Angeles, USA 1998.
 - 136 Stanbridge, A.B.; Ewins, D.J.: Modal Testing Using a Scanning Laser Doppler Vibrometer. Mechanical Systems and Signal Processing 13 (1999), Nr. 2, S. 255/270.

Lebenslauf

PERSÖNLICHE DATEN

Name: Zacharias, Jörg Bernd
Geburtsdatum, -ort: 15. Mai 1970 in München
Familienstand: ledig

SCHULISCHE AUSBILDUNG

1976 bis 1981: Grund- und Hauptschule in München und Geretsried

1981 bis 1990: Gesamtschule Geretsried Gymnasium

Abschluss: Allgemeine Hochschulreife

WEHRDIENST

Juli 1990 bis Juni 1991: Grundwehrdienst als Sanitätssoldat Mat

UNIVERSITÄTSAUSBILDUNG

November 1991 bis Juni 1997:

Studium an der Technischen Universität München, Weihenstephan
„Technologie und Biotechnologie der Lebensmittel“

Semesterarbeiten in den Fachgebieten:

Lebensmittelverfahrenstechnik, Abfüll- und Verpackungstechnik

Diplomarbeit: an der University of Reading, England

„Rheological Properties of Gum Arabic in 50% Solution - Change after High Pressure Processing“

Abschluss: Diplom-Ingenieur Univ. (Dipl.-Ing. Univ.)

BERUFLICHE UND AKADEMISCHE TÄTIGKEITEN

seit Mai 1997: Wissenschaftlicher Angestellter am Lehrstuhl für Fluidmechanik und Prozessautomation der TU München, Weihenstephan

seit Mai 1998: Promotion zum Thema

„Automatische Schadenserkenkung an Getränkekästen mittels Neuronumerik“
Empfänger des Dr. Hermann Kronseder Stipendiums

angestrebter Abschluss: Dr.-Ing.

Juli bis November 2000: Nebentätigkeit am Lehrstuhl für Lebensmittelverfahrenstechnik und Molkereitechnologie der TU München, Weihenstephan

Weihenstephan, den 14. Februar 2003