

Technische Universität München

Lehrstuhl für Systemverfahrenstechnik

## **Automatische Selektion von Mehrweggütern der Lebensmittel- und Getränkeindustrie mittels Neurostatistik**

Markus Schmidt

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**

genehmigten Dissertation.

Vorsitzender: Univ.-Prof. Dr. U. M. Kulozik  
Prüfer der Dissertation: 1. Univ.-Prof. Dr. A. Delgado  
(Friedrich-Alexander-Universität Erlangen-Nürnberg)  
2. Univ.-Prof. Dr. Th. Becker  
3. Univ.-Prof. Dr. G. H. Müller

Die Dissertation wurde am 11.07.2011 bei der Technischen Universität München eingereicht und durch die Fakultät Wissenschaftszentrum Weihenstephan für Ernährung, Landnutzung und Umwelt am 31.01.2012 angenommen.

## **Vorwort**

Die vorliegende Arbeit entstand während und nach meiner Tätigkeit als wissenschaftlicher Mitarbeiter am Lehrstuhl für Fluidmechanik und Prozessautomation (LFP), später Lehrstuhl für Systemverfahrenstechnik, des Wissenschaftszentrums Weihenstephan (WZW) der Technischen Universität München (TUM). Die Durchführung dieser Arbeit wäre ohne die Unterstützung durch eine Vielzahl von Personen in dieser Form nicht möglich gewesen.

Mein besonderer Dank gilt:

- Meinem Doktorvater Prof. Dr.-Ing. Antonio Delgado, der mir immer mit Vertrauen und Fachwissen unterstützend zur Seite stand und mir viele akademische Freiheiten einräumte. Er zeigte sehr viel Geduld und Engagement und verlor niemals den Glauben an einen erfolgreichen Abschluss dieses Vorhabens.
- Prof. Dr.-Ing. Thomas Becker und Prof. Dr.-Ing. Gerhard Müller für die Übernahme der Koreferate.
- Prof. Dr.-Ing. Ulrich Kulozik für die Übernahme der Rolle des Vorsitzenden.

## **Inhaltsverzeichnis**

<b>1</b>	<b>EINLEITUNG</b>	<b>1</b>
1.1	Wissenschaftlich-technische Problemstellung	1
1.2	Getränkeabfüllanlagen	3
1.2.1	Aufbau und Funktionsweise von Getränkeabfüllanlagen	3
1.2.2	Inspektionsmaschinen in Getränkeabfüllanlagen	7
1.2.3	Industrielle Anforderungen an eine Kasteninspektionsmaschine	10
1.3	Forschungsziel	11
1.4	Lösungsweg zur Erreichung des Forschungsziels	11
<b>2</b>	<b>MATERIAL UND METHODEN</b>	<b>15</b>
2.1	Getränkekästen	15
2.2	Schwingungsanalyse zur Strukturanalyse von Festkörpern	17
2.2.1	Grundlagen	17
2.2.2	Anwendung der Schwingungsanalyse – Stand der Forschung	19
2.3	Modellerstellung und numerische Simulation	22
2.3.1	Numerische Simulation mit Finiter Elemente Methode (FEM)	23
2.3.2	Numerische Strukturanalyse unter Verwendung der FEM	26
2.3.3	Definition der Versuchsparameter	28
2.3.4	Simulation von Schadensfällen	29
2.3.5	Auswertung FEM	35
2.4	Datenvorverarbeitungsverfahren (DVV)	36
2.4.1	Fourier-Analyse	38
2.4.2	Datenkomprimierung	39
2.4.2.1	Numerische Integration nach Simpson	39
2.4.2.2	Hauptkomponentenanalyse	41
2.5	Mustererkennung mit Hilfe kognitiver Algorithmen	44
2.5.1	Künstliche Neuronale Netze (KNN)	44
2.5.1.1	Aufbau Künstlicher Neuronaler Netze	47
2.5.1.2	Lernverfahren in Künstlichen Neuronale Netzwerken	51
2.5.2	Anwendung der Neuronalen Netze zur Schadenserkennung	54
<b>3</b>	<b>VERSUCHSANLAGEN ZUR KASTENINSPEKTION</b>	<b>59</b>
3.1	Funktionsmuster 1 – Laboranlage	59
3.1.1	Aufbau von Funktionsmuster 1	60
3.1.2	Anlagensteuerung von Funktionsmuster 1	64
3.2	Funktionsmuster 2 - Feldversuchsanlage	65
3.2.1	Störende Randbedingungen in rauer Feldebene	65

3.2.2	Aufbau von Funktionsmuster 2	67
3.2.3	Anlagensteuerung von Funktionsmuster 2	71
<b>4</b>	<b>VORSTELLUNG UND DISKUSSION DER ERGEBNISSE</b>	<b>73</b>
<b>4.1</b>	<b>Ergebnisse der numerischen Simulation</b>	<b>74</b>
4.1.1	Eigenmoden	74
4.1.2	Definition der Versuchsparameter für die numerischen Simulationen	77
4.1.2.1	Anregungsorte	77
4.1.2.2	Anregungssignal	78
4.1.2.3	Fixierung des Getränkekastens	79
4.1.2.4	Signalerfassung auf dem Getränkekasten	80
4.1.3	Numerische Simulation des Schwingungsverhaltens eines Getränkekastens	81
4.1.4	Ermittlung der besten Sensorposition in Abhängigkeit von Anregungssignal und Fixierung	83
4.1.4.1	Bruch der Griffleiste - Modellschaden S01	85
4.1.4.2	Bruch an der Ecke - Modellschaden S02	86
4.1.4.3	Brüche im Gefache - Modellschaden S03	88
4.1.4.4	Brüche am Kastenboden - Modellschaden S04	89
4.1.5	Vergleich der Modellschäden	91
4.1.6	Ergebnisse der numerischen Simulationen mit Kastenmodell 1	93
4.1.6.1	Untersuchung verschiedener Schadensbilder	95
4.1.6.2	Vergleich verschiedener Signalerfassungspositionen	97
<b>4.2</b>	<b>Ergebnisse der experimentellen Schwingungsanalyse</b>	<b>104</b>
4.2.1	Schwingspektren	105
4.2.2	Reproduzierbarkeit	111
4.2.3	Eingangsdaten für die KNN	113
4.2.4	Verwendete KNN	114
4.2.5	Funktionsmuster 1	116
4.2.5.1	Versuche im Labor	116
4.2.5.2	Versuche auf Feldebene	119
4.2.6	Funktionsmuster 2	124
4.2.6.1	Auswirkung der KNN-Topologie auf die Prognosefähigkeit	126
4.2.6.2	Auswirkungen der Datenkomprimierung auf die Prognosefähigkeit	132
4.2.6.3	Hauptkomponentenanalyse	134
<b>5</b>	<b>ZUSAMMENFASSUNG UND AUSBLICK</b>	<b>150</b>
<b>6</b>	<b>ANHANG</b>	<b>156</b>
<b>6.1</b>	<b>Anhang A</b>	<b>156</b>
<b>6.2</b>	<b>Anhang B</b>	<b>158</b>
<b>6.3</b>	<b>Anhang C</b>	<b>176</b>
<b>6.4</b>	<b>Anhang D</b>	<b>179</b>
<b>7</b>	<b>LITERATUR</b>	<b>180</b>

## Abbildungsverzeichnis

Abbildung 1-1: Nennausbringung nach Berg	4
Abbildung 1-2: Abfüllanlage für MW-Glasabfüllung, Nennausbringung 60.000 Fl./h	7
Abbildung 1-3: Schema des Arbeitslaufs und der eingesetzten Methoden	14
Abbildung 2-1: Untersuchte Getränkekastenmodelle	15
Abbildung 2-2: Der Simulationsprozess	23
Abbildung 2-3: CAD-Getränkekastenmodelle	24
Abbildung 2-4: Tetraeder-Element zur Diskretisierung der kontinuierlichen Struktur	26
Abbildung 2-5: Finite-Elemente-Modell der Getränkekästen	28
Abbildung 2-6: Übersicht der simulierten Schäden	31
Abbildung 2-7: Modellschaden S06 Riss in der kurzen Griffleiste	32
Abbildung 2-8: Modellschaden S09 Riss in der langen Griffleiste	33
Abbildung 2-9: Modellschaden S18 Gefacheschaden	33
Abbildung 2-10: Modellschaden S16 fehlende Ecke	34
Abbildung 2-11: Modellschaden S21 Schaden im Bodengitter	34
Abbildung 2-12: Fließschema der Datenvorverarbeitung	37
Abbildung 2-13: Unterteilung des Frequenzspektrums in Integrationsklassen	40
Abbildung 2-14: Transformation in Hauptkomponenten	42
Abbildung 2-15: Transformation der Originaldaten in die Hauptkomponenten	43
Abbildung 2-16: Schema eines Künstlichen Neuronalen Netzes (KNN)	45
Abbildung 2-17: Neuron als kleinste Einheit in einem KNN	47
Abbildung 2-18: Verbindungsnetzwerk in einem Künstlichen Neuronalen Netz (KNN)	50
Abbildung 2-19: Fließende Grenze zwischen den Zuständen	56
Abbildung 2-20: Trainings- und Validierungsfehler eines KNN	58
Abbildung 3-1: Funktionsmuster 1	60
Abbildung 3-2: Beschleunigungsverlauf im Shaker-Stößel	61
Abbildung 3-3: Vorrichtung zur schnellen Kastenarretierung	62
Abbildung 3-4: Schema der Kastenarretierung	62
Abbildung 3-5: Anlagenschema von Funktionsmuster 1	64
Abbildung 3-6: Schwingungen von Transportketten in einem Kastenrundläufer (zeitlicher Verlauf der Beschleunigung)	66
Abbildung 3-7: Schwingungen von Transportketten in einem Kastenrundläufer (Frequenzspektrum)	66
Abbildung 3-8: Getränkekasteninspektor	67

Abbildung 3-9: Kastenarretierung	68
Abbildung 3-10: Pneumatischer Shaker	69
Abbildung 3-11: Arbeitsablauf des Kasteninspektors	70
Abbildung 3-12: Schematischer Aufbau der Kastenpositionierung	71
Abbildung 4-1: Auswahl von Eigenmoden des Getränkekastens berechnet mit Hilfe der numerischen Modalanalyse auf Basis der FEM	75
Abbildung 4-2: Auswahl von Eigenmoden des Getränkekastens berechnet mit Hilfe der numerischen Modalanalyse auf Basis der FEM	75
Abbildung 4-3: Auswahl von Eigenmoden des Getränkekastens berechnet mit Hilfe der numerischen Modalanalyse auf Basis der FEM	76
Abbildung 4-4: Untersuchte Positionen E1, E2, E3 zur Schwingungsanregung	77
Abbildung 4-5: Zeitverlauf des Anregungssignals	78
Abbildung 4-6: Fouriertransformiertes Anregungssignal	79
Abbildung 4-7: Fixierung des Getränkekastens	80
Abbildung 4-8: Sensorpunkte zur Erfassung des Schwingverhaltens	81
Abbildung 4-9: Darstellung der Amplitudenspektren eines Knotens auf der rechten Seite eines unbeschädigten Kastens angeregt in unterschiedlichen Kraftangriffspunkten	82
Abbildung 4-10: Darstellung der Frequenz eines unbeschädigten sowie eines beschädigten Kastens und das resultierende Differenzsignal	83
Abbildung 4-11: Darstellung der Differenzspektren eines Knotens auf der jeweiligen Vorderseite eines beschädigten Kastens (S01 – S04) angeregt vertikal von unten	93
Abbildung 4-12: Versuchsparameter der Simulationen mit Kastenmodell 1	94
Abbildung 4-13: Simulation verschiedener Beschädigungen	95
Abbildung 4-14: Simulation verschiedener Beschädigungen	96
Abbildung 4-15: Simulation verschiedener Beschädigungen	97
Abbildung 4-16: Vergleich verschiedener Messpositionen am unbeschädigten Kasten	99
Abbildung 4-17: Vergleich verschiedener Messpositionen am beschädigten Kasten mit Griffriß in der kurzen Griffleiste	100
Abbildung 4-18: Vergleich verschiedener Messpositionen am beschädigten Kasten mit Griffriß in der langen Griffleiste	101
Abbildung 4-19: Vergleich verschiedener Messpositionen am beschädigten Kasten mit Riss an der Ecke	102
Abbildung 4-20: Vergleich verschiedener Messpositionen am beschädigten Kasten mit defektem Gefache	103
Abbildung 4-21: Schadensbilder	105

Abbildung 4-22: Beschleunigungsverlauf in den Griffleisten	106
Abbildung 4-23: Frequenzspektren der gemessenen Schwingungen in den Griffleisten	106
Abbildung 4-24: Komprimierte Spektren eines defekten Kastens	107
Abbildung 4-25: Mittelwert und Standardabweichung der Frequenzspektren intakter Kästen	108
Abbildung 4-26: Mittelwert und Standardabweichung der Frequenzspektren defekter Kästen	109
Abbildung 4-27: Mittelwert und Standardabweichung der Frequenzspektren intakter Kästen	110
Abbildung 4-28: Mittelwert und Standardabweichung der Frequenzspektren defekter Kästen	110
Abbildung 4-29: Mittelwert und normierte Standardabweichung einer Mehrfachmessung	112
Abbildung 4-30: KNN-Fehler aufgetragen über Trainingszyklen	118
Abbildung 4-31: Mittlerer quadratischer Trainingsfehler	121
Abbildung 4-32: Mittlerer quadratischer Validierungsfehler	122
Abbildung 4-33: Mittlerer quadratischer Testfehler	123
Abbildung 4-34: Angepasste Gewichte in den KNN	125
Abbildung 4-35: Mittlerer quadratischer Trainingsfehler beim Trainingsprozess	128
Abbildung 4-36: Mittlerer quadratischer Validierungsfehler beim Trainingsprozess	129
Abbildung 4-37: Mittlerer quadratischer Testfehler nach dem Trainingsprozess	130
Abbildung 4-38: Mittlerer quadratischer Testfehler nach dem Trainingsprozess	130
Abbildung 4-39: Mittlerer quadratischer Testfehler nach dem Trainingsprozess	131
Abbildung 4-40: Amplituden der Originaldatensätze bei $f=488$ Hz	135
Abbildung 4-41: Zentrierte und standardisierte Amplituden der Originaldatensätze bei $f=488$ Hz	137
Abbildung 4-42: Konturplot der Korrelationsmatrix der skalierten Daten	138
Abbildung 4-43: Eigenwerte der Korrelationsmatrix	139
Abbildung 4-44: Eigenwerte aus der Korrelationsmatrix (absteigend sortiert)	140
Abbildung 4-45: Konturplot der Korrelationsmatrix der Hauptkomponenten	141
Abbildung 4-46: Screeplot für den Scree-Test	142
Abbildung 4-47: Mittlerer quadratischer Fehler während des Trainingsprozesses (Trainingsdatensatz)	146
Abbildung 4-48: Mittlerer quadratischer Fehler während des Trainingsprozesses (Validierungsdatensatz)	147

Abbildung 4-49: Mittlerer quadratischer Fehler während des Trainingsprozesses (Testdatensatz 1)	147
Abbildung 4-50: Mittlerer quadratischer Fehler während des Trainingsprozesses (Testdatensatz 2)	148
Abbildung 4-51: Mittlerer quadratischer Fehler während des Trainingsprozesses (Testdatensatz 3)	149
Abbildung 6-1: Ergebnisplot E03-S01-2	158
Abbildung 6-2: Ergebnisplot E03-S02-2	159
Abbildung 6-3: Ergebnisplot E03-S03-2	159
Abbildung 6-4: Ergebnisplot E03-S04-2	160
Abbildung 6-5: Ergebnisplot E03-S01-2	160
Abbildung 6-6: Ergebnisplot E01-S02-2	161
Abbildung 6-7: Ergebnisplot E01-S03-2	161
Abbildung 6-8: Ergebnisplot E01-S04-2	162
Abbildung 6-9: Ergebnisplot E02-S01-2	162
Abbildung 6-10: Ergebnisplot E02-S02-2	163
Abbildung 6-11: Ergebnisplot E02-S03-2	163
Abbildung 6-12: Ergebnisplot E02-S04-2	164
Abbildung 6-13: Ergebnisplot E03-S01-3	164
Abbildung 6-14: Ergebnisplot E03-S02-3	165
Abbildung 6-15: Ergebnisplot E03-S03-3	165
Abbildung 6-16: Ergebnisplot E03-S04-3	166
Abbildung 6-17: Ergebnisplot E01-S01-3	166
Abbildung 6-18: Ergebnisplot E01-S02-3	167
Abbildung 6-19: Ergebnisplot E01-S03-3	167
Abbildung 6-20: Ergebnisplot E01-S04-3	168
Abbildung 6-21: Ergebnisplot E02-S01-3	168
Abbildung 6-22: Ergebnisplot E02-S02-3	169
Abbildung 6-23: Ergebnisplot E02-S03-3	169
Abbildung 6-24: Ergebnisplot M02-S01-4	170
Abbildung 6-25: Ergebnisplot M02-S02-4	170
Abbildung 6-26: Ergebnisplot M02-S03-4	171
Abbildung 6-27: Ergebnisplot M02-S04-4	171
Abbildung 6-28: Ergebnisplot M03-S02-4	172



Abbildung 6-29: Ergebnisplot M03-S03-4	172
Abbildung 6-30: Ergebnisplot M03-S04-	173
Abbildung 6-31: Ergebnisplot E02-S01-4	173
Abbildung 6-32: Ergebnisplot E02-S02-4	174
Abbildung 6-33: Ergebnisplot E02-S03-4	174
Abbildung 6-34: Ergebnisplot E02-S04-4	175
Abbildung 6-35: Mittlerer quadratischer Fehler während des Trainingsprozesses	176
Abbildung 6-36: Mittlerer quadratischer Fehler während des Trainingsprozesses	177
Abbildung 6-37: Mittlerer quadratischer Fehler während des Trainingsprozesses	177
Abbildung 6-38: Mittlerer quadratischer Fehler während des Trainingsprozesses	178
Abbildung 6-39: Mittlerer quadratischer Fehler während des Trainingsprozesses	178
Abbildung 6-40: Screenshot des Lab-View Schaltbild	179

---

## Tabellenverzeichnis

Tabelle 2-1: Materialkennndaten der verwendeten Getränkekästen	16
Tabelle 2-2: Spezifikation der Finite-Elemente-Modelle	26
Tabelle 2-3: Liste der Einzelschäden	30
Tabelle 2-4: Aktivierungsfunktionen in einem Neuron	48
Tabelle 2-5: Wertebereiche eines Neuronenausganges	49
Tabelle 2-6: Spezifikation der Lernparameter für das Künstliche Neuronale Netz (KNN)	57
Tabelle 4-1: Übersicht der betrachteten Ergebnisdateien	84
Tabelle 4-2: Ergebnisplots (gebrochene Griffleiste)	86
Tabelle 4-3: Ergebnisplots (gebrochene Ecke)	87
Tabelle 4-4: Ergebnisplots (Gefachebrüche)	89
Tabelle 4-5: Ergebnisplots (Bodenbrüche)	90
Tabelle 4-6: Übersicht der auftretenden Maxima der ermittelten Kenngröße	91
Tabelle 4-7: Fünf lokale Maxima der größten Schwingungen bei verschiedenen Beschädigungen	98
Tabelle 4-8: Übersicht über die Versuchskastenpools	104
Tabelle 4-9: Übersicht der eingesetzten KNN	114
Tabelle 4-10: Zusammensetzung der KNN Eingangsdatensätze	116
Tabelle 4-11: Vergleich der Prognosen der verschiedenen KNN	117
Tabelle 4-12: Zusammensetzung der KNN Eingangsdatensätze	119
Tabelle 4-13: Vergleich der Prognosen der verschiedenen KNN	120
Tabelle 4-14: Zusammensetzung der KNN Eingangsdatensätze	124
Tabelle 4-15: Übersicht der durchgeführten Trainingszyklen	125
Tabelle 4-16: Vergleich der Prognosen der verschiedenen KNN	127
Tabelle 4-17: Komprimierung der Eingangsdaten der KNN	132
Tabelle 4-18: Ergebnisse des KNN-Trainings	133
Tabelle 4-19: Verwendetes Datenmaterial	134
Tabelle 4-20: Korrelationsmatrix R berechnet aus den Originaldaten	137
Tabelle 4-21: Gesamtvariation in Abhängigkeit von signifikanten Hauptkomponenten	143
Tabelle 4-22: Ergebnisse des KNN-Trainings	144
Tabelle 6-1: Modellschäden am Kasten Modell Amstel	156
Tabelle 6-2: Modellschäden am Kasten Modell Amstel	157

## Verzeichnis der Abkürzungen und Symbole

### Abkürzungen

BGB	Bürgerliches Gesetzbuch
CAD	Computer Aided Design
CCD	Charge-Coupled-Device
CM	Condition Monitoring
DIN	Deutsches Institut für Normung
DVV	Datenvorverarbeitungsverfahren
FE	Finite-Elemente
FEM	Finite Elemente Methode
FFT	Fast Fourier Transformation
GDB	Gesellschaft Deutscher Brunnen
HKA	Hauptkomponentenanalyse
IGES	Initial Graphics Exchange Specification
KI	Künstliche Intelligenz
kmU	kleine und mittlere Unternehmen
KNN	Künstliche Neuronale Netze
LDS	Ling-Dynamic Systems
LFP	Lehrstuhl für Fluidmechanik und Prozessautomation
LRZ	Leibniz-Rechenzentrum
MLP	Multi-Layer-Perzeptron (Mehrschichtennetz)
MSC	McNeal Schwendler Corporation
MW	Mehrweg
NDE	Non-Destructive Evaluation
PCA	Principal Component Analysis (Hauptkomponentenanalyse)
SHM	Structural Health Monitoring
SPC	Statistical Process Control
TET10	Tetraederelement mit zehn Knotenpunkten (FEM)
VDM	Verband Deutscher Mineralbrunnen
VI	Virtuelles Instrument (Lab-View)

Lateinische Buchstaben

$A$	Amplitude
$a$	Beschleunigung
$a_j$	Aktivierungsfunktion (KNN)
$a_n$ und $b_n$	Fourier-Koeffizienten
$d$	Tage
$Ec$	Kriechmodul
$E$	Elastizitätsmodul
$E$	Residuenmatrix (HKA)
$E$	Netzfehler (KNN)
$f_{Abtast}$	Abtastfrequenz
$h$	Stunden
$\dot{f}_{akt}$	Aktivierungsfunktion (KNN)
$Hz$	Hertz
$I_A$	Flächenmoment
$i, j$	Indizes
$m$	Meter
$K$	Anzahl der Hauptkomponenten
$M$	Anzahl der Variablen bzw. Merkmale (HKA)
$N$	Anzahl der Messungen
$net_j$	Propagierungsfunktion, Eingabefunktion (KNN)
$o_j$	Ausgabefunktion (KNN)
$P$	Faktorenmatrix (HKA)
$p$	Trainingsbeispiele
$s$	Sekunden
$T$	Periodenlänge
$T$	reduzierte Datenmatrix, Gewichtsmatrix (HKA)
$t_n$	Messzeitraum
$t$	Abtastintervall

## Verzeichnisse

---

$t_{pj}$	Sollwert des Ausganges (KNN)
$w_{ij}$	Gewicht der Verbindung zwischen Knoten i und j (KNN)
$X$	Originaldatenmatrix (HKA)
$X^T$	Korrelationsmatrix (HKA)
$x_n(x_{n1}, x_{n2}, \dots, x_{nm})$	Vektorkoordinaten im Originaldatenraum (HKA)
$x_t(x_{t1}, x_{t2}, \dots, x_{tk})$	Vektorkoordinaten im transformierten Datenraum (HKA)

### Griechische Buchstaben

$\delta_{pj}$	Differenz aus berechnetem zu gewünschtem Ausgangswert (KNN)
$\Delta f$	Frequenzintervall
$\Delta W$	Änderung der Gewichte (KNN)
$\varepsilon$	Dehnung bzw. Verzerrung
$\eta$	Lernrate (KNN)
$\lambda$	Eigenwert
$\nu$	Querdehnungszahl, Poisson-Zahl
$\pi$	Kreiszahl
$\Sigma$	Summe
$\rho$	Dichte
$\sigma$	Längs bzw. Normalspannung
$\omega_0$	Kreisfrequenz

# 1 Einleitung

Die Lebensmittelverpackung hat seit der Einführung der industriellen Produktion von Lebensmitteln stark an Bedeutung gewonnen. So wie die Absatznetzwerke für Lebensmittel durch den globalen Handel und die Massenproduktion an Komplexität gewonnen haben, stiegen auch die Anforderungen an diese Verpackungen. Während ihres Einsatzes müssen sie für das Packgut 'Lebensmittel' den größtmöglichen Schutz vor physikalischen, chemischen und mikrobiellen Einflüssen gewährleisten. Die Verpackungen dürfen für den Verbraucher keine gesundheitlichen Risiken bergen, sollen aus umweltverträglichen Materialien bestehen und außerdem durch ihr werbewirksames Erscheinungsbild zum Kauf animieren. Ein großer Bereich der Lebensmittelverpackungen besteht aus den Getränkeverpackungen, welche aus Glas, Kunststoff oder Verbundmaterialien wie Alu, Kunststoff und Karton gefertigt werden. Man unterscheidet hierbei zwischen Einweg- und Mehrwegverpackungen.

## 1.1 Wissenschaftlich-technische Problemstellung

Die Verpackungsverordnung von 1991 sieht die Einführung eines Zwangspfandes auf Einwegverpackungen vor, falls der Mehrweganteil unter den Sollwert von 72 % fällt. Aus diesem Grund wird seit dem 01.01.2003 ein Pfand auf bestimmte Einwegverpackungen erhoben. Dies betrifft alle Einwegverpackungen von Bier, Mineralwasser, Cola und Limonade, d.h. hauptsächlich Getränkedosen sowie Einwegflaschen aus Glas oder Kunststoff. Diese Verordnung unterstützt die Verwendung von Mehrweggütern nachhaltig und zeigt, dass die Mehrwegverpackungen auch in der Zukunft eine signifikante Rolle spielen werden. Neben der Weiterentwicklung und Produktion dieser Güter ist auch der Erhalt bestehender Verpackungspools ein bedeutender wirtschaftlicher Faktor. Die Verpackungen eines Mehrwegverpackungspools müssen nach jedem Zyklus gereinigt, inspiziert und wieder gefüllt werden. Bei der Inspektion erfolgt eine Überprüfung der Verpackung auf Schäden, z. B. Veränderungen von Material und Form, oder auf Rückstände von schwer entfernbaren Verschmutzungen. Erfüllt eine Verpackung die an sie gestellten Anforderungen nicht mehr vollständig, muss sie durch eine neue ersetzt werden.

Statistische Erhebungen, durchgeführt vom Verband Deutscher Mineralbrunnen (VDM) aus dem Jahre 2006, zeigen, dass derzeit ca. 1,7 Milliarden Mehrwegflaschen (Kunststoff und Glas) auf dem Mineralwassermarkt umlaufen [1]. Als Transport- und Schutzbehälter für diese Flaschen dienen 165 Millionen Mehrweg-Getränkekästen aus Kunststoff, die im Durchschnitt

hundertmal den Mehrwegkreislauf durchlaufen. Betrachtet man alle Getränkebetriebe in Deutschland, so beläuft sich die Anzahl der Mehrwegkästen auf ca. 500 Millionen.

Die Gesellschaft Deutscher Brunnen (GDB), welche den größten Getränkekasten-Mehrwegpool in Deutschland besitzt, hat 2003 in einem so genannten 500-Kasten-Test insgesamt 54.000 Kästen in 108 Betrieben untersucht und festgestellt, dass ca. 6,27 % dieser Kästen schadhaft sind und sich damit nicht zur Weiterverwendung im Mehrwegpool eignen [2].

Eine wesentliche Ursache dafür bilden die derzeit eingesetzten Detektionsmethoden zur Erkennung von Schäden an Getränkekästen (siehe auch Kapitel 2). Deren mangelhafte Erkennung von kleinen und verdeckten Schäden sowie die beschränkte Analysefähigkeit auf begrenzte Bereiche eines Gebindes liefern den Grund, dass nach wie vor eine Vielzahl an schadhaften Kästen in den Mehrwegkreislauf zurück gelangen und in der Logistikkette von der Befüllung bis zum Endverbraucher Komplikationen verursachen. Der dadurch entstehende wirtschaftliche Schaden, aber auch der Imageverlust der Getränkehersteller durch mangelhafte Ware bei den Kunden, erfordert eine Verbesserung der Aussortierquote von defekten Gebinden.

Die Verbesserung und Effizienzoptimierung der Leergutsortierung unterstützt vor allem kleine und mittlere Unternehmen, da gerade diese einen hohen Anteil an Mehrweggebinden aufweisen. Exemplarisch gehören hierzu 217 überwiegend mittelständischen Mineralbrunnenbetriebe (92 % kmU, 14.000 Beschäftigte, 165 Mio. umlaufende Kästen) und 1.302 Braustätten in Deutschland (vorwiegend kleine und mittelständische Brauereien, 33.737 Beschäftigte, 150 Mio. umlaufende Kästen) [3]. Im Mineralbrunnenbereich erfordert eine vorgeschriebene Aussortierquote von 0,6 % die Neuanschaffung von ca. sechs Millionen Kästen pro Jahr. Ein zuverlässiges Sortiersystem, das die Aussortierung auf tatsächlich defekte oder überalterte Kästen beschränkt, erspart den Mineralbrunnenbetrieben bei einer Reduktion der Sortierquote um nur 0,1 % bereits eine jährliche Neuanschaffung von einer Million Kästen.

## 1.2 Getränkeabfüllanlagen

Die DIN 8782 (Begriffe für Abfüllanlagen und einzelne Aggregate) bezeichnet Abfüllanlagen als „die Gesamtheit der im Verbund zusammenwirkenden einzelnen Aggregate zum Abfüllen von Getränken, einschließlich der vor- und nachgeschalteten Maschinen und Geräte – in der Regel von der Eingabe des gepackten und gegebenenfalls palettierten Leerguts bis zur Ausgabe des gepackten und gegebenenfalls palettierten Vollguts“.

Auch definiert diese DIN normierte Kennzahlen zur Bewertung der Leistungsfähigkeit von Getränkeabfüllanlagen (Nennausbringung, Wirkungsgrad usw.). Diese spielen bei der Abnahme einer Abfüllanlage nach der Inbetriebnahme oder auch nach langjähriger Laufzeit eine große Rolle und sind fester Bestandteil eines Kaufvertrages zwischen dem Anlagenhersteller und dem Getränkehersteller. Sie dienen hauptsächlich zur standardisierten Bewertung und zum Vergleich verschiedener Anlagen [4, 5].

### 1.2.1 Aufbau und Funktionsweise von Getränkeabfüllanlagen

Die Wiederbefüllung von gebrauchten Mehrweggütern zum Zweck des Wiederverkaufes an den Kunden ist eine logische serielle Abarbeitung von verschiedenen Prozessschritten, z. B. das Reinigen von verschmutzten Flaschen oder das Befüllen von gereinigten Flaschen, und bedarf einer optimalen Planung. Die Ausführung der einzelnen Prozessschritte erfolgt dabei durch eine eigenständige Maschine. Der Transport zwischen den Maschinen erfordert Förderbänder, die durch eine definierte Überdimensionierung als Puffer fungieren können. Damit lässt sich bei der Störung eines Aggregates eine sofortige Auswirkung auf vor- und nachgeschaltete Aggregate abpuffern. Die Größe dieser Puffer hängt sowohl von den baulichen Gegebenheiten als auch von statistischen Kenndaten, z.B. wie lange eine Störung des betrachteten Aggregates im Durchschnitt dauert, ab. Ziel der Planung der einzelnen Aggregate und der dazwischen liegenden Pufferstrecken ist es immer, das zentrale Organ der Anlage, die Flaschenfüllmaschine, effizient, also ohne Stillstandzeiten, zu betreiben. Die Überdimensionierung der Aggregate vor und hinter der Füllmaschine gewährleistet dies. Damit ist es den Aggregaten möglich, auch nach kurzen Störzeiten die voll- bzw. leer gelaufenen Pufferstrecken wieder in einem optimalen Befüllungszustand zu bringen (Abbildung 1-1 zeigt diese Überdimensionierung der Aggregate exemplarisch nach Berg [6]). Um die Gesamtausbringung einer Anlage zu berechnen, spielt demnach nicht nur die Ausbringung am Flaschenfüllorgan eine Rolle sondern die Gesamtheit aller Aggregate.






Abbildung 1-1: Nennausbringung nach Berg

Die Aggregate erfüllen im Abfüllprozess folgende Aufgaben [7, 8]:

### **Palettenentlademaschine**

Die Palettenentlademaschine lädt die Getränkekästen von der Palette auf einen Kistenförderer, welcher zur Kastensortierung führt. Nach einer Überprüfung der entladenen Paletten werden diese in einem Palettenmagazin zwischengestapelt oder, sofern sie defekt sind, aus der Produktion entfernt.

### **Auspackmaschine**

Die Auspackmaschine packt die Flaschen des Getränkekastens mit einem Greifkopf aus und setzt die Flaschen auf einen Flaschenförderer. Nach einer Flaschenvorsortierung erfolgt die Reinigung in der Reinigungsmaschine. Ihre Ausbringung richtet sich nach den folgenden Maschinen und dem verfügbaren Platz auf den Pufferbereichen der Flaschenförderer. Die Befüllung der Flaschenförderer erfolgt mittels Stauschalter. Eine vollständige Befüllung der nachfolgenden Transportketten führt zum Abschalten der Auspackmaschine.

### **Kastenmagazin, Kastenreinigungsmaschine**

Um die Getränkekästen von Verunreinigungen und Fremdstoffen zu reinigen, müssen diese vor der erneuten Befüllung eine Kastenreinigungsmaschine durchlaufen. Besteht ein Überschuss an Getränkekästen auf der Anlage, erfolgt eine Zwischenlagerung in einem Kastenmagazin.

### **Flaschenreinigungsmaschine**

Analog zur Kastenreinigungsmaschine durchlaufen auch die gebrauchten Flaschen in sogenannten Flaschenzellen, welche an einer Kette befestigt sind, eine Flaschenreinigungsmaschine, um Verunreinigungen zu entfernen. Dies geschieht mit Hilfe von verschiedenen Lauge- und Wasserbädern.

### **Leerflascheninspektionsmaschine**

Die aus der Reinigungsmaschine kommenden Flaschen durchlaufen zunächst eine Überprüfung in der Leerflascheninspektionsmaschine bevor sie die Füllmaschine erreichen. Die Leerflascheninspektionsmaschine hat die Aufgabe, mittels Kamera-, Infrarot- und Hochfrequenztechnik mögliche Beschädigungen oder Verschmutzungen der Flaschen bzw. Restflüssigkeiten in den Flaschen zu erkennen und diese Flaschen aus dem Prozess zu entfernen. Damit sinkt die Gefährdung von Produkt und Konsumenten. Im Falle einer Beschädigung folgt das Recycling der Flaschen, im Falle von Verunreinigungen oder Restflüssigkeiten schließt sich ein weiterer Reinigungsvorgang in der Reinigungsmaschine an. Heutige Leerflascheninspektionsmaschinen sind häufig als Linearmaschinen ausgeführt und in ihrer Ausbringung frei regelbar. Um Pufferstrecken zu sparen, geschieht häufig eine elektronische Verblockung mit der Füll- und Verschließmaschine. Eine in der Fördergeschwindigkeit elektronisch regelbare einsträngige Transportkette ohne Speichervermögen verbindet dabei die Leerflascheninspektionsmaschine mit der Füll- und Verschließmaschine.

### **Füll- und Verschließmaschine**

Die Füllmaschine füllt die Flaschen mit dem Getränk und versieht diese anschließend mit einem Kronenkorken, einem Anrollverschluss oder einem Schraubverschluss.

**Ausstattungsmaschine**

Die Ausstattungsmaschine etikettiert die Flaschen, um diese vorschriftsmäßig zu kennzeichnen und ihnen ein für den Verbraucher ansprechendes Äußeres zu verleihen.

**Einpackmaschine**

Die Einpackmaschine packt die gefüllten Flaschen, analog zur Auspackmaschine, wieder in die Kästen.

**Palettenbelademaschine**

Die Palettenbelademaschine funktioniert analog zur Entlademaschine. Sie stapelt die Kästen auf Paletten, die dann in das Vollgutlager transportiert werden.

**Behälterförderer**

Abfüllanlagen sind lineare Netzwerke mehrerer Einzelmaschinen. Für den Transport der Behälter von Maschine zu Maschine dienen Scharnierbandketten aus Edelstahl oder Kunststoff.

**Kastenförderer**

Der Transport der Getränkekästen von der Auspack- bis zur Einpackmaschine findet auf ein- oder mehrsträngigen, staufähigen Förderstrecken – ausgeführt als Rollenbahnen oder Kettenbänder – statt.




Abbildung 1-2: Abfüllanlage für MW-Glasabfüllung, Nennausbringung 60.000 Fl./h

- 1) Palettenentlademaschine, 2) Palettenkontrollmaschine, 3) Palettenbelademaschine, 4) Bindemaschine, 5) Neuglasabräumer, 6) Kastenkontrollmaschine, 7) Auspackmaschine, 8) Flaschenreinigungsmaschine, 9) Flascheninspektionsmaschine, 10) Flaschenfüll- und Verschließmaschine, 11) Ausstattungsmaschine, 12) Einpackmaschine, 13) Kasteninspektionsmaschine, 14) Kastenreinigungsmaschine, 15) Kastenmagazin

In Abbildung 1-2 ist das Schema einer Abfüllanlage für Mehrwegglasflaschen dargestellt. Die Nennausbringung dieser Anlage beträgt 60.000 Flaschen pro Stunde. Die Aggregate sind alle innenliegend, damit das Personal zwischen den Aggregaten nur kurze Wege zurücklegen muss. Somit ist der Betrieb der Anlage mit wenig Personalmitteln zu bewerkstelligen.

### 1.2.2 Inspektionsmaschinen in Getränkeabfüllanlagen

Bei den Inspektionsmaschinen einer Getränkeabfüllanlage, die für die Unversehrtheit, Sauberkeit der Kästen und Flaschen sowie deren Sortenreinheit eingesetzt werden, kann man unterscheiden zwischen dem Durchsatz, den dieses Aggregat pro Stunde leistet, sowie der Güte, mit der die Erkennung erfolgt.

Durch die gesetzlich vorgegebenen maximalen Abweichungen vom Nennfüllstand eines Getränkegebundes wird bei den Füllstandssensoren neben der Ausbringungsleistung hoher Wert auf die Genauigkeit dieses Inspektors gelegt. Nur ein gewisser Prozentsatz der abgefüllten Flaschen darf dabei den Nennfüllstand unterschreiten (siehe Fertigpackungsverordnung in der Fassung der Bekanntmachung vom 8. März 1994 (BGBl. I S. 451, 1307), zuletzt geändert durch Artikel 392 der Verordnung vom 31. Oktober 2006 (BGBl. I S. 2407)). Dabei kommen neben optischen Methoden häufig akustische Sensorverfahren zum Einsatz [9, 10].

Auch die Gefährdung des Kunden durch Fremdkörper oder Reinigungsmittel im Produkt sowie Beschädigungen an den Getränkeflaschen fordert durch das Produkthaftungsgesetz vom Anlagenbetreiber einen sicheren Ausschluss dieser Gefahr durch entsprechende Inspektionstechnik. Auch hier sind hauptsächlich optische Verfahren im Einsatz [11-15].

Demgegenüber ist die Sortierquote für Getränkekästen noch nicht gesetzlich reglementiert und somit einzig dem Anlagenbetreiber überlassen. Während die Gesellschaft Deutscher Brunnen die Benutzer ihres Getränkekastenpools mit einer künstlichen Sortierquote, welche auf statistischen Erhebungen beruht, dazu zwingt, alte Getränkekästen gegen neue auszutauschen, haben Brauereien im Allgemeinen dazu keine Auflagen. Dem Risiko der eintretenden Produkthaftung bzw. des Imageverlustes beim Kunden stehen für sie die Kosten für die Einspeisung neuer Getränkekästen gegenüber.

Zusätzlich tragen die Abfüllbetriebe dafür Sorge, nicht nur defekte Getränkekästen auszusortieren, sondern auch, dass nur sortenreines Leergut die Anlagen erreicht. Da die Individualisierung der einzelnen Marken in der jüngsten Vergangenheit eine Vielzahl ähnlicher Leergüter (z.B. gleiches Getränkekastenmodell mit unterschiedlichem Logo) auf den Markt gebracht hat, müssen die Abfüllbetriebe unter Einsatz von Sortieranlagen in ihrem eigenen Interesse eine Sortentrennung vornehmen, um nur das markeneigene Leergut wiederzubefüllen [16-26].

Nach dem heutigen Stand der Technik werden derzeit in den meisten Getränkebetrieben hauptsächlich optische Sortiersysteme zur Leer- und Vollgutkontrolle in Abfüllanlagen verwendet. Diese Systeme basieren auf einer elektronischen Auswertung von Bildaufnahmen mit digitalen CCD-Kameras (Charge-Coupled-Device) [16, 27-29].

Üblicherweise geschieht die Erkennung durch den Vergleich von einem oder mehreren aufgenommenen Bildern mit einem vorgegebenen Sollbild. Abweichungen in diesem Vergleich führen anschließend zur Klassifikation des jeweiligen Untersuchungsobjektes. Untersuchungskriterien können dabei sein:

**Bei Flaschen:** Füllstand, Verschlusskontrolle, Mündungskontrolle, Bodenkontrolle, Fremdkörpererkennung, Etikettenkontrolle, Schadenserkenung usw.

**Bei Kästen:** Flaschenhöhen, Auspackbarkeit, Formatkontrolle, Restverschlüsse, Bügelverschlüsse, Flaschenfarbe im Kasten, Kastenfarbe, Kastenlogo, Kastencode, Schadenserkenung usw.

Die optischen Systeme der Schadenserkenung werden teilweise durch Ultraschall oder holographische Systeme ergänzt [30, 31]. Diese sind jedoch lokal auf bestimmte Regionen des Kastens (z.B. nur Griffleiste) eingeschränkt. Ein Patent beschreibt einen Aufbau zur Kasten- und Flascheninspektion, bei dem mit Hilfe von mehreren Umlenkspiegeln, einer speziellen Beleuchtung und einer Kamera, die über dem zu untersuchenden Objekt aufgehängt ist, eine Aufnahme des Untersuchungsobjektes gemacht wird. Durch die Umlenkspiegel entsteht ein zusammengesetztes Bild des Getränkekastens, das mindestens zwei unterschiedliche Ansichten des zu untersuchenden Gegenstandes enthält [32]. Andere Systeme sortieren den Kasten typ lediglich durch Identifizierung eines Barcodes an der Seitenwand, Erkennung des Logos oder über die Erkennung anhand eines in den Kasten eingegossenen Transponders [33]. Zusammenfassend beruhen alle diese Systeme auf optischen oder akustischen Verfahren. Sie eignen sich durchaus für eine äußere Beurteilung der Getränkekästen, doch ermöglichen sie es nur schwer oder gar nicht, verdeckte und kleinere Schäden oder Kästen hohen Alters ausfindig zu machen.

### 1.2.3 Industrielle Anforderungen an eine Kasteninspektionsmaschine

Der schlechte Zustand der Kastenmehrwegpools der Getränkeindustrie zeigt die Notwendigkeit einer zuverlässigen Sortierung [2]. Die Anlagenbetreiber stellen Anforderungen an diesen Prozess, um den Betrieb der Anlagen effizient zu halten. Dabei gilt grundsätzlich, nur Kästen auszusortieren, die unterhalb eines definierten Qualitätskriteriums liegen [34]. Außerdem muss die Kasteninspektionsmaschine in die vorhandene Abfüllanlage integrierbar sein, ohne deren Fluss zu stören. Grundsätzlich hat der Einbau der Kasteninspektionsmaschine im Bereich des Leerkastentransports zu erfolgen, also zwischen Flaschenauspack- und Flascheneinpackmaschine. Innerhalb der diese beiden Maschinen verbindenden Kastenförderstrecke befindet sich generell eine Kastenreinigungsmaschine mit einem vorgeschalteten und einem nachgeschalteten Kastenwender zur Restentleerung. Nach der Kastenreinigungsmaschine ist häufig ein Kastenmagazin als Pufferspeicher integriert.

Im Einzelnen gilt es im Rahmen der praktischen Erprobung folgende Randbedingungen zu berücksichtigen:

Der Leerkastendurchsatz beträgt im einsträngigen Förderbereich bis zu maximal 3000 Kästen pro Stunde. Dies entspricht in Brauereien einer Anlagenausbringung von 60.000 und in Brunnenbetrieben von 36.000 Flaschen pro Stunde. Üblicherweise werden Kasteninspektoren mit ca. 125 % und Flascheninspektoren mit ca. 110 % der Anlagenausbringung der Abfüllanlage betrieben, um einen kontinuierlichen Füllbetrieb zu gewährleisten. Gängige Flascheninspektionsmaschinen haben dabei einen Durchsatz von 60.000 Flaschen pro Stunde. Um diesen zu erreichen, erfolgt eine Teilung des Flaschenstromes. Dies führt dazu, dass den Inspektoren zur vollständigen Überprüfung eines Kastens ca. eine Sekunde zur Verfügung steht.

Die Kästen können vor der Reinigungsmaschine in trockenem oder hinter dem Maschinenauslauf in benetztem Zustand geprüft werden. Vor der Reinigungsmaschine weisen die Kästen einen unterschiedlichen Verschmutzungsgrad auf. Außerdem schwankt die Materialtemperatur je nach Lagerort zwischen  $-20^{\circ}\text{C}$  und  $+60^{\circ}\text{C}$ , was einen erheblichen Einfluss auf die Materialeigenschaften hat. Nach der Kastenreinigungsmaschine ist mit homogenen Bedingungen zu rechnen. Nachteil ist hierbei der Transport defekter Kästen durch die Waschmaschine bis zum Inspektor.

Der Kastentransport erfolgt entweder im Längs- oder Querlauf, wobei im Querlauf bei gleicher Fördergeschwindigkeit ein höherer Durchsatz erzielt wird. Die Beförderung der Kästen

findet hierbei aufrecht stehend oder im Bereich der Kastenreinigungsmaschine auch Kopf stehend statt.

Für den eigentlichen Selektionsvorgang muss der zu prüfende Kasten fixiert werden. Dies bedeutet, dass förder technisch eine Abkopplung vom nachfolgenden Strom erfolgen muss. Hierzu ist der Kastenstrom mit einer mechanischen Stoppeinrichtung auszustatten, für die in der Umgebung des Kasteninspektors ausreichend Stellplatz vorhanden ist. Wie oben bereits erläutert, soll der eigentliche Selektionsvorgang pro Kasten nicht länger als eine Sekunde dauern.

Nach dem Selektionsvorgang erfolgt abschließend die automatische Entnahme der als defekt eingestuften Kästen mit Hilfe eines Kastenpushers. Dieser schiebt die entsprechenden Exemplare auf eine parallel geführte Pufferstrecke. Von dort erfolgt dann die Zuführung zur entsprechenden Entsorgungseinrichtung.

### **1.3 Forschungsziel**

Diese Arbeit hat die Entwicklung der Grundlagen für eine praxistaugliche Realisierung eines automatischen Selektionssystems für Getränkekästen, basierend auf der schnellen und zuverlässigen Beurteilung von mechanischen Schwingungssignalen, zum Ziel.

### **1.4 Lösungsweg zur Erreichung des Forschungsziels**

Aus dem Forschungsziel lassen sich folgende Hauptaufgaben ableiten:

#### **Schadenserkennung an Getränkekästen mittels Schwingungsanalyse**

Die Basis hierzu bildet die Forschungsarbeit von Zacharias et. al. [35-37], welche zeigt, dass es die mechanische Schwingungsanalyse, kombiniert mit einem auf Neuronumerik basierenden Auswertungs- und Selektionsverfahren, ermöglicht, Schäden an Getränkekästen zu detektieren. Dies beinhaltet auch das Erkennen von versprödetem Kunststoff und Fremdfabrikaten. Unter Laborbedingungen erreichte diese Methode eine Erkennungsrate von 99 %.

Als nachteilig erweist sich die relativ lange Dauer eines Prüfungszyklus von ca. 10 Sekunden und die konstruktive Umsetzung, was den praktischen Einsatz in Getränkebetrieben unmöglich macht.



In der vorliegenden Arbeit werden die Taktzyklen des Erkennungsverfahrens durch eine Modifizierung des Schwingungsanalyseverfahrens auf ein gefordertes Mindestmaß von maximal einer Sekunde (industrielle Anforderung an einen Prototyp, siehe Kapitel 1.2.3) reduziert. Anstatt lang andauernder Sinus-Sweep-Signale kommen hierbei Schockanregungssignale zum Einsatz [38, 39].

### **Datenvorverarbeitung und Parametrierung der Mustererkennung**

Die gemessene Schwingungsantwort der Getränkekästen liegt nach dem in der vorliegenden Arbeit verwendeten Prüfvorgang als Beschleunigungsverlauf vor. Anschließend erfolgt die Extraktion und Auswertung der Information über den Zustand des jeweiligen Prüflings.

Die Multivariate Datenanalyse der Rohdaten zeigt auf, welche Vorverarbeitungs- und Verdichtungsschritte bzw. welche Umformungen notwendig sind [40-42]. Die daraus erzeugten, veredelten Daten bilden die Basis für eine Mustererkennung mit Künstlichen Neuronalen Netzen, mit deren Hilfe schließlich eine Aussage über den Zustand der Kästen gemacht werden kann [43-46].

Die Anwendung der Multivariaten Datenanalyse vereint mit einem Neuronalen Netz führt zu einem neuartigen Hybriden, dessen Anwendung in der vorliegenden Arbeit sehr gute Ergebnisse lieferte. Die Bezeichnung Neurostatistik beschreibt diese Zusammenführung der beiden Methoden. Dabei werden die Vorteile der beiden Methoden gebündelt, um daraus ein leistungsfähigeres Verfahren zu entwickeln und somit bessere Resultate zu erzielen.

### **Integrationsfähigkeit des Laborsystems in bestehende Flaschenabfüllanlagen**

Eine weitere Hauptaufgabe dieser Arbeit bildet die Betrachtung der Randbedingungen einer Integrationsfähigkeit in bestehende Flaschenabfüllanlagen. Besondere Berücksichtigung findet dabei die Anpassung auf praxisnahen Durchsatz und die gegebene Schadensverteilung.

Bei einer Ausbringung einer Flaschenabfüllanlage von 60.000 Flaschen/h und einer Anzahl von 20 Flaschen pro Kasten erfordert eine industrielle Applikation dieser Erkennungsmethode einen Prüfungszyklus von etwa einer Sekunde. Der konstruktive Aufbau sowie die Datenerfassung und -auswertung müssen diesen Vorgaben Rechnung tragen, um industriellen Maßstäben gerecht zu werden.

Im Zuge dieser Überlegungen stellen sich folgende Fragen:

- An welcher Stelle regt man, in Abhängigkeit von Fixierung und Messsignalerfassungspunkt, den Getränkekasten an?
- Auf welche Art muss die Anregung des Kastens erfolgen, damit alle Schäden erkannt werden können?
- An welcher Stelle liegt die beste Position für die Signalerfassung?

Das Zusammenspiel der Bereiche Fixierung, Anregung und Signalerfassung wirft eine sehr komplexe Thematik auf. Eine Untersuchung dieses Problems lässt sich wegen der hohen Anzahl an möglichen Kombinationen nur mit Hilfe von numerischen Computersimulationen bewältigen, damit der finanzielle wie auch zeitliche Aufwand in einem vertretbaren Rahmen bleibt. Hierbei kommt das Finite Elemente Verfahren zum Einsatz [47-49].

Entsprechend dieser Aufgabenstellung mit den zahlreichen Unterzielen gliedert sich die vorliegende Arbeit folgendermaßen:

Kapitel zwei umfasst den Themenkomplex Material und Methoden. Neben der Beschreibung der eingesetzten Getränkekästen behandelt dieser Teil auch die eingesetzten Methoden zur Schwingungsanalyse, zur numerischen Simulation sowie die Verfahren zur Informationsextraktion bis hin zur endgültigen Klassifizierung der Getränkekästen. Ein Exkurs in die Materie der Schwingungsanalyse zeigt auf, welche Methoden derzeit für die Schadenserkennung eingesetzt werden. Theoretische Grundlagen zur Schwingungsanalyse, zur Finiten Elemente Methode sowie zu Künstlichen Neuronalen Netzen befinden sich bei der jeweiligen Methodenbeschreibung. Das Kapitel drei befasst sich eingehend mit dem konstruktiven Aufbau der Versuchsanlagen sowie der softwareseitigen Realisierung der Rohdatenverarbeitung. Außerdem wird ein kurzer Einblick in das Steuerungskonzept der Anlagen gegeben. Den Abschluss der Arbeit bildet die Präsentation und Diskussion der erarbeiteten Ergebnisse in Kapitel vier. Besonderes Augenmerk wird in diesem Kapitel auf die Realisierbarkeit in der Praxis sowie die zu erreichenden Erkennungsraten gelegt. Bemerkenswert ist hierbei v. a. die Verbesserung der Erkennungsrate aufgrund verbesserter Datenvorverarbeitung. Ein Ausblick auf zukünftige Entwicklungen rundet die vorliegende Arbeit ab.

Einen generellen Überblick dazu gibt folgende Illustration:

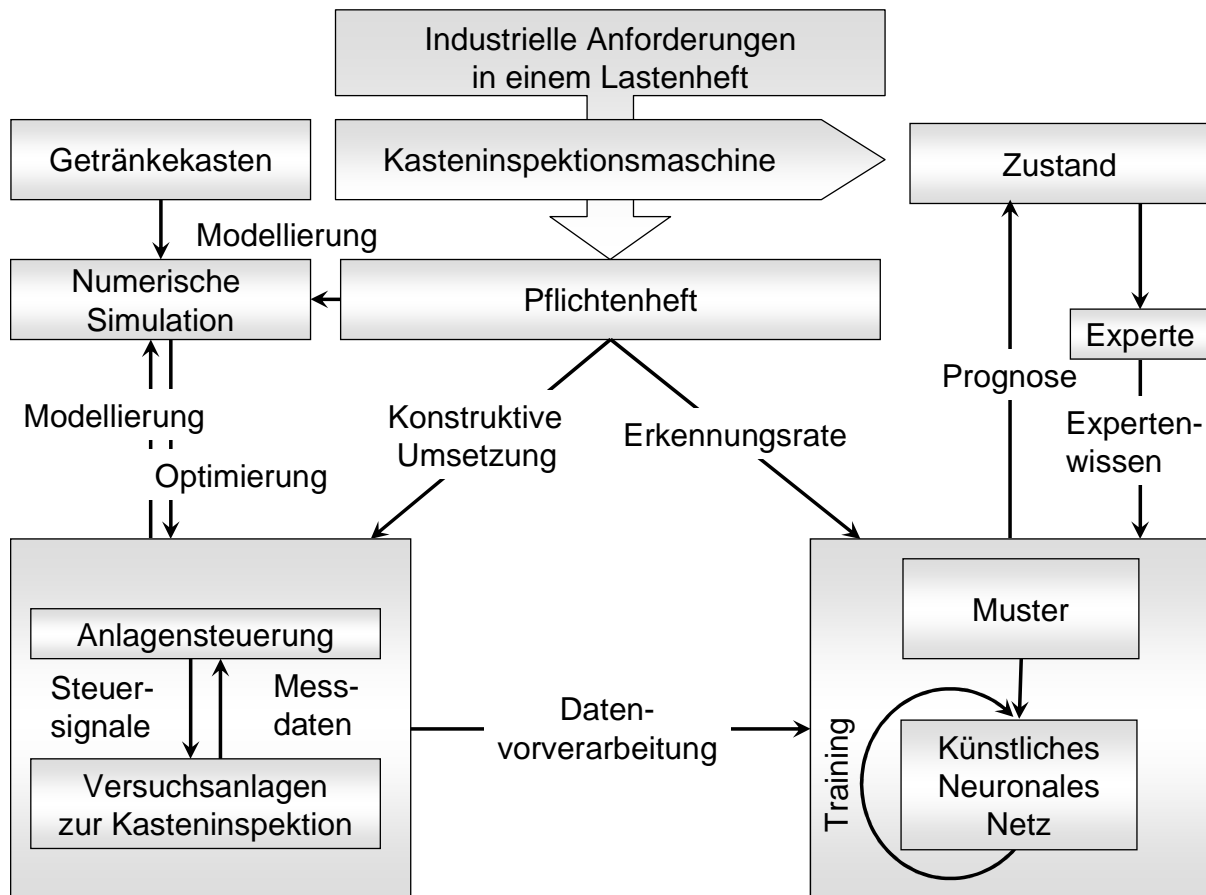


Abbildung 1-3: Schema des Arbeitslaufs und der eingesetzten Methoden

## 2 Material und Methoden

In diesem Abschnitt folgt nach einer Beschreibung der Untersuchungsobjekte ein Abriss über die zur Anwendung kommenden Methoden der Schwingungsanalyse, der Simulation mittels Finiter Elemente Methode sowie die eingehende Erläuterung der Datenvorverarbeitungs- und Auswertungsverfahren.

### 2.1 Getränkekästen

Von Interesse ist der allgemeine Zustand von Mehrwegkästen der Getränkeindustrie. Dabei interessiert neben der mechanischen Stabilität auch das optische Erscheinungsbild. Diese Getränkekästen haben die Hauptaufgabe, die darin enthaltenen Getränkeflaschen beim Transport vom Ort der Herstellung über den Einzelhandel bis hin zum Endkunden vor äußeren, negativen Einflüssen zu schützen. Stellvertretend für die im Mehrwegkreislauf auftretende Vielfalt an Getränkekästen kommen bei diesen Untersuchungen zwei handelsübliche Modelle (siehe Abbildung 2-1) zum Einsatz. Die Methoden werden dabei immer auf eine allgemeine Anwendbarkeit bzw. Übertragbarkeit auf andere Kastenmodelle geprüft.




Abbildung 2-1: Untersuchte Getränkekastenmodelle

Um bei den betrachteten numerischen Simulationen das reale Verhalten des Prüflings nachstellen zu können, ist neben der exakten geometrischen Beschreibung in Form von CAD-Daten die exakte Spezifizierung der physikalischen Eigenschaften von großer Bedeutung. Hierbei wurden die Spezifikationstabellen der behandelten Modelle von den Herstellern herangezogen. Tabelle 2-1 listet die wichtigsten Kennwerte der verwendeten Modelle auf. Für die Simulation besonders relevant sind Elastizitätsmodul, Poisson-Zahl und Dichte.

Tabelle 2-1: Materialkenndaten der verwendeten Getränkekästen

Kastenmodell	WKG1A 12 x 0,7 l	Amstel 24 x 0,33 l
Maße (l x b x h) [mm]	356 x 275 x 347	398 x 298 x 237
Gewicht [kg]	1,4	1,9
Material	HD-PE (High Density Poly-Ethylen)	
Dichte [ $\text{kgm}^{-3}$ ]	963	
Herstellungsmethode	Spritzgussverfahren	
Fertigungstoleranz [%]	<1	
E-Modul [GPa]	1,5	
Streckspannung [MPa]	30	
Streckdehnung [%]	10	
Nominelle Bruchdehnung [%]	>50	
Zug-Kriechmodul (1h) [GPa]	900	
Querkontraktion (Poisson-Zahl) [-]	0,419	

Die Zusammensetzung der eingesetzten Versuchskastenpools erfolgt wegen der besseren Übersichtlichkeit im Kapitel vier.

## 2.2 Schwingungsanalyse zur Strukturanalyse von Festkörpern

### 2.2.1 Grundlagen

In einer Schwingungsanalyse versetzt man einen Prüfling, z. B. eine Lebensmittelverpackung, durch ein Schwingerregersystem (z. B. einem Impulshammer) in eine definierte und im Rahmen der Fehlerschranken reproduzierbare mechanische Schwingung. Das Antwortverhalten des Prüfobjektes (unter Einwirkung aufgezwungener Belastungen) dient in der anschließenden Analyse als Kriterium zur Einstufung des Objektzustandes, da sich Schäden am Prüfling in Form von Materialdefekten wie Rissen oder Brüchen, aber auch Materialalterung, z. B. Versprödung von Kunststoffen, auf das Antwortverhalten auswirken. Anhand dieser Informationen ist es möglich, den Zustand des Prüflings genauer zu charakterisieren und bei Bedarf eine Selektion vorzunehmen. Zur Anregung des Testgegenstandes benutzt man häufig folgende Erregungsarten:

#### **Sinusförmige Anregung**

Eines der meist verwendeten Signale zur Anregung ist die Sinusschwingung. Bei der Prüfung mit einer Festfrequenz wirkt eine sinusförmige Beschleunigung mit einer Amplitude  $A$  über eine Zeitdauer  $t$  mit einer konstanten Frequenz  $f$  auf den Prüfling ein. Wenn es sich bei der gewählten Frequenz um eine Resonanzfrequenz des Prüflings handelt, kann eine intensive Schwingungsantwort die Folge sein. Wenn die Eigenfrequenzen nicht von vornherein bekannt sind, benutzt man die Gleitsinusprüfung. Bei dieser Prüfung wird die Anregungsfrequenz stetig zwischen den beiden Grenzen  $f_a$  und  $f_b$  verändert. Die Änderung der Frequenzen kann hierbei linear (Anzahl der Lastwechsel steigt mit der Frequenz) oder logarithmisch (Anzahl der Lastwechsel ist für jeden Frequenzschritt gleich) erfolgen.

#### **Schockanregung, Stoßanregung**

Bei diesem Verfahren (auch als Schock bezeichnet) regt man den Prüfling mit kurzen Beschleunigungsstößen an. Durch das gleichmäßig verteilte Frequenzspektrum des Schocksignals werden theoretisch alle Eigenschwingungen im Prüfling angeregt. Im praktischen Einsatz lässt sich der Schock nur näherungsweise über folgende Signalformen erzeugen:

- Halbsinus-Schock
- Sägezahn-Schock
- Dreieck-Schock
- Trapez-Schock
- Rechteck-Schock

Damit sind die Maximalwerte der Anregungsbeschleunigung und das in der Anregung enthaltene Frequenzspektrum festgelegt. Die Schockanregung hat den großen Vorteil, dass die Anregung durch einen Impulshammer und die Aufnahme des Antwortspektrums, im Gegensatz zur Sinusprüfung bei endlicher Frequenz, relativ wenig Zeit benötigt. Sie erfüllt somit die Voraussetzung für die Integration in einen kontinuierlichen Prozess. Alle zur eindeutigen Kennzeichnung des Prüfverfahrens notwendigen Angaben werden in den Prüfbedingungen festgelegt. Sie lassen sich in folgende Gruppen einteilen:

- Prüfschärfeangaben
- Angaben der Prüfdauer
- Spezifische Angaben zur Prüfanregung
- Reproduzierbarkeitsbedingungen

Für zahlreiche Verfahren der Schwingungsanalyse sind die Prüfbedingungen in DIN-Normen festgelegt. Hierbei handelt es sich häufig um so genannte Umweltpfprüfverfahren, die einen Prüfling, z. B. ein Motorbauteil, auf seine Einsatzfähigkeit in einer realen Umgebung hin untersuchen. Diese Verfahren werden häufig bei der Planung und Konstruktion von Bauteilen eingesetzt. Die Entwickler wollen hierbei mit Hilfe von Prototypen sicher gehen, dass das zu entwickelnde Bauteil den Belastungen auf der Feldebene standhält, bevor es in die Serienproduktion gelangt.

Die europäische Norm 60068-2-6 für Umweltpfprüfungen definiert den Anwendungsbereich für diese Prüfvorschrift wie folgt:

„Die Prüfung dient dazu, mechanische Schwachstellen aufzuzeigen und/oder eine Verschlechterung der vorgegebenen Kennwerte von Prüflingen zu ermitteln. Diese Informationen werden in Verbindung mit den Einzelbestimmungen als Kriterium dafür verwendet, ob der Prüfling den geforderten Bedingungen genügt. In einigen Fällen kann diese Prüfung außerdem zur Demonstration der mechanischen Widerstandsfähigkeit der Prüflinge und/oder zur Beobachtung des dynamischen Verhaltens der Prüflinge angewendet werden.“

## 2.2.2 Anwendung der Schwingungsanalyse – Stand der Forschung

Die Schadenserkennung an Bauteilen, Gebäuden, Maschinen etc. ist für den reibungslosen Betrieb bzw. Einsatz dieser Objekte von herausragender Bedeutung (siehe z.B. [50-54]). Zu spät erkannte Schäden haben meist negative Konsequenzen und führen neben erhöhtem finanziellem Aufwand oft auch zu Schäden an Personen. Die traditionelle Art Schäden zu erkennen, geschieht mit Hilfe von optischen Erkennungsmethoden [55]. Es ist aber unmöglich, Schäden, wie z.B. Brüche im Inneren eines Materials oder Materialverbundes mit diesen Methoden zu detektieren. Als Alternativen dazu wurden Methoden auf akustischer oder Röntgenbasis oder mit Hilfe von magnetischen Feldern entwickelt, um unsichtbare Defekte zu erfassen (siehe z.B. [56-60]). Nachteil dabei ist, dass aktiv nach Schäden gesucht und dazu das Bauteil aus seiner ursprünglichen Funktion entnommen werden muss, um für die Messtechnik zugänglich zu sein. Eine dauerhafte „On-Line“-Überwachung ist damit schwer realisierbar. Die Schwingungsanalyse ist eine alternative Methode zur Schadenserkennung in diesen Bereichen, die ihre Ursprünge in der Raumfahrt und im Maschinenbau hat und in den vergangenen 25 Jahren durch intensive Forschungsarbeit stark an Bedeutung gewann. Zahlreiche Veröffentlichungen, Konferenzen und Arbeitskreise belegen dies [61-67]. Umfangreiche Literaturstudien auf diesem Gebiet von Doebling et. al. [68, 69] zeigen, welche Methoden zur Überwachung und Detektion des Schwingungsverhaltens von Strukturen existieren. Die Überwachung bezieht sich dabei auf Änderungen in den Eigenfrequenzen und den Eigenformen sowie Änderungen der Materialparameter Steifigkeit, Masse, Dämpfung sowie nichtlineares Verhalten aufgrund struktureller Veränderungen. Da Beschädigungen in der Struktur eines Körpers seine Steifigkeit vermindern und somit das Schwingungsverhalten verändern, ist es durch die Überwachung der Schwingungscharakteristik eines Körpers möglich, auf dessen Zustand zu schließen [70-72]. Prinzipiell existieren hierbei vier Kategorien der Schadenserkennung [73]:

### **Structural Health Monitoring (SHM) [73-75]**

verwendet man vor allem für Gebäude und Flugzeuge und setzt ein Sensornetzwerk zur Überwachung voraus. Dabei kommen z.B. Dehnmessstreifen, akustische und andere auf Schwingungen basierende Verfahren zum Einsatz.



**Condition Monitoring (CM) [76]**

findet vor allem in der Industrie zur Überwachung von rotierenden Maschinen und Kolbenmotoren Verwendung. Dieses Verfahren ist onlinefähig und arbeitet z.B. mit Bewegungsinformationen von Beschleunigungssensoren.

**Non-Destructive Evaluation (NDE) [77]**

stellt ein Offline-Verfahren zur Untersuchung von aufgetretenen Schäden, z. B. an Druckventilen oder Schienen dar. Dabei kommen Ultraschall-, Thermographie- oder Shearographieverfahren zum Einsatz.

**Statistical Process Control (SPC) [78]**

benutzt als sehr stark prozessabhängiges Verfahren eine Vielzahl an Sensoren zur Überwachung eines Prozesses.

Laut Rytter [79] gibt es vier Stufen der Schadenserkenkung. Die benötigten Informationen über den Prozess bzw. Schaden steigen dabei von der ersten zur vierten Stufe an.

**Stufe 1: Schadensdetektion (Damage detection)**

In dieser Stufe wird nur die Frage nach einem vorliegenden Schaden behandelt, was für viele praktische Anwendungen ausreichend ist. Die Forschung beschäftigt sich derzeit damit, möglichst kleine auftretende Schäden und deren Ausbreitung in einem Frühstadium zu erkennen.

**Stufe 2: Schadenslokalisierung (Damage localisation)**

Nicht nur die bloße Anwesenheit eines Schadens sondern auch die Lage wird in dieser Stufe untersucht.

**Stufe 3: Schadensquantifizierung (Damage quantification)**

Neben der Anwesenheit und der Lage des Schadens erfolgt in dieser Stufe eine Quantifizierung der Schadensart und des Umfangs.

**Stufe 4: Schadensvorhersage (Damage prediction)**

Sind Art, Lage und Umfang des Schadens quantifiziert, erfolgt in Stufe vier eine Abschätzung der Auswirkungen des Schadens auf das Bauteil bzw. den Prozess. Dabei interessiert den Anwender, wie lange das Bauteil noch eingesetzt werden kann und ab wann eine Gefährdung

für die Umgebung oder den Prozess eintritt bzw. wann das betreffende Bauteil erneuert werden muss.

Die Informationen, die zur Beurteilung des Zustandes bzw. zur vierstufigen Schadenserken- nung notwendig sind, stellen diverse Mess- und Prüfinstrumente sowie daran anknüpfende Datenauswerteverfahren bereit. Für die schwingungsbasierende Schadenserken- nung spielen v. a. Bewegungsinformationen des Untersuchungsobjektes aufgrund einer definierten Anregung, aber auch aufgrund stochastischer Anregung bzw. der Arbeitsbewegung des Bauteils im Pro- zess, z.B. Drehung einer Welle am Motor, die entscheidende Rolle. Dies geschieht mit Hilfe von Bewegungssensoren, die ein zeitaufgelöstes Geschwindigkeits- bzw. Beschleunigungs- signal vom untersuchten Objekt bereitstellen. Die Auswertung erfolgt anschließend direkt mit dem Beschleunigungssignal oder mit Verfahren auf Basis der transformierten Frequenzspek- tren. Einen Überblick über die gängigsten Verfahren geben Humar et. al. [80] und Fritzen [81].

Im Bereich der Lebensmitteltechnologie, und hier im speziellen im Verpackungsbereich, sind diese Methoden noch weitgehend ungenutzt. So beschreiben Benedito et. al. [82] die Überprü- fung der Textur und des Reifegrades von Käse. Hiromichi et. al. benutzen die Schwingungs- analyse zur Kontrolle der Textur von Obst wie z.B. Äpfel oder Wassermelonen [83-85]. Frühere Forschungsprojekte aus dem Verpackungsbereich befassten sich mit der Schadenser- kennung an Transportpaletten [86, 87] oder an Weithalsbehältern aus Glas, die mittels eines Wasserstrahls angeregt wurden [88].

Des Weiteren zeigen Zacharias et. al. [36, 37], dass es prinzipiell möglich ist, Schäden an Getränkekästen mittels der Schwingungsanalyse zu detektieren. Er setzte hierzu ein neuronu- merisches Hybrid ein, das die Vorteile der Finiten Elemente Simulation, der Mustererkennung mit Künstlichen Neuronalen Netzen sowie der experimentellen Schwingungsanalyse vereint und erreichte damit sehr gute Ergebnisse. Neuronumerische Hybride wurden am Lehrstuhl für Fluidmechanik und Prozessautomation erstmalig entwickelt und z. B. von Benning et. al. zur Vorhersage von Strömungsfeldern erfolgreich eingesetzt [89-91].

Werden ausschließlich rein numerische Daten zur Konditionierung des KNN eingesetzt, ist eine exakte Modellierung des Schwingprüfsystems notwendig, um annähernd reale Schwingantwortspektren der simulierten Getränkekästen zu erhalten [92]. Da sich aber so- wohl der Aufbau des Systems, die Störungen aus der Umgebung und die große Anzahl an spezifischen Beschädigungen die Modellierung sehr komplex gestalten, ist es in vielen Fällen

einfacher, experimentell gewonnene Daten zur Konditionierung der KNN zu verwenden.

Dabei spielt das Schwingverhalten des untersuchten Objektes eine große Rolle bezüglich der auftretenden Eigenfrequenzen bzw. Schwingamplituden. Das eingesetzte Messsystem muss dabei in der Lage sein, das komplette Schwingenspektrum des Systems zu erfassen. Da hierbei im Allgemeinen eine große Menge an Daten anfallen, ist auch die anschließende Datenauswertung bzw. die vorhergehende Aufbereitung des Datenmaterials Gegenstand zahlreicher Forschungsprojekte und Publikationen. Das Komprimieren der Daten oder die Feature-Extraktion, also die Extraktion von besonderen Merkmalen, wie z.B. die Eigenfrequenzen aus den Frequenzspektren [93-97] oder eine Hauptkomponentenanalyse [98-103], kommen hierbei häufig zum Einsatz. Die Weiterverarbeitung der vorverarbeiteten Daten geschieht mit Hilfe von klassischen Algorithmen [104-107], aber auch Ansätze aus dem Bereich des Maschinennlernens und der künstlichen Intelligenz finden immer häufiger Anwendung [108-116].

### **2.3 Modellerstellung und numerische Simulation**

Die Untersuchung des Schwingverhaltens an Getränkekästen erfolgt zunächst an einem Labormessstand und danach an einer industrietauglichen Applikation. Diese bestehen grundsätzlich aus einer mechanischen Vorrichtung zur Fixierung, einer Schwingerregeranlage zur Anregung und der Hard- und Software für die Datenerfassung zur Aufnahme der Schwingungsantwort. Die Zahl der verfügbaren Sensoren bestimmt dabei die maximale Anzahl an zu beobachtenden Messpunkten. Will man Vergleiche einzelner Messpunkte anstellen oder Variationen an Fixierung, Anregung oder Zustand der Prüflinge untersuchen, bedeutet dies einen erheblichen konstruktiven, zeitlichen und nicht zuletzt finanziellen Aufwand.

Eine andere Möglichkeit zur Analyse dynamischer Systeme bietet die Computersimulation. Dabei wird das System Getränkekasten mit allen relevanten Randbedingungen in einem diskreten, deskriptiven Simulationsmodell abstrahiert. Mit Hilfe der Finiten Elemente Methode und der numerischen Mathematik lässt sich das dynamische Verhalten eines Getränkekastens modellieren und die Reaktion auf erzwungene Schwingungen berechnen. Bei der Idealisierung bildet man, um den Rechenaufwand gering zu halten, nur diejenigen Merkmale ab, die für die Lösung des vorliegenden Problems von Bedeutung sind. Eine zu starke Verallgemeinerung bzw. Vereinfachung des Modells hat dabei zur Folge, dass die Ergebnisse das reale System nur ungenügend wiedergeben. Auch die in der numerischen Mathematik auftretenden Diskretisierungsfehler sowie unvermeidbare Rundungsfehler durch den Einsatz von Computern führen zu Abweichungen. Eine schrittweise erfolgende Approximation der Simulation an

die Realität durch Modifikation der Modellparameter ist daher meist unumgänglich. In Abbildung 2-2 ist der Ablauf der Modellerstellung schematisch dargestellt.

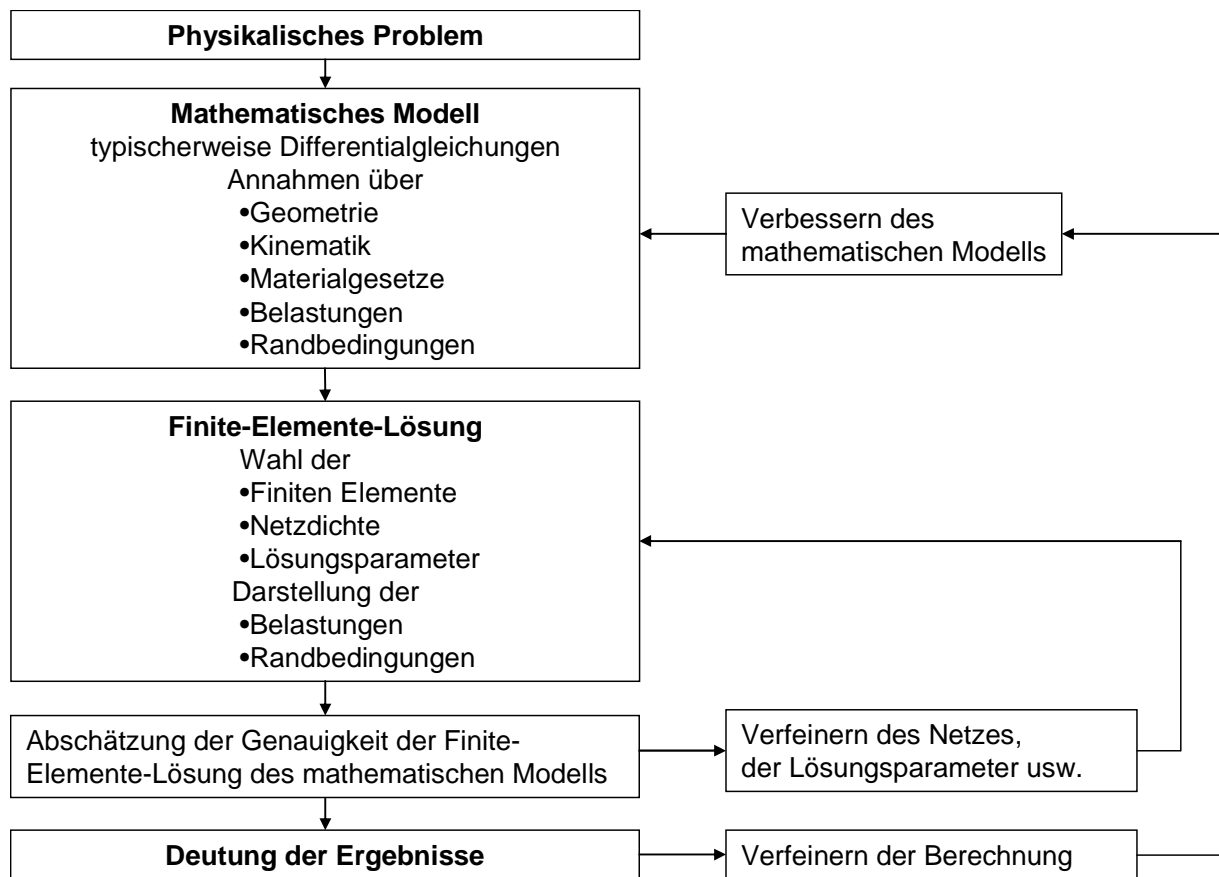


Abbildung 2-2: Der Simulationsprozess

### 2.3.1 Numerische Simulation mit Finiter Elemente Methode (FEM)

Eine ohnehin nicht erreichbare Vollständigkeit in der Darstellung des Wissens auf dem Gebiet der FEM wird hier nicht angestrebt, vielmehr sei hier auf Übersichtsarbeiten und einschlägige Literatur verwiesen [47-49, 96, 117-125].

Die Finite-Elemente-Methode stellt ein Verfahren zur näherungsweise Lösung von gleichungsbasierten Modellen dar. Sie basiert auf der Idealisierung der reellen physikalischen Gegebenheiten in einem Modell. Üblicherweise wird hier auf die von den Herstellern zur Produktion eingesetzten CAD-Dateien (Computer-Aided-Design) zurückgegriffen (vgl. Abbildung 2-3). Diese enthalten meist ein aus einzelnen Flächen zusammengesetztes Volumenmodell, das sich durch seine exakte Beschreibung der Geometrie für den Einsatz in Computersimulationen optimal eignet. Die Verwendung universeller Datenformate, wie z. B. die "Initial Graphics Exchange Specification" (IGES), vereinfachen den plattformübergreifenden

Austausch und die Verwendung in unterschiedlichen Simulationsapplikationen und tragen zur Vermeidung von Idealisierungsfehlern bei. Somit führen sie zu einer hohen initialen Modellgenauigkeit.




Abbildung 2-3: CAD-Getränkekastenmodelle

Die kontinuierliche Struktur wird bei der FEM durch die Unterteilung in eine endliche Anzahl kleiner, finiter Unterelemente diskretisiert. Je nach Problemstellung und Geometrie kommen hierbei ganz unterschiedliche Elementtypen zum Einsatz. Grundsätzlich benutzt man für dünnwandige Bauteile Scheibenelemente wie z. B. Scheiben, Platten, Schalen. Für dickwandige Bauteile werden Volumenelemente wie z.B. Tetraeder verwendet. Die Elemente sind durch die Knotenpunkte, die auf den Rändern des Elementes liegen, definiert. Je exakter eine Berechnung erfolgt, d. h. je genauer ein Modell die reale Struktur beschreiben soll, desto kleinere Elemente und umso mehr Knotenpunkte kommen zum Einsatz. In der Regel sind Bereiche, in denen erwartungsgemäß große Spannungen und Verzerrungen auftreten, mit einem feineren Elementnetz unterteilt als Gebiete, in denen man wenige Reaktionen erwartet.

Der Kraft- und Momentenfluss von Element zu Element erfolgt in den diskreten Knotenpunkten. Verschiebungen der Knoten werden als Unbekannte eingeführt. Dabei stellen Formfunktionsansätze der unbekanntenen Knotenverschiebungen den Verschiebungszustand innerhalb

eines Elementes dar. Diese Verschiebungsansätze sind kompatibel zu den angrenzenden Nachbarelementen. Das Verschiebungsfeld gibt innerhalb eines Elementes auch Verzerrungszustand und - über das Stoffgesetz - Spannungszustand als Funktion der Knotenpunktverschiebungen an. Über ein Variationsprinzip (Prinzip der virtuellen Arbeit) oder die Methode der gewichteten Residuen (Methode von Galerkin) werden den entlang der Elementränder übertragenen Spannungen statisch gleichwertige, resultierende Knotenpunktkräfte zugeordnet. Man geht davon aus, dass die verwendeten Gleichungen für jedes Element lösbar sind und somit eine Lösung für das Gesamtsystem existiert. Bei der Berechnung des Verhaltens einer linear elastischen Struktur legt man hierbei folgende Eigenschaften fest:

- Elastisches Verhalten (nach Entfernen 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

Weitere wichtige Aspekte bei der Modellerstellung sind die Definition der Materialeigenschaften, der wirkenden Lasten und die Festlegung der geometrischen Randbedingungen.

Zur Durchführung der Computersimulationen auf Basis der Finite-Elemente-Methode kommt in der vorliegenden Arbeit das kommerzielle Softwarepaket Nastran/Patran der McNeal-Schwendler Kooperation zum Einsatz. Das mit einer graphischen Benutzeroberfläche ausgestattete Pre- und Postprozessor-Programm Patran unterstützt den Anwender bei der Modellerstellung sowie der Eingabe aller relevanten Parameter. Es bietet die Möglichkeit, CAD-Dateien zu importieren oder mit Hilfe bereitgestellter Werkzeuge zu erstellen. Der integrierte Netzgenerator unterstützt den Anwender bei der Diskretisierung der Geometrie in Finite Elemente und der Erstellung eines Knotennetzes. In der vorliegenden Arbeit wurden die in Abbildung 2-4 dargestellten Tetraederelemente verwendet. Diese verursachen, im Gegensatz zu einfachen Quaderelementen, zwar einen erheblich größeren Rechenaufwand, haben aber den Vorteil einer exakteren Modellerstellung. Die Besetzung der Kanten mit einem zusätzlichen Knoten erhöht die Berechnungsgenauigkeit und ermöglicht des Weiteren eine innere Verformung der einzelnen Elemente. Die Wechselwirkungen eines Elementes mit den Nachbarelementen, die nur über die Knotenpunkte stattfinden, sind damit differenzierter darstellbar.




Abbildung 2-4: Tetraeder-Element zur Diskretisierung der kontinuierlichen Struktur

Tabelle 2-2 listet die Einzelheiten der Diskretisierung des verwendeten Getränkekastens auf. Der Rechenaufwand nimmt mit der Anzahl der Knotenpunkte stark zu, hängt aber auch vom gewählten Berechnungsverfahren ab. Die prinzipiellen Bewegungsabläufe können durch die Eigenfrequenzen und die Eigenformen mit der Modalanalyse hinreichend genau ausgedrückt werden. Dadurch lässt sich gerade bei komplexen Modellen mit vielen Knotenpunkten erheblich Rechenzeit einsparen.

Tabelle 2-2: Spezifikation der Finite-Elemente-Modelle

Kastenbezeichnung	GDB 1A 12 x 0,7 l	Amstel 24 x 0,33 l
Art der verwendeten Elemente	TET10 (Tetraeder)	
Anzahl Knotenpunkte pro Element	10	
Anzahl der Knotenpunkte (gesamt)	244.269	751.729
Anzahl der Elemente (gesamt)	121.912	377.453
Mittlere Kantenlänge [mm]	10	4

### 2.3.2 Numerische Strukturanalyse unter Verwendung der FEM

Der eingesetzte FEM-Solver MSC.Nastran erlaubt es, auf drei verschiedene Arten dynamische Analysen von Strukturen durchzuführen [126]:

- Real-Eigenvalue-Analysis
- Linear-Frequency-Response-Analysis
- Linear-Transient-Response-Analysis

Die "Real-Eigenvalue-Analysis" findet vor allem bei der Charakterisierung einer Struktur Anwendung. Sie basiert nicht auf einer von außen einwirkenden Kraft, sondern definiert die Frequenzen und die dazugehörigen Moden, mit denen die Struktur, bedingt durch ihre Eigenschaften wie Material, Form etc., schwingt [127].

Die "Frequency-Response-Analysis" stellt eine effiziente Methode, um das Antwortverhalten einer Struktur auf harmonische Anregungssignale zu untersuchen, dar. Die Anregungskraft wird hierbei als eine Funktion der Frequenz mit definierter Amplitude und Phasenverschiebung angegeben.

Das Ziel der "Transient-Response-Analysis" ist die Berechnung des Strukturverhaltens eines Körpers, der einer dynamischen Anregung unterliegt. Alle Belastungen, die auf die Struktur im beobachteten Zeitraum einwirken, müssen bekannt und als zeitveränderliche Größen stetig definiert sein. Es handelt sich hierbei meist um von außen wirkende Kräfte oder um erzwungene Bewegungen. Die berechneten Ergebnisse einer solchen Analyse sind typischerweise Verschiebungen, Geschwindigkeiten und Beschleunigungen von Knotenpunkten und Kräfte bzw. Spannungen in den einzelnen Elementen.

Abhängig von der Struktur und den einwirkenden äußeren Belastungen existieren verschiedene numerische Methoden der "Transient-Response-Analyse". Die aufwändigere und auch exaktere Methode führt eine numerische Integration über alle direkt miteinander gekoppelten Bewegungsgleichungen durch. Die numerischen Differenzialgleichungslöser, welche im Solverprogramm integriert sind, lösen das FEM-Gleichungssystem entweder auf direktem Weg (z.B. Choleski-Verfahren, Gaußverfahren) oder bei größeren Systemen auf iterativem Weg (z.B. Jakobi-Verfahren, Gauß-Seidl-Verfahren usw.). Zur Beschränkung der Rechenzeit ist es hier notwendig, die Netzstruktur zu modifizieren. Stellen, an denen hohe Spannungen auftreten oder Kräfte angreifen, müssen mit einem feineren Netzwerk diskretisiert werden, um eine exaktere Lösung zu erhalten. Im Kastenmodell betrifft dies beispielsweise den Boden. An unkritischen Stellen, wie den abgerundeten senkrechten Kanten des Kastens, erreicht man auch mit größeren Elementen eine ausreichende Genauigkeit. Eine Verkleinerung der Elemente brächte im Verhältnis zur Erhöhung des Rechenaufwandes keinen nennenswerten Informationsgewinn.

Die Modal Methode benutzt die Eigenfrequenzen der Struktur, um die Bewegungsgleichungen zu entkoppeln und zu reduzieren. Die Lösung erfolgt hierbei durch ein Summieren der einzelnen modalen Antworten. Sie stellt für aufwändige Berechnungen großer Modelle und die Betrachtung einer großen Anzahl von Zeitschritten wegen dem reduzierten Berechnungsaufwand die bessere Methode dar.



Abbildung 2-5 illustriert die verwendeten Kästen mit dem an der Oberfläche sichtbaren Elementnetz.




Abbildung 2-5: Finite-Elemente-Modell der Getränkekästen

### 2.3.3 Definition der Versuchsparameter

Um die Schwingungen der Getränkekästen realitätsnah simulieren zu können, müssen neben der Geometrie und den Materialparametern auch die einflussnehmenden Umgebungsbedingungen definiert werden. Das impulsartige Einwirken eines Stößels auf die Oberfläche des Prüflings regt diesen zum Schwingen an. Die Art der auslösenden Kraft bedingt die Art der Bewegungen der einzelnen Knotenpunkte während des Schwingvorganges. Veränderliche Parameter stellen dabei Angriffspunkt, Betrag bzw. zeitlicher Verlauf und Wirkungsrichtung des Kraftvektors dar.

Ebenso wirken sich die Fixierungsvorrichtung auf das Schwingverhalten des Kastens aus. Im experimentellen Aufbau müssen diese zum einen verhindern, dass der Kasten sich während der Messung der Schwingungssignale aus seiner Position bewegt, dürfen aber die Bewegungsfreiheit des Prüflings nicht zu sehr einschränken.

Neben den Umgebungsbedingungen stellt natürlich auch die Erfassung der Schwingungen der Getränkekästen eine Herausforderung dar. Während eine numerische Simulation theoretisch die Bewegungsinformation eines jeden Punktes des Modells zur Verfügung stellt, soll sich der Messaufwand im realen Versuchsaufbau so gering wie möglich gestalten. So ist es das Ziel, mit den Schwingungsinformationen aus nur einem Punkt auf der Oberfläche eine Klassifizierung vorzunehmen. Die Bestimmung der besten Messposition für die Datenaufnahme steht aus diesem Grund in diesen Untersuchungen ebenso im Fokus. Resultate und detaillierte Angaben zu den einzelnen Versuchsparametern finden sich im Abschnitt 4.1.

### **2.3.4 Simulation von Schadensfällen**

Zur Schadenserkenkung erfolgt ein Vergleich der Schwingungsantwort eines beschädigten Getränkekastens mit dem eines unbeschädigten Kastens. Eine Beschädigung bedeutet in diesem Fall geometrische Veränderungen an der Struktur des Prüflings, die zu einer Unbrauchbarkeit im Mehrwegkreislauf führen. Die Fehler in der Struktur lassen sich in der FE-Simulation durch das Herauslösen der betreffenden Volumenelemente aus dem Modell realisieren.

Tabelle 2-3 und Abbildung 2-6 bieten eine Übersicht über alle 26 simulierten Einzelschäden des Kastenmodells 1. Nachfolgend werden einige repräsentative Schäden detailliert beleuchtet. Die Wahl der Schäden berücksichtigt eine sinnvolle Kombinierbarkeit sowie einige Variationen der Schadensarten. So können Griffschäden mittig oder am Rand der Griffleisten auftreten. Brüche im Boden und Gefache wirken sich nahe der Anregungsfläche anders aus als am Rand. Aufgrund der durch den Schaden hervorgerufenen Asymmetrie ist auch die Position in Bezug auf den Messpunkt entscheidend, besonders bei Rissen in den kurzen Griffleisten.

Die für Messungen zur Verfügung stehenden Kästen weisen häufig mehrere Schäden gleichzeitig auf. Aus den Einzelschäden kann durch entsprechende Kombination eine nahezu beliebige Anzahl an Mehrfachschäden erzeugt werden. Das Gesamtkastenmodell liegt zu Beginn in einzelnen Teilen vor (Boden, Griffe, Seiten) die vor der Simulation zu einem Gesamtmodell zusammengesetzt werden. Von jedem Teil gibt es mehrere Versionen, die verschiedene Beschädigungsgrade aufweisen. Eine Kombination mit den verschiedenen Versionen aller anderen Kastenteile ermöglicht somit die Simulation einer großen Anzahl verschiedener Beschädigungsmodelle.

Tabelle 2-3: Liste der Einzelschäden

Nummer	Bezeichnung
01	Riss in der kurzen Griffleiste links Seite
02	Riss in der kurzen Griffleiste links Mitte
03	Riss in der langen Griffleiste vorne links
04	Riss in der langen Griffleiste vorne Mitte
05	Riss in der langen Griffleiste vorne rechts
06	Riss in der kurzen Griffleiste rechts Seite
07	Riss in der kurzen Griffleiste rechts Seite
08	Riss in der langen Griffleiste hinten links
09	Riss in der langen Griffleiste hinten rechts
10	Riss in der Ecke vorne links
11	Riss in der Ecke hinten rechts
12	Riss in der Seitenwand links / Rand
13	Riss in der Seitenwand vorne / Rand
14	Riss in der Seitenwand rechts / Mitte
15	Riss in der Seitenwand hinten / links bis Mitte
16	Fehlende Ecke
17	Fehlender Gefacheteil hinten Mitte
18	Fehlender Gefacheteil Mitte
19	Fehlender Gefacheteil vorne rechts
20	Bruch im Gefache hinten: fehlende Verbindung zum Boden
21	Fehlendes Bodensegment Mitte
22	Fehlendes Bodensegment rechts
23	Bruch im Boden links
24	Bruch im Boden Mitte
25	Bruch im Boden rechts
26	Fehlendes Bodensegment links vorne




Abbildung 2-6: Übersicht der simulierten Schäden

Die am häufigsten auftretende Beschädigung an Mehrweggetränkekästen ist laut einer Studie der GDB [2] ein Bruch in den kurzen Griffleisten. Vor allem Haarrisse, bei denen die gebrochenen Teile derart übereinander liegen, dass sie die Beschädigung optisch verdecken, führen bei den herkömmlichen Erkennungssystemen zu Detektionsproblemen. Erst unter Belastung, z. B. beim Tragen, tritt dieser Defekt in Erscheinung und führt zu Komplikationen bis hin zu Verletzungen. Abbildung 2-7 stellt einen solchen Griffbruch im Modell dar; der Bruch befindet sich auf der rechten Seite (linke Abbildung) des Getränkekastens. Hierbei ist in der Mitte der Griffleiste (Vergrößerung in der rechten Abbildung) ein Teil herausgetrennt.




Abbildung 2-7: Modellschaden S06 Riss in der kurzen Griffleiste

Der am zweithäufigsten auftretende Mangel an GDB-Getränkekästen stellt laut dieser Studie ein Bruch in den langen Griffleisten dar. Auch hier führen vor allem Haarrisse bei den herkömmlichen Erkennungssystemen zu Detektionsproblemen. Abbildung 2-8 zeigt einen weiteren Griffbruch im Modell. Der Bruch befindet sich auf der Rückseite (linke Abbildung) des Getränkekastens. Hier ist auf der rechten Seite der Griffleiste (siehe Vergrößerung in der rechten Abbildung) ein Teil herausgetrennt.




Abbildung 2-8: Modellschaden S09 Riss in der langen Griffleiste

Die dritte Schadensart (siehe Abbildung 2-9) bilden fehlende Fragmente im Gefache des Prüflings. Die Gefache des Getränkekastens dienen vorwiegend zum Schutz der einzelnen Flaschen. Sie halten die einzelnen Gebinde an ihrem vorgesehenen Platz und sorgen dafür, dass sich diese nicht durch Aneinander reiben bzw. Stoßen gegenseitig beschädigen und auch die Etiketten nicht beschädigt werden. Dies spielt beim Transport und der Distribution eine sehr große Rolle, da die Verpackungseinheiten hier ständigen Vibrationen ausgesetzt sind.




Abbildung 2-9: Modellschaden S18 Gefacheschaden

Einen Getränkekasten mit einer abgebrochenen Ecke zeigt Abbildung 2-10. Der Schaden befindet sich an der vorderen Ecke, rechts unten. Diese Art von Defekt führt zu einer Destabilisierung der tragenden Kante und wirkt sich dadurch besonders negativ auf das Stapelverhalten aus.




Abbildung 2-10: Modellschaden S16 fehlende Ecke

Auch Schäden im Bodengitter, wie in Abbildung 2-11, treten oft in Form von Rissen oder gar als Fehlen ganzer Teile auf. Dies kann insbesondere beim Heben und Tragen zum Herausfallen einzelner Flaschen führen.




Abbildung 2-11: Modellschaden S21 Schaden im Bodengitter

Die Simulationen auf Basis dieser beschädigten Modelle liefern grundlegende Informationen über das Verhalten der Getränkekästen bei einer Stoßanregung. Der Vergleich der Frequenzspektren (siehe Abbildung 4-10) von Kästen mit verschiedenen Beschädigungen und unbeschädigten Exemplaren gibt Auskunft über die Frequenzbereiche, in denen sich die Beschädigungen hauptsächlich auswirken. Hierbei spielen auch das Anregungssignal, der Anregungsort, die Fixierung und nicht zuletzt die Sensorposition eine große Rolle. Die Simulationsspektren können des Weiteren in der Trainingsphase der KNN zur Mustererkennung durch Substitution der experimentellen Spektren zur Systemparametrierung eingesetzt werden. Eine detaillierte Diskussion der Ergebnisse erfolgt in Kapitel vier.

Im Kapitel „Anhang A“ befinden sich die Erläuterungen weiterer simulierter Schadensfälle des Kastenmodells zwei. Die Ergebnisse mit Diskussion erfolgt ebenso in Kapitel vier.

### 2.3.5 Auswertung FEM

Nach einem Simulationslauf liegen in der Ergebnisdatei für die betrachteten Knotenpunkte die zeitdiskreten Bewegungsvektoren im Abtastintervall  $t = \frac{1}{f_{Abtast}}$  in Tabellenform vor. Dadurch

ist die Lage der Punkte zu jedem Zeitpunkt  $t_n = n \cdot t$  im N Messungen umfassenden Messzeitraum  $t_N = \frac{N}{f_{Abtast}}$  definiert. Mit Hilfe der schnellen Fouriertransformation werden aus den

Bewegungsvektoren die Fourier Koeffizienten  $a_n$  und  $b_n$  für jede Oberschwingung bestimmt. Um das veränderte Schwingverhalten eines beschädigten Getränkekastens, das hier ausschließlich die veränderte Geometrie hervorruft, zu quantifizieren, wird das Frequenzspektrum mit den Amplituden  $a_n^S$  und  $b_n^S$  dem des unbeschädigten Kastens mit den Amplituden  $a_n^U, b_n^U$  gegenübergestellt. Bedeutend ist hier nur die absolute Differenz im Schwingverhalten als Auswirkung der Beschädigung, nicht ob eine Oberschwingung durch den Defekt des Getränkekastens gedämpft oder verstärkt wird. Eine Möglichkeit dies zu berücksichtigen, ist die Bildung der Summe der Beträge der Amplituden jeder Oberwelle:

$$A_n^{S,U} = \left| a_n^{S,U} \right| + \left| b_n^{S,U} \right|.$$



Die Abweichung vom Sollwert ergibt sich durch

$$A_n^{US} = \left| A_n^U - A_n^S \right|$$

Um die Frequenz der einzelnen Knotenpunkte vergleichen zu können, muss im weiteren Verlauf aus dem Spektrum eine aussagekräftige Kenngröße gebildet werden. Da es dabei nicht von Bedeutung ist, bei welchen Frequenzen sich die Schwingung von der eines intakten Getränkekastens unterscheidet, kann durch die Integration über den gesamten Frequenzbereich für jeden einzelnen Knotenpunkt die Kenngröße

$$I_A = \sum_{n=0}^{\frac{N}{2}-1} A_n^{US} \cdot \frac{f_{Abtast}}{N} \quad \text{bzw.} \quad I_A = \int_0^{\frac{f_{Abtast}}{2}} A_n^{US}(f) df$$

definiert werden. Diese fasst die Abweichungen vom Spektrum eines intakten Kastens zusammen und ermöglicht dadurch eine einfache Bewertung der Eignung des Knotenpunkts als Messpunkt zur Schadenserkennung. Es bietet allerdings keine Informationen über die Frequenzen, bei denen die Abweichungen von der Schwingung des intakten Kastens auftreten. Die Bewertung der Kenngröße kann daher nur zur Vorauswahl dienen, der eine weitergehende Analyse der Frequenzantwort an den ausgewählten Messpunkten folgen muss. Zudem findet bei der Bildung dieser Kenngröße bei den Frequenzen, die im Anregungssignal nur schwach auftreten, eine schwächere Gewichtung statt, da dort im Experiment eine geringere Messgenauigkeit zu erwarten ist. Die Ergebnisse dieser Auswertungsmethode finden sich im Abschnitt vier.

## 2.4 Datenvorverarbeitungsverfahren (DVV)

Die Vielfalt der DVV nimmt sich sehr groß aus. Demgemäß sollen hier, ohne Vollständigkeit anzustreben, nur Methoden zur Sprache kommen, welche unmittelbar die vorliegende Arbeit betreffen. Eine umfassende Darstellung findet sich z. B. in [40-42, 102].

Die gemessenen Bewegungsdaten der vibrierenden Kästen beinhalten genügend Informationen, um daraus Rückschlüsse auf den Zustand des Getränkekastens ziehen zu können. Da die gemessenen Rohdaten nach der Schwingungsanalyse aber noch keinen direkten Zugang zu diesen Informationen bieten, geschieht eine Aufbereitung, um die Information zu extrahieren. Es erfolgt eine Transformation der Daten aus der Zeitdomäne in den Frequenzraum. Dadurch werden die Unterschiede in den einzelnen Datensätzen, welche im unterschiedlichen Zustand

der Kästen begründet liegt, besser sichtbar. Um die große Anzahl an Informationen zu bewältigen bzw. überflüssige oder redundante Informationen zu entfernen, erfolgt eine Datenkomprimierung. Dazu kommen in der vorliegenden Arbeit zwei verschiedene Verfahren zum Einsatz: die numerische Integration sowie eine Hauptkomponenten-Transformation. Danach liegen die Informationen in bereinigter, verdichteter Form als Eingangsdaten (Pattern) zur Weiterverarbeitung durch das Künstliche Neuronale Netz vor. Abbildung 2-12 gibt einen Überblick über die beschriebene Prozedur.

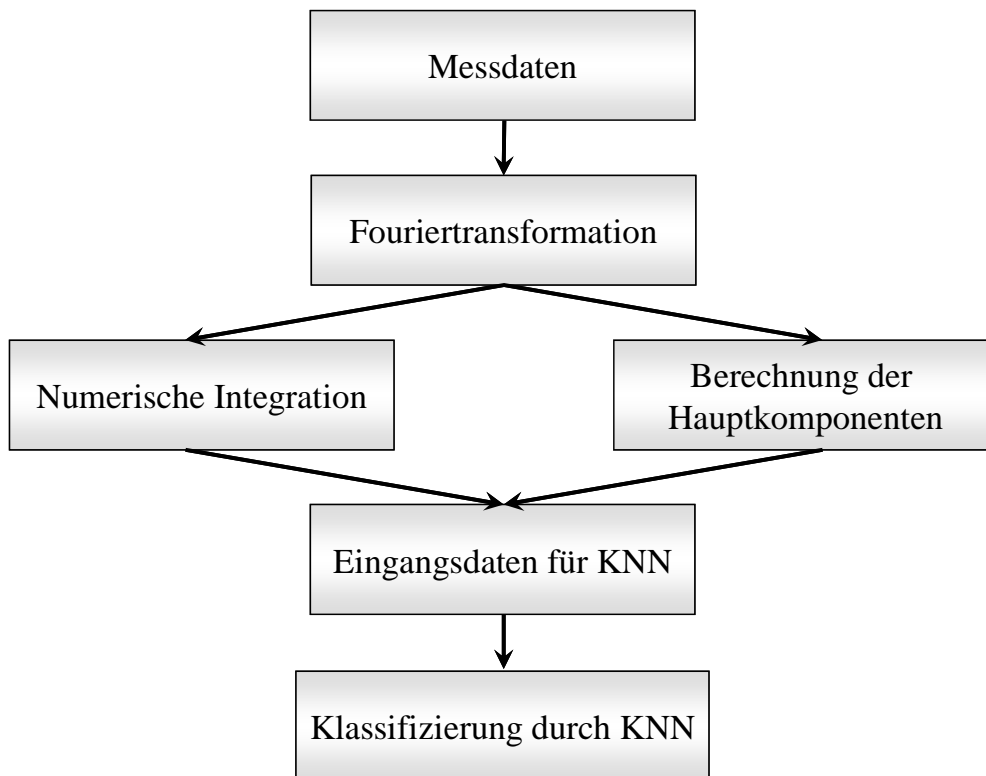


Abbildung 2-12: Fließschema der Datenvorverarbeitung

Die Digitalisierung des Beschleunigungssignals erfolgt mit einer Abtast-Frequenz von 10 kHz. Die Aufzeichnung von 2048 Messpunkten ergibt dabei ein Signalabtastintervall von 204,8 ms. Das fouriertransformierte Spektrum besteht aus 1024 diskreten Frequenzintervallen mit einer Frequenzauflösung von 4,88 Hz und einer Maximalfrequenz von 5 kHz.

### 2.4.1 Fourier-Analyse

Die Fourier-Analyse ist ein Verfahren zur Analyse von Signalen. Es beschreibt das Signal  $y(t)$  als eine Überlagerung unendlich vieler, harmonischer Sinus- und Kosinusschwingungen der Fourier-Reihe. Die einzelnen Summanden der Reihe werden dabei durch ihre Amplitude und Frequenz definiert. Die Schwingungskomponenten, auch als Oberschwingungen bezeichnet, schwingen mit einer Kreisfrequenz, die ein ganzzahliges Vielfaches der Kreisfrequenz  $\omega_0$  der Grundschwingung (Periodenlänge  $T = \frac{2\pi}{\omega_0}$ ) ist. Die unendliche Fourier-Reihe lässt sich nach

der Vorschrift

$$y(t) = a_0 + \sum_{n=1}^{\infty} [a_n \cdot \cos(n \cdot \omega_0 \cdot t) + b_n \cdot \sin(n \cdot \omega_0 \cdot t)]$$

bilden, wobei sich die Fourier-Koeffizienten nach

$$a_0 = \frac{1}{T} \cdot \int_{-\frac{T}{2}}^{+\frac{T}{2}} y(t) dt$$

$$a_n = \frac{2}{T} \cdot \int_{-\frac{T}{2}}^{+\frac{T}{2}} y(t) \cos(n\omega_0 t) dt$$

$$b_n = \frac{2}{T} \cdot \int_{-\frac{T}{2}}^{+\frac{T}{2}} y(t) \sin(n\omega_0 t) dt$$

ergeben [128, 129]. Durch die Transformation des zeitabhängigen Schwingungssignals in den Frequenzbereich gewinnt man Einblick in die Struktur des Signals. Die Amplituden der einzelnen Teilschwingungen werden als Funktion der Frequenz aufgetragen. Dadurch ist ersichtlich, welche Oberschwingungen das Signal erhält und mit welchem Anteil diese in die Gesamtschwingung eingehen. Tritt ein Signal nur in einem endlichen Zeitintervall  $T$  auf, wird es zur Fouriertransformation als periodisch fortgesetzt betrachtet.

Liegt es in Form von diskreten, äquidistanten Punkten vor, so verwendet man zur Analyse die diskrete Fouriertransformation. Zu beachten ist dabei das Abtasttheorem nach Nyquist-

Shannon, welches besagt, dass die Abtastfrequenz des Ursprungssignales mindestens doppelt so groß sein muss wie die maximal zu erwartende Signalfrequenz um alle Frequenzen korrekt zu erfassen ( $f_{Nyquist} = 0.5 \cdot f_{Abtast}$ ).

Wie häufig in der Signalverarbeitung oder zur Informationsaufbereitung kommt auch in der vorliegenden Arbeit die schnelle Fouriertransformation (Fast Fourier Transformation, FFT) zum Einsatz, um die Frequenzanteile in der Schwingungsantwort zu erhalten. Weitere Details hierzu finden sich in der Fachliteratur z.B. [128].

## 2.4.2 Datenkomprimierung

Um eine geeignete Weiterverarbeitung zu gewährleisten, erweist es sich als zweckmäßig, eine Datenreduktion vorzunehmen. Das eingesetzte DVV richtet sich dabei nach der Leistungsfähigkeit des eingesetzten Netzes sowie nach den Praxisanforderungen. Dabei wird ein Verfahren gesucht, dessen Komplexität möglichst niedrig ist und das dennoch aussagefähige Ergebnisse für das KNN liefert. Ziel ist es, ein auch im Hinblick auf den Rechenaufwand möglichst einfaches Verfahren anzuwenden, welches die charakteristischen Eigenschaften extrahiert und nicht-redundante Datensätze zur Verfügung stellt. Eine geeignete Transformation filtert die notwendigen Informationen aus den Datensätzen heraus und gibt diese in einem geeigneten Format zum Netztraining aus.

### 2.4.2.1 Numerische Integration nach Simpson

Ein Verfahren zur Informationsverdichtung und Datenreduktion, das schon Zacharias [35] erfolgreich verwendete, ist die Aufteilung der Frequenzspektren in äquidistante Klassen und deren Integration. Die Anwendung der Simpson-Regel (auch als Keplersche Fassregel bekannt) führt zu einer Halbierung des Ursprungsdatensatzes von 1024 diskreten Amplitudenwerten zu 512 Flächenintegralen über jeweils zwei Frequenzintervalle mit einer Breite von  $\Delta f = 9,76\text{Hz}$ .

$$\int_a^b f(f)df \approx \frac{b-a}{6} \left[ f(a) + 4f\left(\frac{a+b}{2}\right) + f(b) \right]$$

Durch Summation benachbarter Flächen erfolgt eine weitere Datenreduktion. Dem Vorteil der reduzierten Eingangsknotenzahl der neuronalen Netze und dem daraus resultierenden Gewinn an Performance steht als Nachteil ein reduzierter Informationsgehalt in den Daten gegenüber.

Eine Verringerung von ursprünglich 1024 diskreten Eingangsknoten zu 512 Eingangsknoten senkt die Anzahl der anzupassenden Knotenverbindungen und somit den Rechenaufwand beim Netztraining um ca. 75 %. Die Auswirkungen auf die Netzgüte (Zuverlässigkeit bzw. Reproduzierbarkeit und maximal erreichbare Erkennungsrate) wird in Kapitel vier erläutert.

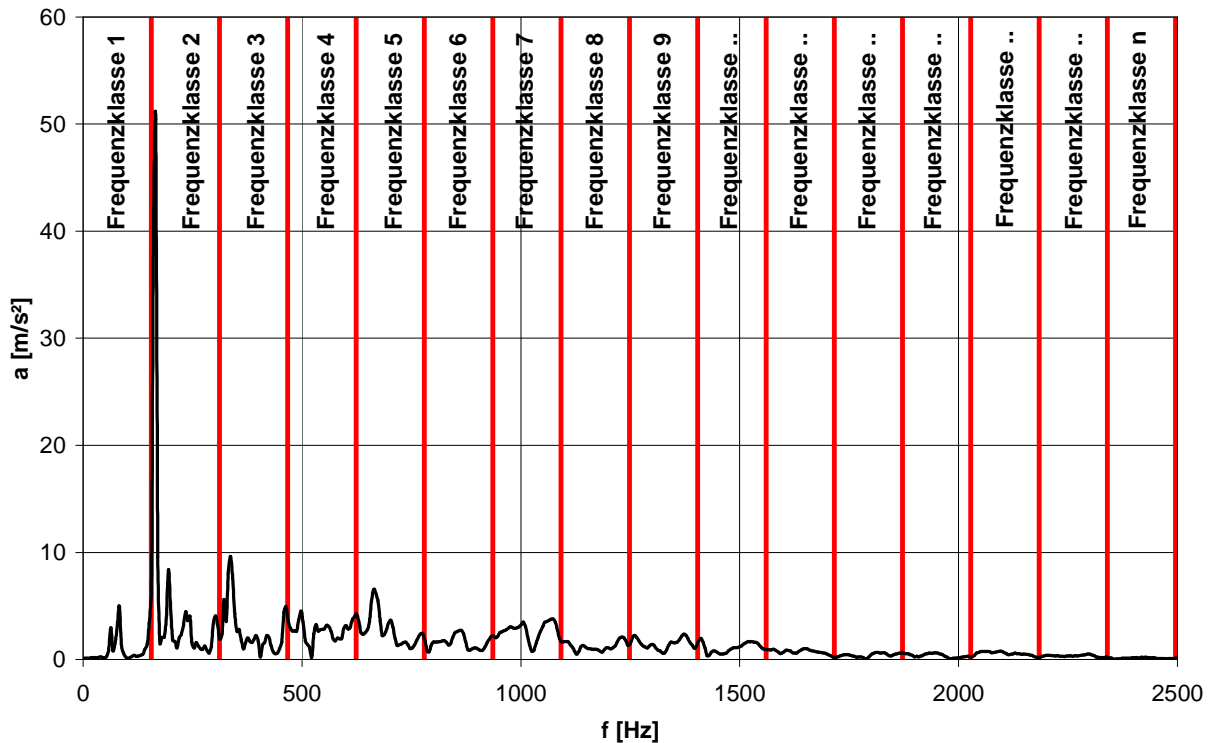


Abbildung 2-13: Unterteilung des Frequenzspektrums in Integrationsklassen

Die bei diesem Verfahren durch Komprimierung entstehende Zahlenkolonne besteht aus z.B. 32 Frequenzklassen und enthält genügend Informationen, um eine Differenzierung und Klassifizierung von Getränkekastenschäden vorzunehmen. Nach einer geeigneten Normierung der Werte, z. B. in das Intervall  $[0,1]$ , dienen diese als Eingangsdaten für das KNN.

### 2.4.2.2 Hauptkomponentenanalyse

Um eine Steigerung der Erkennungsrate zu erreichen, kommt in der vorliegenden Arbeit als alternative Informationsverdichtungsmethode eine Hauptkomponentenanalyse zum Einsatz [40-42]. Dabei geht es um die Frage: Welche Teile der gemessenen Schwingungsspektren bzw. welche Frequenzbereiche in den transformierten Messdaten enthalten die nötigen Informationen zur Charakterisierung des Zustandes eines Getränkekastens? Im vorliegenden Fall besteht ein Datensatz nach der Fouriertransformation aus 1024 diskreten Frequenzanteilen je Getränkekasten. Diese bezeichnet man als Merkmale bzw. Variablen. Alle Merkmale, die gleiche Informationen enthalten, werden in sog. Hauptkomponenten zusammengefasst. Ein Maß dafür gibt die Korrelation der einzelnen Merkmale. Variablen, die keine Information enthalten, zeichnen sich durch eine geringe Varianz über alle gemessenen Spektren aus. Sie werden durch die Hauptkomponentenanalyse abgetrennt, da sie als sogenannte Nicht-Informationen das Rauschen in den Daten erhöhen, so erhält man eine Datenreduktion, da jeder Getränkekasten nur noch mit wenigen latenten Variablen, den wichtigsten Hauptkomponenten oder Faktoren, beschrieben wird, anstatt durch viele einzelne Variablen. Die Hauptkomponenten sind eine Linearkombination  $t_{KN} = \sum_i^M p_{iK} \cdot x_{iN}$  der ursprünglichen Variablen. Die Datenmatrix X, bestehend aus den Fourier-transformierten Messdaten, dient als Grundlage zur Berechnung der Hauptkomponenten. Sie besteht aus N Zeilen (Anzahl der gemessenen Spektren) und M Spalten (Anzahl der Variablen bzw. Merkmale). Somit ist jeder Getränkekasten durch einen Vektor im M-dimensionalen Raum bestimmt. Die daraus berechnete transformierte Datenmatrix besteht aus N Zeilenvektoren (vgl. Abbildung 2-14 ). Die Dimension der Vektoren hängt von der Anzahl der verwendeten Hauptkomponenten ab und kann maximal so groß wie die Anzahl der Originalvariablen werden. Da die Hauptkomponentenanalyse in diesem Zusammenhang hauptsächlich zur Datenreduktion dient, ist es erstrebenswert, eine kleinere Anzahl an Hauptkomponenten zur Weiterverarbeitung einzusetzen.

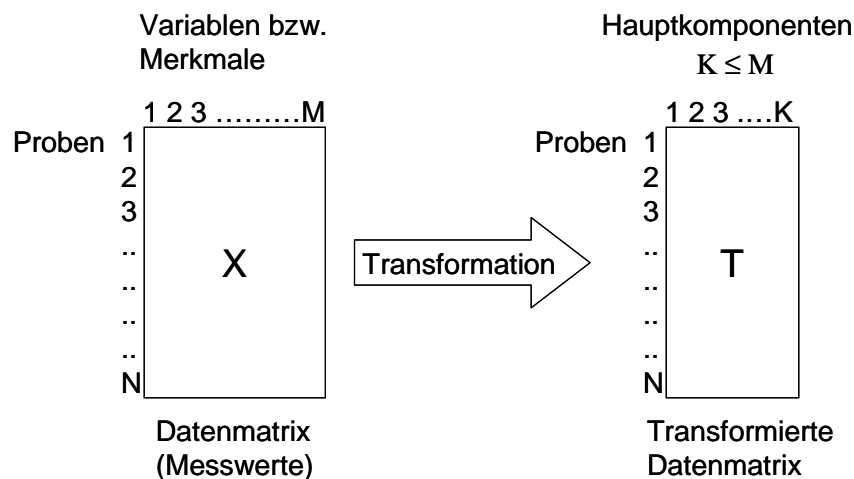


Abbildung 2-14: Transformation in Hauptkomponenten

Bei der Hauptkomponentenanalyse sucht man nach einer linearen Transformation der Vektorkoordinaten  $x_n(x_{n1}, x_{n2}, \dots, x_{nm})$  in neue Koordinaten  $x_t(x_{t1}, x_{t2}, \dots, x_{tk})$ , die einen möglichst großen Teil der Varianz der Originaldaten beschreiben. Um die Originaldatenmatrix  $X$  in die reduzierte Datenmatrix  $T$  (Gewichtsmatrix, Scores) zu transformieren, benötigt man die Faktorenmatrix  $P$  (Faktorenladungen, Loadings). Sie enthält die Gewichte, die zur Berechnung der einzelnen Hauptkomponenten nötig sind. Mathematisch betrachtet stellen diese Gewichte die Eigenvektoren der Korrelationsmatrix  $X^T X$  der standardisierten Datenmatrix dar. Die dazugehörigen Eigenwerte sind ein Maß für die erklärte Varianz pro Eigenvektor und somit ein Maß für den Informationsgehalt, den dieser Eigenvektor beschreibt. Diese sind nach dem prozentualen Anteil der enthaltenen Information geordnet und somit nimmt mit steigendem Index die Bedeutung der Komponenten am Gesamtinformationsgehalt ab. Werden Hauptkomponenten mit geringem Informationsgehalt abgetrennt, so entsteht ein Fehler, da die transformierten Daten nun nicht mehr 100 % der Varianz der Originaldaten beschreiben. Dieser Fehler wird aber im Zuge der Datenreduzierung in Kauf genommen und in der Residuenmatrix  $E$  angegeben. Bei Verwendung aller Hauptkomponenten erklären die transformierten Daten 100 % der Varianz der Originaldaten und der Fehler verschwindet. Die Residuenmatrix enthält demnach nur Nullwerte. Abbildung 2-15 illustriert das Schema der Hauptkomponentenanalyse.

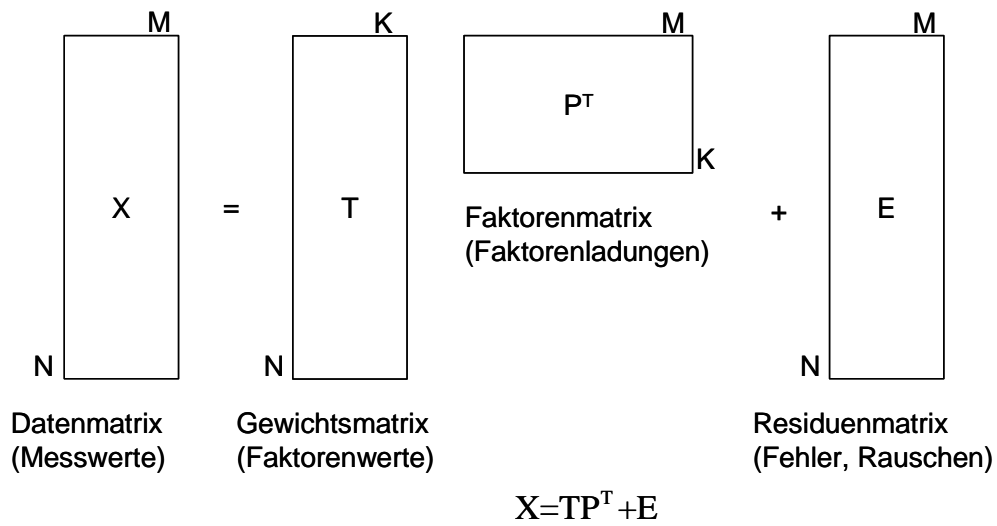


Abbildung 2-15: Transformation der Originaldaten in die Hauptkomponenten

Weitere Details und Erläuterungen mit Resultaten zu diesem Verfahren befinden sich im Abschnitt 4.2.6.3.



## 2.5 Mustererkennung mit Hilfe kognitiver Algorithmen

Auch hier soll die Diskussion nur solche kognitiven Verfahren betreffen, welche eine spezifische Anwendung in dieser Arbeit finden. Dies sind Künstliche Neuronale Netze (KNN) speziell zur Mustererkennung und Klassifizierung. Die Arbeiten [43, 46, 109, 110, 130-134] geben diesbezüglich einen umfassenden Einblick.

### 2.5.1 Künstliche Neuronale Netze (KNN)

Künstliche neuronale Netze bestehen aus einer großen Anzahl in Schichten angeordneter, einfacher Neuronen (Zellen). Diese senden sich Informationen in Form der Aktivierung der Zellen über gewichtete Verbindungen zu. Analog zu den biologischen Vorbildern, den Säugerhirnen, ist es mit diesen Systemen möglich, funktionale Zusammenhänge zwischen einem Eingangsdatenvektor und einem dazugehörigen Ausgangsdatenvektor herzustellen. Die Größe der beiden Vektoren ist problemspezifisch. Die Darstellung des extrahierten Wissens aus den Daten geschieht bei diesem System nicht in einem mathematischen Gleichungssystem, sondern liegt in der Gesamtheit des neuronalen Netzes sowohl in den Verbindungen außerhalb der Neuronen als auch in den mathematischen Funktionen in den Neuronen verankert. Die interne Logik eines KNN ist streng mathematisch. In beliebiger Verschachtelungstiefe approximieren einfache Funktionen den Gesamtzusammenhang. KNNs können sowohl statische als auch dynamische Zusammenhänge abbilden. Dabei unterscheiden sich die Netze jedoch sowohl in der Topologie als auch im Trainingsverfahren.

Die Arbeitsweise eines KNN vollzieht sich in zwei Stufen: In der ersten, der so genannten Trainingsphase, erlernt das KNN den Zusammenhang zwischen dem Ein- und dem Ausgabevektor an Hand von vorliegenden zusammengehörigen Datensätzen. In der Prädiktionsphase verwendet das Netz die zuvor erlernten Zusammenhänge, um die Ausgänge bei unbekanntem Eingängen zu berechnen. Es erweist sich jedoch als möglich, in der Prädiktionsphase jeweils aktuelle Dateien in die Wissensbasis zu integrieren.

Zentraler Punkt bei der Anwendung eines KNN ist das vorliegende Datenmaterial, das in der Trainingsphase Verwendung findet. Das KNN kann in der Prädiktionsphase nur dann eine entsprechend sinnvolle Abbildung vornehmen, wenn der Prädiktionsbereich nur bis zu einem gewissen Grad vom Trainingsbereich abweicht. Neue Entwicklungen zeigen, dass eine Datenextrapolation zumindest zu der gleichen Güte führt wie andere Extrapolationsmethoden. Darüber vermögen sogenannte „functional nodes“ die Prädiktion stark zu stützen [135].

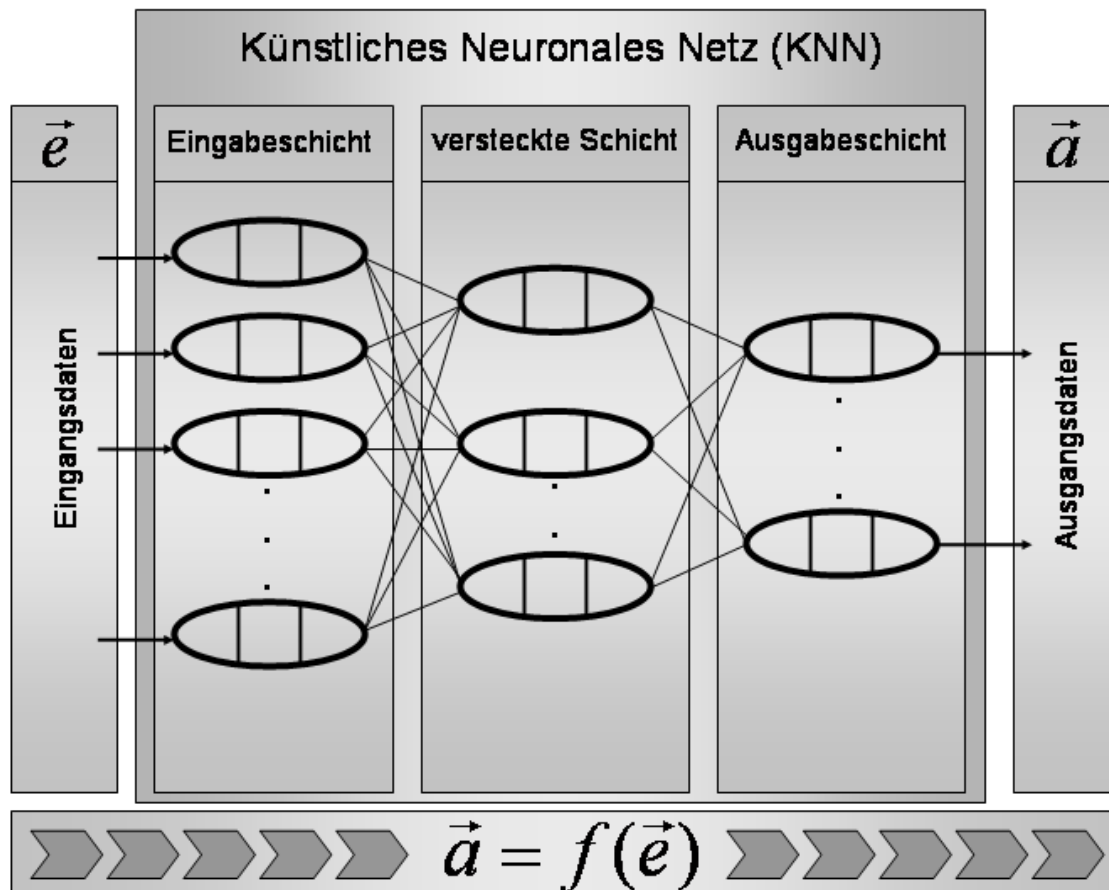


Abbildung 2-16: Schema eines Künstlichen Neuronales Netzes (KNN)

Diese Form der Informationsextraktion und Speicherung hat folgende Vorteile [46]:

**Lernfähigkeit:** Neuronale Netze werden nicht fest programmiert, sondern durch ein Lernverfahren mit einer großen Klasse von Trainingsmustern trainiert. Damit sind sie, eher als fest programmierte Algorithmen, in der Lage, ihr Verhalten (d.h. ihre Ausgaben) geänderten Eingaben anzupassen.

**Parallelität:** Neuronale Netze sind bereits vom Ansatz her massiv parallel und daher für eine Implementierung oder Simulation auf Parallelrechnern geeignet.

**Verteilte Wissenspräsentation:** Bei fast allen neuronalen Modellen ist das Wissen des neuronalen Netzes in den Gewichten verteilt gespeichert. Zum einen ermöglicht dies erst die hochgradig parallele Verarbeitung, zum anderen bewirkt es eine höhere Fehlertoleranz des Gesamtsystems gegenüber Ausfall einzelner Neuronen oder Verbindungen.

**Höhere Fehlertoleranz:** Durch die verteilte Repräsentation können neuronale Netze eine höhere Fehlertoleranz bei Ausfall einzelner Komponenten als herkömmliche Algorithmen

besitzen. Dies gilt allerdings nur, wenn die Fehlertoleranz beim Entwurf des Systems (z.B. bei der Dimensionierung des Netzes, der Kodierung der Werte und beim Lernverfahren) mitberücksichtigt wurde. Nicht jedes trainierte KNN ist automatisch fehlertolerant.

**Assoziative Speicherung von Informationen:** Das Speichern von Informationen erfolgt inhaltsbezogen, d.h. assoziativ, und nicht adressbezogen wie in konventionellen Rechnerarchitekturen und Programmen. Mit neuronalen Netzen ist es leicht, ein zum eingegebenen Muster ähnliches Muster abzurufen.

**Robustheit gegenüber Störungen oder verrauschten Daten:** Neuronale Netze reagieren bei verrauschten Daten oder Störungen in den Eingabemustern meist weniger empfindlich als konventionelle Algorithmen. Dies ist aber sehr stark vom Trainingsvorgang abhängig.

**Default Werte und spontane Generalisierung:** Neuronale Netze bilden oft automatisch Prototypen von Eingabemustern, die derselben Klasse zugeordnet werden. Diese automatische Generalisierung liefert auch quasi umsonst „default“ Werte für nicht vollständig spezifizierte Parameter von Mustern, die als Eingabe an ein neuronales Netz angelegt werden.

**Aktive Repräsentation:** Neuronale Netze realisieren eine aktive Repräsentation, d.h. die Repräsentation ist nicht passiv und eine aktive Komponente (Programm) greift auf sie zu, sondern die Repräsentation des Wissens in den Verbindungsgewichten ist gleichzeitig an der Verarbeitung beteiligt.

Die Nachteile von künstlichen neuronalen Netzen sind [46]:

**Wissenserwerb nur durch Lernen möglich:** Speziell bei einer verteilten Repräsentation ist es sehr schwer, einem neuronalen Netz ein gewisses Basiswissen bereits mitzugeben, wie dies etwa bei lernfähigen symbolischen KI-Systemen in Form einer Wissensbasis möglich ist. Es gibt nur ganz wenige Anwendungen neuronaler Netze, bei denen die Gewichte durch einen externen Algorithmus vorbestimmt sind [135].

**Keine Introspektion möglich:** Neuronale Netze können keine Introspektion, d.h. keine Analyse ihres eigenen Wissens oder Problemlösevorgangs, durchführen, wie dies etwa die Erklärungskomponenten von Expertensystemen tun können. Auch die Analyse des Wissens eines Netzwerkes ist sehr schwierig.

**Lernen ist relativ langsam:** Fast alle populären Lernverfahren, wie beispielsweise auch die Variante des bekannten Backpropagation-Algorithmus, lernen sehr langsam. Dies ist insbesondere dann der Fall, wenn Netzwerke verwendet werden, die vollständig ebenen Weise verbunden sind, d.h. bei denen jedes Neuron einer Ebene mit allen Neuronen der nächsten Ebene verbunden ist.

### 2.5.1.1 Aufbau Künstlicher Neuronaler Netze

Um die Arbeits- und Funktionsweise neuronaler Netze zu verstehen, ist es wichtig, die Einzelkomponenten zu kennen. Dafür soll hier ein grundlegender Einblick geschaffen werden. Für weitergehende Informationen wird auf die einschlägige Fachliteratur verwiesen (siehe z.B. [43-46]).

Künstliche Neuronale Netze setzen sich grundsätzlich aus folgenden Bestandteilen und Funktionen zusammen:

#### Neuronen, Zellen

Angelehnt an das biologische Vorbild besteht das künstliche Netzwerk aus idealisierten Neuronen (vgl. Abbildung 2-17). Diese lassen sich als zentrales Element des Netzwerkes in drei Bestandteile aufteilen.




Abbildung 2-17: Neuron als kleinste Einheit in einem KNN

#### Propagierungsfunktion, Eingabefunktion $net_j$

Jedes Neuron besitzt zur Datenaufnahme einen bis mehrere tausend Eingänge. Diese können, je nach Neuron und Verbindungsnetzwerk, von einem netzinternen Neuronenausgang oder als externer Dateneingang stammen. Bevor die Datenverarbeitung im Neuron stattfinden kann,

werden diese Eingänge vorverarbeitet. Dies geschieht meist durch Bilden der Summe der Eingänge, multipliziert mit dem Gewicht  $w_{ij}$  des jeweiligen Einganges.

$$net_j = \sum_i o_i w_{ij}$$

Dieser berechnete, diskrete Wert wird im nächsten Schritt an die Aktivierungsfunktion weitergegeben.

### Aktivierungsfunktion $a_j$

Nachdem die aktuellen Eingänge am Neuron mit der Propagierungsfunktion zusammengefasst wurden, folgt daraus die Berechnung des Aktivierungszustandes des Neurons.

$$a_j = f(net_j)$$

Es kommen dabei häufig die in Tabelle 2-4 aufgelisteten mathematischen Funktionen zum Einsatz:

Tabelle 2-4: Aktivierungsfunktionen in einem Neuron

Identität	$a_j = net_j$
Linear bis Sättigung	$a_j = \begin{cases} S_u, & a_j < S_u \\ net_j, & S_u \leq a_j \leq S_o \\ S_o, & a_j > S_o \end{cases}$
Binäre Schwellenwertfunktion	$a_j = \begin{cases} 1, & net_j \geq S \\ 0, & net_j < S \end{cases}$
Sinus bis Sättigung	$a_j = \begin{cases} S_u, & a_j < S_u \\ \sin(net_j), & S_u \leq a_j \leq S_o \\ S_o, & a_j > S_o \end{cases}$
Logistische Funktion (Sigmoid)	$a_j = \frac{1}{1 + \exp(-cnet_j)}$
Tangens Hyperbolicus	$a_j = \tanh(net_j)$

Der Aktivierungswert der Neuronenausgang ist problemspezifisch. Es können beliebig komplexe Funktionen in den Neuronen verwendet werden [135]. Der Wertebereich des Neuronen-

ausgang kann kontinuierlich oder diskret sein. Für Klassifizierungsaufgaben empfiehlt sich meist der diskrete Wertebereich, um eine eindeutige Zuordnung zu einer Klasse zu bekommen (vgl. Tabelle 2-5).

Tabelle 2-5: Wertebereiche eines Neuronenausganges

$a_j$	kontinuierlich	unbeschränkt	[REAL] [INTEGER] ...
		Intervalle	[0,1] [-1,1] ...
	diskret	binär	(0,1) (-1,18) ...
		mehrwertig	(-1,0,1) (-100,...,100) ...

### Ausgabefunktion $o_j$

Der Ausgang des Neurons wird durch die Ausgabefunktion aus der zuvor berechneten Aktivierung bestimmt  $o_j = f_{out}(akt_j)$ . In der Regel wird der Ausgangszustand dem inneren Aktivierungszustand gleichgesetzt  $o_j(t) = akt_j(t)$ .

Die Ausgabefunktion ermöglicht z.B. einen Wettbewerb unter den einzelnen Neuronen einer Schicht. So kann die Ausgabefunktion „winner-takes-all“ eingesetzt werden, um nur einem bestimmten Neuron, z.B. dem mit der höchsten Aktivierung, die Weitergabe seiner Information zu ermöglichen. Alle übrigen Neuronen dieser Schicht werden blockiert und geben keine Information weiter.

### Verbindungsnetzwerk

Zur Verarbeitung der Informationen im neuronalen Netz muss zwischen den einzelnen Neuronen eine Kommunikationsverbindung bestehen (siehe Abbildung 2-18). Diese Verbindungen dienen den Neuronen als Ein- bzw. Ausgang und können über die veränderbaren Gewich-

te  $w$  angepasst werden. Bei KNNs besitzt jeder Knoten in der Regel einen Ausgang, kann aber verschiedene Ausgänge vorangehender Knoten als Eingänge aufnehmen.

Bei den in dieser Arbeit benutzten Feed-Forward-Netzwerken verbinden die einzelnen richtungsabhängigen Linien, die in der Gesamtheit die Vernetzung festlegen, den Ausgang des vorangegangenen Knotens mit dem Eingang des betrachteten Knotens (vgl. Abbildung 2-18).




Abbildung 2-18: Verbindungsnetzwerk in einem Künstlichen Neuronen Netz (KNN)

Der Index  $j$  bezeichnet die Bestandteile und Funktionen für das betrachtete Neuron, der Index  $i$  die Größen von Vorgängerneuronen bzw. Gewichten. Das Gewicht  $w_{ij}$  bezeichnet zum Beispiel die Verbindungsstärke des Neurons  $i$  zum Neuron  $j$ . Der Ausgang  $o_i(t)$  multipliziert mit dem Verbindungsgewicht  $w_{ij}$  ergibt somit einen Eingang des betrachteten Neurons. Der Index  $t$  deutet an, dass diese Größen im Netzwerk veränderbar sind. Die Gesamtheit aller Verbindungen wird für die Berechnungen in einer Gewichtsmatrix abgespeichert. Die Konditionierung erfolgt ausschließlich im Trainingsvorgang. Nach dem Training ist die Gewichtsmatrix festgelegt und wird zur Prognose, also zur Berechnung unbekannter Ausgangsvektoren zu gegebenen Eingangsvektoren, benutzt.

Die Verbindung der einzelnen Neuronen erfolgt in beliebiger Weise miteinander, wobei auch rekursive Strukturen (Abbildung einer Dynamik) auftreten. Die Anzahl der Zwischenknoten und auch die Vernetzung untereinander sind problemspezifisch und meist empirisch festgelegt.

### 2.5.1.2 Lernverfahren in Künstlichen Neuronale Netzwerken

Neuronale Netze leiten Verallgemeinerungen aus gegebenen Beispielen eines Entscheidungsproblems und deren Lösungen ab. Dazu müssen sie „lernen“, zu einem gegebenen Eingangsdatenvektor den richtigen Ausgangsdatenvektor zu liefern. Diesen Lernprozess nennt man auch Trainings- oder Konditionierungsprozess. Die Gesamtheit der Daten, auf denen dieser Prozess basiert, nennt man deshalb Trainingsdaten. Die Güte eines KNN hängt direkt von der Qualität der Trainingsdaten ab. Die Trainingsdaten sollten die Wertebereiche sämtlicher Ein- und Ausgabevariablen vollständig umspannen. Die notwendige Anzahl der Daten wird durch die Sensitivität des Zusammenhanges in den unterschiedlichen Wertebereichen festgelegt. Durch zyklisches Präsentieren dieser Daten versucht das Neuronale Netz gemäß einer fest vorgegebenen Vorschrift, der Lernregel, die korrekten Anpassungen vorzunehmen. Prinzipiell kann dieser Lernprozess bestehen aus folgenden Schritten:

- Entwickeln neuer Verbindungen
- Löschen existierender Verbindungen
- Modifikation der Verbindungsstärke zwischen den Zellen
- Modifikation des Schwellenwertes
- Modifikation der Funktionen in den Zellen
- Entwickeln neuer Zellen
- Löschen bestehender Zellen (Pruning)

Von diesen Möglichkeiten findet die Modifikation der Verbindungsstärke zwischen den Zellen am häufigsten Anwendung. Man unterscheidet dabei grundsätzlich drei Verfahren des Lernens:

#### **Überwachtes Lernen (supervised learning)**

Die konkrete Abweichung des Netzoutputs vom Solloutput, der Fehler, bildet die Basis der Gewichtsveränderung. Dazu muss zu jedem Eingangsdatenvektor ein Ausgangsdatenvektor existieren.

#### **Bestärkendes Lernen (reinforcement learning)**

Es erfolgen nur qualitative Einstufungen (exakt, sehr nahe, nahe, weit, sehr weit). Daraus resultiert ein eingeschränkter Handlungsspielraum zur Gewichtsanzpassung.



## Unüberwachtes Lernen (unsupervised learning)

Das KNN versucht selbstständig, nach vorgegebener Strategie, die Eingangsdatensätze zu klassifizieren.

In der vorliegenden Arbeit fanden nur überwachte Lernverfahren Anwendung. Die Topologie des Netzwerkes wurde vor dem Training, basierend auf empirischen Informationen, festgelegt, und während des Trainingsvorganges nicht mehr verändert. Die Anpassung der Gewichte erfolgt grundsätzlich nach dem iterativen Schema:

### Neues Gewicht = altes Gewicht + Gewichtsänderung

$$w_{ij}(t+1) = w_{ij}(t) + \Delta w_{ij}(t)$$

- $w_{ij}(t)$  ist das alte Gewicht vor dem Lernschritt
- $w_{ij}(t+1)$  steht für das neue Gewicht nach dem Lernschritt
- $\Delta w_{ij}(t)$  ist die im Lernschritt hervorgerufene Gewichtsänderung

Von diesem Verfahren sind die Gewichte zwischen allen Neuronen betroffen. Die Gewichtsänderung hängt allgemein vom Netzfehler  $E$ , also der Abweichung zwischen berechnetem  $o_{pj}$  und gewünschtem Ergebnis  $t_{pj}$  (teaching-input), ab.

Das Ziel der Gewichtsanzpassung ist die Minimierung dieser Abweichung, also die Minimierung des Gesamtnetzfehlers  $E$ . Ein gängiges Abbruchkriterium beendet den Lernprozess, wenn z.B. der summierte quadratische Fehler über alle Ausgangsneuronen  $o_{pj}$  und alle Trainingsbeispiele  $p$  als hinreichend klein eingestuft wird.

$$E_{\text{Gesamt}} = \sum_p E_p \quad \text{mit} \quad E_p = \frac{1}{2} \sum_j (t_{pj} - o_{pj})^2$$

Für die Gewichtsanzpassung kam die für einstufige Netze ohne versteckte Zwischenschicht und mit linearer Aktivierungsfunktion entwickelte Delta-Regel zum Einsatz.

Dabei erfolgt die Änderung der Gewichte  $\Delta W$  aufgrund des vorliegenden negativen Gradienten der Gesamtfehlerfunktion  $-\nabla E(W)$ .

Die Gewichtsveränderung kann nach jedem Trainingsdatensatz  $p$  erfolgen (online-lernen)

oder nach Abschluss aller Trainingsdatensätze (offline-lernen). Das Offline-Verfahren erfordert ein Aussummieren der für jeden Datensatz  $p$  berechneten Fehler.

$$\text{Online: } \Delta_p w_{ij} = \eta o_{pi} \delta_{pj}$$

$$\text{Offline: } \Delta w_{ij} = \eta \sum_p o_{pi} \delta_{pj}$$

Die Änderung des Gewichtes  $\Delta w_{ij}$  von Neuron  $i$  zu Neuron  $j$  ist proportional zu

- Lernrate  $\eta$ ,
- Ausgabe  $o_{pi}$  des Vorgängerneurons  $i$ ,
- Differenz aus berechnetem zu gewünschtem Ausgangswert  $\delta_{pj} = (t_{pj} - o_{pj})$ .

Die Proportionalitätskonstante  $\eta$ , als Lernrate oder Schrittweite bezeichnet, bestimmt den zur Gewichtskorrektur verwendeten Anteil des berechneten Netzfehlers. Setzt man die Lernrate zu hoch, kann es sein, dass man über den gesuchten minimalen Fehler springt, da die Anpassung der Gewichte in zu großen Schritten erfolgt. Eine zu klein gewählte Lernrate kann den Lernprozess wesentlich verlängern, da zur Minimierung des Gesamtfehlers mehr Iterationsschritte nötig sind.

Für mehrschichtige Neuronale Netzwerke mit bereits erwähnter Zwischenschicht hat die Delta-Regel keine Gültigkeit, da für die Anpassung der Gewichte der versteckten Neuronen kein definierter Ausgang  $t_{pj}$  existiert und somit kein Fehler in den Zwischenschichten berechenbar ist. Deswegen muss dieser Sollausgang bzw. der Fehler anderweitig bereitgestellt werden. Dies geschieht mit Hilfe der Backpropagation-Lernregel, welche auf der Delta-Lernregel basiert. Sie war die erste Lernregel, die es ermöglichte, Gewichte auf Verbindungen zu versteckten Neuronen anzupassen. Die Berechnung der Gewichtsänderung erfolgt hierbei ebenso nach obiger Berechnungsvorschrift. Einzig bei der Bestimmung von  $\delta_j$  wird nun unterschieden, ob es sich um ein Ausgangsneuron oder ein verdecktes Zwischenneuron handelt.

$$\delta_{pj} = \begin{cases} \dot{f}_{akt}(net_{pj}) \cdot (t_{pj} - o_{pj}) & \text{falls } j \text{ Ausgabezelle ist} \\ \dot{f}_{akt}(net_{pj}) \cdot \sum_k (\delta_{pk} w_{jk}) & \text{falls } j \text{ verdeckte Zelle ist} \end{cases}$$

Eine Änderung der Gewichte an den Eingängen eines Neurons ändert den Gesamtinput  $net_{pj}$

des Neurons und damit auch seine Aktivierung  $akt_{pj}$ . Bei nicht-linearen Aktivierungsfunktionen kann eine kleine Änderung des Einganges eine große Auswirkung auf die Aktivierung und somit auf den Netzausgang bewirken. Die Sensitivität der Aktivierung aufgrund von Gewichtsschwankungen erfolgt durch die Ableitung der Aktivierungsfunktion  $\dot{f}_{akt}(net_{pj})$  nach dem Gesamtinput und hat Einfluss auf die Gewichtsänderung im Training.

Gewichte bzw. Verbindungen die zu verdeckten Neuronen führen, werden mit Hilfe der bereits berechneten Gewichtsadjustierungen aller verbundenen Nachfolgeneuronen  $k$  bestimmt. Die Anpassung der Gewichte  $\Delta w_{ij}$  eines verdeckten Neurons  $j$  zu seinen vorgelagerten Neuronen  $i$  erfolgt unter Einbeziehung der Verbindungen  $w_{jk}$  dieses Neurons zu seinen verbundenen Nachfolgeneuronen  $k$  sowie für diese bereits berechneten Fehlersignale  $\delta_{pk}$ .

Nach der erfolgreichen Anpassung der Gewichte einer Neuronenschicht beginnt die Prozedur für die vorhergehende Schicht erneut. Daher rührt der Name Backpropagation, weil der Fehler bzw. die Gewichtsadjustierung vom Ausgang zum Eingang zurückpropagiert wird.

Stoppt der Trainingsprozess, so liegen die Gewichte auf den Verbindungen fest. Dann ist auch eindeutig determiniert, wie aus den anliegenden Inputs die Berechnung eines Outputs erfolgt. Dies ist gleichbedeutend mit der Aussage, dass eine Funktion im Netz abgespeichert ist, die diese Verarbeitung festlegt.

Die Backpropagation Lernregel bildet die Basis für eine Reihe weiterer Lernregeln wie z.B. Quick-Prop, SuperSAB oder Resilient Propagation (RPROP). Diese stellen eine konsequente Weiterentwicklung und Verbesserung des Lernverfahrens von Künstlichen Neuronalen Netzen dar (an dieser Stelle ein Verweis auf die einschlägige Fachliteratur [43, 45, 46]).

## 2.5.2 Anwendung der Neuronalen Netze zur Schadenserkennung

Die eingesetzte Software „Stuttgart-Neural-Network-Simulator“ (SNNS), von Professor Zell et. al am Institut für Parallele und Verteilte Systeme (IPVS) der Universität Stuttgart entwickelt, steht im Rahmen der GNU General Public License für Anwendungs- und Forschungszwecke frei zur Verfügung [46]. Langjährige Entwicklungs- und Forschungsbestreben der Entwicklergemeinschaft um Professor Zell machen den Code sehr leistungsfähig. Eine große Anzahl an verschiedenen Methoden und eine Parametrierbarkeit mit vielen Freiheitsgraden sowie die Möglichkeit, direkt am Quellcode Änderungen vorzunehmen, tragen diesen Vorteilen

Rechnung. Der Simulationskern zur Berechnung der Neuronalen Netze ist in der Programmiersprache C verfasst und plattformunabhängig. Die Bedienung und Parametrierung erfolgt über Befehle auf Kommandozeilenebene oder auf graphischem Weg über ein fensterbasierendes Benutzerinterface. Die graphische Benutzeroberfläche (GUI), ursprünglich für Unix-Systeme entwickelt, ist mit entsprechenden Hilfsprogrammen auch auf anderen Betriebssystemen ausführbar. Für die Anwendung größerer Netzwerke empfiehlt sich die Nutzung eines Hochleistungsrechners.

Bei der Wahl der Netztopologie ist die Anzahl der zu verarbeitenden Datenpunkte entscheidend. Da ein Datensatz (das vorverarbeitete Messspektrum) die gesamte Information zum Beschädigungsgrad enthält, muss dieser dem Neuronalen Netz als eine Einheit zur Verfügung gestellt werden. Liegen nach der Datenreduktion z.B. 64 Hauptkomponenten bzw. Flächenintegrale vor, so muss das neuronale Netz in der Eingabeschicht genauso viele Eingangsknoten enthalten.

Die Ausgangsschicht des Netzwerkes ist durch die Art der Schadensdetektion ebenfalls festgelegt. Die Prognose des Netzwerkes soll nur zwischen den beiden Zuständen „Intakt“ und „Defekt“ unterscheiden. Numerisch wird dies durch die Zuordnung der Zahlenwerte „1“ für einen fabrikneuen Getränkekasten und „0“ für einen zerstörten und somit zur Weiterverwendung im Mehrwegkreislauf ungeeigneten Getränkekasten approximiert. Der Übergang vom fabrikneuen zum unbrauchbaren Zustand wird von den Kästen im Laufe ihrer Einsatzzeit fließend durchlaufen und hängt sehr stark von ihrer Beanspruchung ab. Werte, die zwischen 0 und 1 liegen, bedeuten in diesem Fall eine nicht eindeutige Zuordnung zu einer Klasse. Durch Einfügen einer Zuordnungsgrenze lässt sich hier die Schwelle zwischen der Zuordnung zu einem der beiden Zustände verschieben und somit die Sortierqualität beeinflussen. Dies ist schematisch in Abbildung 2-19 dargestellt. Eine Verschiebung der Aussortiergrenze nach rechts hat eine Vergrößerung des Bereiches Defekt (rot) und eine Verkleinerung des Bereiches Intakt (grün) zur Folge. Datensätze, denen das Künstliche Neuronale Netz am Ausgang einen Zahlenwert zwischen 0 und der Zuordnungsgrenze zuweist, werden somit der Kategorie von unbrauchbaren Mehrwegkästen zugeordnet. Eine Aussortierung wäre die Folge. Diese Vorgehensweise erlaubt dem Anlagenbetreiber die fließende Anpassung der Aussortierung an seine Qualitätskriterien. Damit ist eine wesentliche Anforderung aus der Praxis erfüllt.




Abbildung 2-19: Fließende Grenze zwischen den Zuständen

An die versteckte Zwischenschicht in den untersuchten Netzen sind keine Anforderungen gestellt. Die Wahl der Größe der Zwischenschicht geschieht rein empirisch basierend auf Literaturempfehlungen. Sie bewegt sich im Bereich des 0,5-fachen bis 2-fachen der Anzahl der Eingangsknoten [136, 137]. Die Topologie des Neuronalen Netzwerkes ist damit definiert und im weiteren Trainingsverlauf statisch. Im Training geschieht folglich nur eine Anpassung der Gewichte zwischen den Knoten. Tabelle 2-6 listet alle relevanten Parameter zu dieser Prozedur auf.

Tabelle 2-6: Spezifikation der Lernparameter für das Künstliche Neuronale Netz (KNN)

Netzwerkparameter	Einstellung bzw. Startwerte	
Lernmethode	überwachtes Lernen	
Netzwerkdynamik	statisch	
Eingangsformat der Neuronen	keine Skalierung bzw. Normierung	
Ausgabeformat der Neuronen	keine Skalierung bzw. Normierung	
Startgewichte	Zufällig: -1,0 bis 1,0	
RPROP - Koeffizienten	Lernrate $\eta$ steigend:	1,2
	Lernrate $\eta$ fallend:	0,5
	Weight Decay Term:	2,0
	Begrenzung oberes Limit:	50,0
	Begrenzung unteres Limit:	1,0 e-6
Schrittweite - Delta Weight:		0,1
	Aktivierungsfunktion	Sigmoid: $akt_j = \frac{1}{1 + \exp(-net_j)}$
	Gewicht-Anpassung	online
	Gütekriterium	halber quadratischer Fehler:
		$E_{ges} = \frac{1}{2} \sum E_w^2$
Berücksichtigte Fehlerarten bei der Fehlerminimierung im Netz	MSE (mittlerer quadratischer Fehler):	
	$E_{RAE} = \frac{\sum (t_{pj} - o_{pj})^2}{n}$	
Berücksichtigte Fehlerarten bei der Fehlerminimierung im Netz	RAE (relativer absoluter Fehler):	
	$E_{RAE} = \frac{\sum \left  \frac{t_{pj} - o_{pj}}{t_{pj}} \right }{n}$	
Berücksichtigte Fehlerarten bei der Fehlerminimierung im Netz	Gewichtung der Fehlerarten:	
	$\frac{m_{Validation}}{m_{Training}} = 0,1; \frac{m_{Test}}{m_{Training}} = 0,35$	

Die Beurteilung des Gesamtfehlers erfolgt anhand der Abweichung der prognostizierten Ausgabe und der gewünschten bzw. vorgegebenen Ausgabe, die das KNN während des Trainings zu minimieren versucht. Die Lernvorgabe geschieht nicht im kontinuierlichen Wertebereich zwischen 0 und 1, sondern diskret mit den Extremwerten 0 und 1. Es findet eine Binarisierung der Netzwerkausgabe anhand der vorgegebenen Trenngrenze statt. Die Bestimmung der Netzgüte erfolgt in zwei Schritten. Ca. 80 % der Datensätze dienen als sogenannte Trainingsdaten aktiv zur Fehlerminimierung, und 20 % der Kontrolle (10 % als Validierungsdaten, 10 % als Testdaten). Die Validierung erfolgt während des Trainings. Der Validierungsfehler ermöglicht Schlussfolgerungen über den Lernstatus des KNN. Während im Allgemeinen, bedingt durch das Gradientenabstiegsverfahren, der Trainingsfehler mit steigender Anzahl an Trainingsritten abnimmt bzw. nach einer gewissen Zeit konstant bleibt, steigt der Validierungsfehler in den meisten Fällen wieder an (siehe Abbildung 2-20). Dies liegt daran, dass das KNN speziell die Trainingsdaten zu prognostizieren vermag, die Generalisierungsfähigkeit dabei aber verloren geht. Das Netz lernt „auswendig, was in der Literatur als „overfitting“ bezeichnet wird. Folglich ist der optimale Trainingsfehler dann erreicht, wenn die Validierungskurve ein Minimum erreicht hat bzw. im Schnittpunkt von Validierungs- und Trainingsfehlerkurve liegt. In Abbildung 2-20 ist dies durch einen Kreis graphisch gekennzeichnet. Zwar ist die Erkennung der Trainingsdatensätze in diesem Stadium noch nicht optimal, die Erkennung von unbekanntem Datensätzen, welche in der Anwendungsphase des KNN auftreten, ist hier aber am besten.

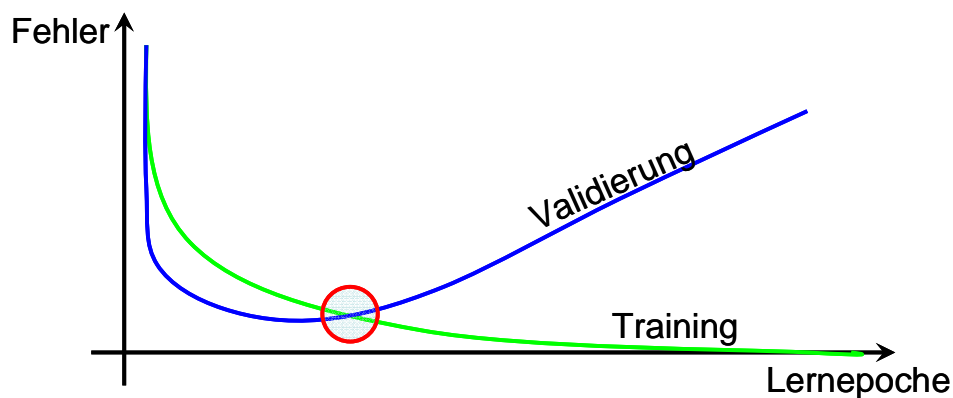


Abbildung 2-20: Trainings- und Validierungsfehler eines KNN

Nach dem Netzwerktraining erfolgt eine abschließende Bewertung der Prognosefähigkeit mit nun festgelegten Gewichten anhand des Testdatensatzes. Je nach enthaltenem Datenmaterial kann der Netzwerkfehler im Bereich des Trainingsfehlers liegen oder sich bei besonders „kniffligen“ Datensätzen vergrößern [43, 45, 46].

### 3 Versuchsanlagen zur Kasteninspektion

Im Verlauf der Projektabwicklung entstanden durch neue Erkenntnisse aus den Simulationsergebnissen und durch empirische Weiterentwicklung verschiedene Test- und Versuchsanlagen. Beim Funktionsmuster eins war das Hauptaugenmerk auf die generelle Entwicklung der Methode gerichtet, wogegen beim Funktionsmuster zwei vor allem die industrielle Nutzbarkeit umgesetzt wurde. Eine Beschreibung der beiden Funktionsmuster erfolgt in diesem Kapitel.

Die Anlagensteuerung und Messwerterfassung erfolgt über eine handelsübliche Workstation und eine Schnittstellenkarte sowie die kommerzielle Software LabVIEW (Laboratory Virtual Instrumentation Engineering Workbench) der Firma National Instruments. LabVIEW-Programme werden als Virtuelle Instrumente (VI) bezeichnet und sind in der Programmiersprache „G“ erstellt. Sie bestehen aus zwei Komponenten: dem Frontpanel, welches die Benutzerschnittstelle enthält und dem Blockdiagramm zur graphischen Programmierung. Dieses wird nicht von einem Interpreter abgearbeitet, sondern kompiliert. Dadurch ist die Performance mit anderen Hochsprachen vergleichbar. Eine Echtzeitregelung ist mit entsprechender Hardware realisierbar und das System somit mit speicherprogrammierbaren Steuerungen (SPS) konkurrenzfähig.

#### 3.1 Funktionsmuster 1 – Laboranlage

Die ersten Versuche zur Schadensdetektion an Getränkekästen mit Hilfe von Schockanregung erfolgten unter Laborbedingungen. Bei weitestgehend unveränderlicher Prüfungsumgebung haben z. B. Temperatur oder Luftfeuchte keinen maßgeblichen Einfluss auf das Ergebnis. Dies gilt auch für die Materialtemperatur der Getränkekästen, welche im industriellen Umfeld gravierenden Schwankungen unterworfen ist. Eine Berücksichtigung im Prognoseprozess kann bei diesen quasi konstanten Parametern deshalb unterbleiben. Da es sich bei diesem Versuchsaufbau nicht um eine industrielle Applikation handelt, wurde der Automatisierungsgrad gering gehalten. Deshalb ist zur Prüfung eines Getränkekastens bei einigen Vorgängen das manuelle Eingreifen eines Benutzers erforderlich.



### 3.1.1 Aufbau von Funktionsmuster 1

Abbildung 3-1 zeigt das erarbeitete Funktionsmuster 1 für Laborversuchszwecke. Die Anregung der Getränkekästen durch den elektrodynamischen Schwingerreger erfolgt, wie sich in Vorversuchen und den numerischen Simulationen als beste Methode erwies, vertikal, zentral von unten im Symmetriezentrum der Getränkekästen.



Abbildung 3-1: Funktionsmuster 1

1. Laservibrometer
2. Pneumatische Arretierungsvorrichtung
3. Elektrodynamischer Schwingerreger (Shaker)
4. Prüfling
5. Anlagenregelung und Datenverarbeitung

Eine Anregung am elastischen Kastenboden hat den Vorteil, dass sich die Schwingung über das Gefache und den Boden symmetrisch auf die steifen Seitenteile und die Griffleisten ausbreitet. Eine Beschädigung in diesem Teil des Kastens verändert somit deutlich die Übertragung der Anregung auf die Seitenteile und ist daher auch im Griffbereich noch gut detektierbar. Bei einer Anregung am relativ steifen Außenbereich wäre dies in deutlich geringerem Ausmaß der Fall. Bei einem maximalen Hub von ca. 2 mm beschleunigt der Shakerstößel in 2 ms auf ca. 400 m/s<sup>2</sup> (vgl. Abbildung 3-2). Die dabei wirkende Kraft drückt den Kastenboden in einem Radius von 5 cm um das Symmetriezentrum ein und erzeugt dadurch eine Verformung der Geometrie. Da es sich dabei um eine Verformung im elastischen Bereich des Kas-

tens handelt, wirkt er dieser entgegen und nimmt, nachdem keine Kraft mehr anliegt, nach ca. 200 ms seine ursprüngliche Ausgangslage und -form wieder ein. Die Dauer der Anregung und der daraus resultierenden Schwingung liegt damit mit 0,2 s bei einem Fünftel der zur Verfügung stehenden Zeit von 1 s.




Abbildung 3-2: Beschleunigungsverlauf im Shaker-Stößel

Eine definierte, reproduzierbare Anregung des Getränkekastens sowie die zuverlässige Erfassung der Schwingungsantwort am vorgegebenen Messort erfordern die kurzzeitige Arretierung des Prüflings für die Dauer des Messvorganges. Abbildung 3-3 zeigt die im Labormaßstab entwickelte Arretierungsvorrichtung. Die Fixierung des Getränkekastens (5) erfolgt hierbei über zwei Klemmbacken (2), die mit Hilfe von Druckluftzylindern (3) horizontal entlang der Klemmbackenführungen (1) gleiten.




Abbildung 3-3: Vorrichtung zur schnellen Kastenarretierung

Ein speziell an die Kastenform angepasstes Schrägprofil (45°) auf den Klemmböcken drückt beim Arretierungsvorgang auf die ca. 1 cm überstehende Bodenleiste des Kastens. Durch die schrägen Pressflächen wirkt die eingebrachte Kraft auch in vertikaler Richtung nach unten und presst den Kasten auf die Bodenplatte (vgl. Abbildung 3-4). Bei einem Kolbendruck von ca. 4 bar wirkt die Arretierung der Verschiebung des Prüflings erfolgreich entgegen und gewährleistet somit eine zuverlässige Datenaufnahme im Messpunkt (4) auf der Griffleiste.




Abbildung 3-4: Schema der Kastenarretierung

Die Einspannung der Getränkekästen geschieht bei diesem Funktionsmuster manuell. Das heißt, die pneumatisch betriebene Klemmbackenvorrichtung wird durch das Öffnen eines Ventils auseinander gefahren und der zu untersuchende Getränkekasten auf der Basisplatte in der Mitte platziert. Das Schließen des Ventils setzt die Schubkolben der Klemmbackenvorrichtung unter Druck (ca. 5 bar) und bewegt diese in Richtung Plattenmitte auf den Getränkekasten. Mit speziell angepassten Zentrierhilfen, die durch das Gefache des Getränkekastens in dafür vorgesehene Bohrungen in der Basisplatte gesteckt werden, ist es möglich, die Position der Prüflinge exakt zu definieren, so dass reproduzierbare Versuchsbedingungen herrschen. Zum einen ist dadurch ein zentrischer Stoß des Shakers gewährleistet, zum anderen liegt der Fokus des Laservibrometers immer an der gleichen Stelle in der Mitte der kurzen Griffleiste des Prüflings. Kleine Abweichungen von diesen idealen Positionen entstehen durch die Verschiebung der Klemmbacken, aber auch durch die variierenden Abmessungen der Prüflinge, welche aber im vorgegebenen Toleranzbereich liegen. Die eigentliche Messung startet durch manuelles Auslösen der Messprozedur im Steuerungs- und Messwertaufnahme-Programm. Dabei befinden sich alle Teile der Versuchsapparatur statisch in der vorgesehenen Position. Nur der Stößel des Shakers führt die beschriebene Bewegung aus, um den Kasten in Schwingung zu versetzen. Ein störender Einfluss der Umgebung, z.B. durch Maschinenvibrationen, ist hierbei auszuschließen.

Die Eigenschwingungen der Versuchsapparatur sind durch deren massive Stahlkonstruktion und die zusätzliche Gewichtskraft des Schwingerregers auf ein Minimum reduziert und wirken sich nicht negativ auf die Schwingungen des Getränkekastens aus. Diese Schwingungen treten in jedem aufgenommenen Spektrum als nichtinformatives Rauschen auf. Eine Abtrennung durch Signalfilter wäre möglich, ist aber unnötig, da keine negative Beeinträchtigung der Auswertung durch die neuronalen Netze auftritt.

Bei der Erfassung der Schwingungsantwort steht neben der Forderung nach Schnelligkeit und Robustheit das einfache Bedienen an oberster Stelle. Die auf dem Dopplereffekt basierende Laservibrometrie genügt den gestellten Anforderungen an das entwickelte Sensorsystem sowohl im Labor als auch im darauf folgenden Feldeinsatz. Der eingesetzte Einpunkt-Messkopf OFV-505 (siehe Abbildung 3-1, Pos. 1) der Firma Polytec arbeitet mit einem Helium-Neon-Laser (Laserklasse 2) und ermöglicht zuverlässig die exakte Erfassung kleinster Bewegungen (80 nm) selbst bei großem Abstand zum Messobjekt. Der dazu benötigte Vibrometer-Controller OFV-5000, ausgestattet mit Bewegungs- und Geschwindigkeitsdecodern sowie verschiedenen Signalfiltermodulen, dient zur Transformation und Weiterverarbeitung des

Signals und stellt dieses als Spannung am Ausgang bereit. Eine große Auswahl an verschiedenen Messbereichen sowie die flexible Parametrierung der Filtermodule (z.B. Hoch, Tiefpassfilter) ermöglichen die optimale Anpassung an die Schwingungsantwort der untersuchten Prüflinge.

### 3.1.2 Anlagensteuerung von Funktionsmuster 1

Die Steuerung und Messdatenerfassung erfolgt nach folgendem Schema:




Abbildung 3-5: Anlagenschema von Funktionsmuster 1

1. Prüfling
2. Laservibrometer
3. Elektrodynamischer Schwingerreger
4. Stößel mit Beschleunigungssensor
5. Vibrometercontroller
6. Shakercontroller
7. Verstärker
8. Konnektorblock
9. PC mit Schnittstellenkarte
10. Manuelle Arretierung

Der elektrodynamische Schwingerreger V550 der Firma Ling-Dynamic Systems (LDS) (3) wird über den zugehörigen Mikrocontroller Dactron Laser (6) und den Feldverstärker PA500L (7) gesteuert. Nachdem die Parametrierung über eine graphische Benutzeroberfläche abgeschlossen ist, erfolgt die Übertragung der Parameter über eine USB-Schnittstelle an den Controller. Eine echtzeitfähige Schwingprüfung ist durch den ausfallsicheren Controller jederzeit gewährleistet, da dieser vom PC unabhängig arbeitet. Der Prüfungsbeginn sowie eine Prüfungsunterbrechung sind vom Benutzer zu initiieren. Ein Beschleunigungssensor, der am Stößel des Shakers angebracht ist, dient zur aktiven Kontrolle der Schwingbewegung und liefert die Daten zur graphischen Echtzeit-Darstellung der Schwingbewegungen am PC. Die shakereigene Parametriersoftware ist zusätzlich über eine Active-X-Schnittstelle für andere

Programme zugänglich. Dadurch ist eine Integration der Shakersteuerung in LabVIEW möglich und die Messdaten vom Sensor (4) stehen für weitere Auswertungen zur Verfügung. Der Controller für das Laservibrometer ist ebenfalls über eine serielle Schnittstelle zugänglich, und vom PC aus bedienbar. Die Fokussierung des Lasers oder die Einstellung des Messbereiches können sowohl am Controller oder aber über das Lab-VIEW-Programm erfolgen. Die Messdaten des Laservibrometers stehen von den jeweiligen Decodern im Controller in Form von Spannungssignalen zur Verfügung. Diese liegen in einem Spannungsintervall von +/- 10 Volt und sind zur gemessenen Bewegung proportional. Die Signalaufnahme erfolgt über den mit der Messkarte verbundenen Konnektorblock. Nach dem Einlesen der analogen Spannung erfolgt in LabView je nach Signalart die Umrechnung in eine Beschleunigung, Geschwindigkeit oder Verschiebung. Das Laservibrometer liefert fortwährend Schwingungsdaten vom Prozess, aus denen in LabView eine Extraktion des relevanten Signals erfolgt. Große Amplituden im Beschleunigungssignal dienen als Indikator für die Anregung des Kastens und somit als Startpunkt. Die Länge des Zeitfensters, in dem die Schwingung abklingt, beträgt immer ca. 0,2 s. Das erhaltene Rohsignal dient anschließend der Weiterverarbeitung und Auswertung.

## **3.2 Funktionsmuster 2 - Feldversuchsanlage**

Um die aus zahlreichen Messreihen und Auswertungen gewonnenen Erkenntnisse in einem praxistauglichen Schadenserkennungsaggregat zu realisieren, ohne dabei in der Konstruktions- und Testphase den laufenden Abfüllbetrieb eines Getränkeherstellers zu stören, wurden die Experimente an einem Versuchsrundläufer durchgeführt. Die hier herrschenden Umgebungsbedingungen entsprechen annähernd realen Gegebenheiten. Außerdem bestand so die Möglichkeit, verschiedene Testszenarien mit variierenden Umgebungsbedingungen ausgiebig zu testen.

### **3.2.1 Störende Randbedingungen in rauer Feldebene**

Da in einer realen Abfüllanlage ständig Vibrationen auftreten, ist es von großer Bedeutung, diese Schwingungen im Vorfeld zu charakterisieren. Wenn Fremdschwingungen sich auf den Kasten und die Messapparatur übertragen, verfälschen sie das gemessene Frequenzspektrum und können bei unvorbereiteten Systemen zu Abweichungen in den Klassifizierungsergebnissen führen. Abbildung 3-6 und Abbildung 3-7 zeigen eine mit dem Laservibrometer gewonnene Momentaufnahme der Schwingung der Transportketten eines Kastenförderers im Zeit- und Frequenzbereich.




Abbildung 3-6: Schwingungen von Transportketten in einem Kastenrundläufer  
(zeitlicher Verlauf der Beschleunigung)




Abbildung 3-7: Schwingungen von Transportketten in einem Kastenrundläufer  
(Frequenzspektrum)

Abbildung 3-7 verdeutlicht, dass die Anregungsintensität, insbesondere im Frequenzbereich unter 200  $\text{Hz}$ , die der Vibration der Transportketten (außer bei der Eigenfrequenz des Fördermittels bei 40  $\text{Hz}$ ) um deutlich mehr als eine Größenordnung übersteigt. Die konstruktive

Ausgestaltung der Kastenarretierung entkoppelt zudem den Kasten durch anheben vom Förderstrom und verhindert dadurch die Übertragung der Vibration auf den Kasten. Somit sind die Einflüsse der Umgebung auf den Prüfling weitestgehend ausgeschaltet.

### 3.2.2 Aufbau von Funktionsmuster 2

Abbildung 3-8 zeigt den prinzipiellen Aufbau von Funktionsmuster 2 aus drei verschiedenen Perspektiven. Dieser Aufbau ist freistehend und somit nahezu von der restlichen Anlage abgekoppelt. Hierdurch wird die direkte Übertragung störender Schwingungen bestmöglich unterdrückt. Einer Schwingungsübertragung über den Boden ist zudem durch den Einsatz von Puffern an den Beinen der Vorrichtung vorgebeugt.




Abbildung 3-8: Getränkekasteninspektor

Die Arretierungselemente zum definierten Anpressen der Prüflinge zeigt Abbildung 3-9. Mit Hilfe der zylinderförmigen Profile kann somit ein Kasten festgehalten und der Schwingprü-



fung unterzogen werden. Da sich die Arretierungsköpfe nur  $90^\circ$  um ihre eigene Achse drehen, ist diese Fixier Vorrichtung unanfällig gegenüber Störungen. Des Weiteren geschieht das Öffnen und Schließen in Bruchteilen einer Sekunde ( $t < 0.1 \text{ s}$ ) und beeinträchtigt daher nicht die für den Praxiseinsatz geforderte Taktzeit.




Abbildung 3-9: Kastenarretierung

Die Anregung des Prüflings geschieht - wie auch in der Laboranlage - weiterhin mit einem Shaker, der einen Schockimpuls von unten auf den Kasten ausübt. Da ein elektrodynamischer Shaker aufgrund seiner Baugröße nicht in das System integrierbar ist, kommt hierbei ein pneumatisch betriebenes Modell der Firma Netter-Vibration zum Einsatz (siehe Abbildung 3-10). Dieser Shaker hat zwei Druckluftanschlüsse, dadurch sind der Vorschub- und der Rückstelldruck frei einstellbar. Die Differenz der beiden Drücke stellt den wirkenden Druck dar, der den Kolben effektiv nach oben treibt. Liegt der Rückstelldruck nahe dem Vorschubdruck bewegt sich der Kolben sehr langsam. Bei zunehmender Druckdifferenz vergrößert sich die Geschwindigkeit des Stößels. Sobald der Vorschubdruck wegfällt, wirkt der Rückstelldruck und bringt den Anschlagkolben in seine Ausgangstellung zurück: je höher der Druck, desto höher die Geschwindigkeit. Bei optimaler Einstellung lässt sich so ein kurzes Anregungssignal, aber auch die schnelle Rückstellung des Anregungskopfes, realisieren. Für die Verwendung dieses Shakersystems spricht neben der geringen Baugröße auch seine niedrige Störungsanfälligkeit, gerade in der relativ feuchten Umgebung einer Abfüllanlage.



Abbildung 3-10: Pneumatischer Shaker

Abbildung 3-11 zeigt den Kasteninspektor integriert in einen Kastenförderer. Die Einzelbilder stellen ein Prüfszenario mit den auszuführenden Einzelschritten dar. Der Kasten läuft auf den Ketten über die einzelnen Stationen, wie z. B. die Kastenreinigungsmaschine oder den hier neu integrierten Kasteninspektor, von der Auspack- zur Einpackmaschine. Zuerst muss der Kasten an einer genau definierten Position anhalten. Dies geschieht über zwei pneumatisch betriebene Stopplatten, die aus- und einfahrbar sind. Danach erscheint von unten durch die Zwischenräume des Förderers eine pneumatisch betriebene Hebevorrichtung, die den Kasten vom Förderer abhebt. Zugleich fixieren die Arretierungsköpfe den Kasten auf der Hebevorrichtung. Sofort danach erfolgt die Anregung durch den pneumatischen Shaker und die Erfassung der daraus resultierenden Schwingung mit dem integrierten Laservibrometer. Nachdem die Messung abgeschlossen ist, öffnet sich die Arretierungsvorrichtung und der Kastenlift fährt nach unten. Dadurch setzt der Getränkekasten auf den Förderbändern auf und wird von diesen durch die zwischenzeitlich geöffneten Stopplatten weiter transportiert. Durch gezielte Vereinzelung der Getränkekästen auf den Förderbändern sollte sich beim Verlassen des geprüften Kastens der nächste Prüfling bereits vor dem Kasteninspektor befinden, so dass die Prozedur von neuem beginnen kann.




Abbildung 3-11: Arbeitsablauf des Kasteninspektors

### 3.2.3 Anlagensteuerung von Funktionsmuster 2

Die Anlagensteuerung des industrietauglichen Funktionsmusters 2 kann man in zwei Aufgabengruppen unterteilen. Die erste Aufgabe besteht, wie bei Funktionsmuster 1, darin, den Getränkekasten durch einen definierten, vertikalen Schlag von unten in Schwingung zu versetzen und die daraus resultierende Schwingantwort des Kastens mit Hilfe des Laservibrometers aufzunehmen. Die zweite Aufgabe besteht darin, den Kasten aus dem Beförderungsfluss der Getränkeabfüllanlage für den Zeitraum der Messung automatisch in einer definierten Position zu fixieren und ihn danach wieder in den Materialfluss einzuschleusen. Eine exakte Positionierung ist auch hier von essentieller Bedeutung, da die Fokussierung des Laserstrahls auf die Griffleiste und somit das Messsignal davon abhängt. Die definierte Positionierung des Getränkekastens geschieht mit Hilfe von Lichtschranken und Schrägprofilen. Eine schematische Darstellung hierzu illustriert Abbildung 3-12.




Abbildung 3-12: Schematischer Aufbau der Kastenpositionierung

Der Kasten bewegt sich in der Illustration auf den Kastenförderbändern (2) in Materialflussrichtung von rechts nach links. Dabei passiert er die erste Lichtschranke (1) und unterbricht den Lichtstrahl. An den Halteplatten (4), die sich zu diesem Zeitpunkt in einer Position über den Bändern befinden, hält der Kasten an. Die Bänder schleifen in konstanter Geschwindigkeit unter dem Kasten durch. Die kurzzeitige Unterbrechung der Lichtschranke sowie die darauf folgende Freigabe dienen dem Steuerungsmechanismus als Anzeichen für einen wartenden Prüfling. Dieser wird mit dem Kastenlift (5) vertikal vom Band abgehoben und währenddessen mit den Klemmbacken fixiert. Sobald das Messsignal des Laservibrometers (3) einen völligen Stillstand des Getränkekastens anzeigt, erfolgt die Anregung sowie die Messdatener-

fassung. Nach Abschluss dieses Vorganges öffnen sich die Halteplatten (4) sowie der Arretierungsmechanismus und der Kastenlift fährt nach unten. Der Getränkekasten setzt dadurch auf den Förderbändern auf und bewegt sich in Materialflussrichtung weiter durch die Austrittslichtschranke. Ist diese Lichtschranke wieder frei und das System von neuem aktiviert, kann der nächste Kasten die Lichtschranke passieren. Um sicherzustellen, dass kein Getränkekasten die erste Lichtschranke passiert so lange sich noch ein Kasten im Messbereich (zwischen Lichtschranke 1 und 2) befindet, erfolgt zuvor eine Vereinzelung der Prüflinge. Dies geschieht in der Abfüllanlage durch unterschiedlich schnelle Transportbänder. Der dadurch erzeugte Abstand zwischen den Kästen ist so groß, dass der jeweils nächste Prüfling die Messstation erst erreicht, wenn der aktuelle Prüfling den Messbereich verlassen hat. Alternativ wäre die Installation eines zweiten Kastenstoppers vor der Messstation denkbar.

Die in diesem Abschnitt vorgestellten Materialien und Methoden schaffen eine tragfähig Grundlage um eine automatisierte Schadenerkennung - auch unter praxisähnlichen Randbedingungen - umzusetzen. Dabei zeigt sich, dass mit Hilfe der vorgestellten Methode das in Abschnitt 1 vorgestellte Forschungsziel erreicht und die gestellten industriellen und wirtschaftlichen Anforderungen erfüllt werden können.

Der folgende Abschnitt belegt die physikalisch-technische Machbarkeit des hier verfolgten Konzeptes.

## 4 Vorstellung und Diskussion der Ergebnisse

In diesem Teil der Arbeit folgen die Präsentation der Ergebnisse sowie deren Diskussion und die Schlussfolgerung aus ableitbaren Erkenntnissen. Wie im Verlauf des Projektes handelt der erste Abschnitt die numerischen Simulationen zur Schaffung der Grundlagen und zur Gewinnung von Informationen ab. Dabei steht die Entwicklung der Methode zur Schadenserkennung im Fokus der Untersuchungen. Die Anwendung eines Schocksignals zur Schwingungsanregung als zwingende Maßnahme zur Reduzierung der Untersuchungsintervalle aus den industriellen Anforderungen sowie die optimale Fixierung der Getränkekästen und die Bestimmung einer geeigneten Messposition zur Erfassung der Schwingantwort sind dabei Gegenstand der Analysen. Diese Erkenntnisse sind Basis für den experimentellen Teil der Arbeit, der sich um die Planung, Konstruktion und Inbetriebnahme der Versuchsanlagen dreht.

Zu Beginn der experimentellen Arbeiten entstand ein Versuchsstand im Labormaßstab, in dem die gewonnenen Erkenntnisse aus dem numerischen Teil Anwendung finden. Hauptaugenmerk lag dabei noch nicht auf der industriellen Integrationsfähigkeit in ein Linienaggregat, sondern auf der generellen Anwendbarkeit der Methode auf die Getränkekästen. Neben der Anregung durch einen elektrodynamischen Schwingerreger und der Fixierung der Prüflinge durch pneumatisch betriebene Klemmbacken stellte hierbei die Einführung der berührungslosen Schwingungserfassung mit Hilfe eines Laservibrometers die Herausforderungen dar. Durch die Weiterentwicklung des Laborversuchsstandes konnten anschließend unter vereinfachten industriellen Bedingungen weitere Untersuchungen durchgeführt werden. Auf dieser Basis entstand Funktionsmuster zwei, welches ein industrietaugliches Linienaggregat darstellt. Gegenstand dieser Entwicklung ist die Anwendung der vorgestellten Methode im industriellen Umfeld unter Berücksichtigung der daran geknüpften Anforderungen. So steht z.B. für die Untersuchung eines Prüflings jeweils ein Zeitfenster von einer Sekunde zur Verfügung.

Der letzte Abschnitt dieses Kapitels erläutert die Ergebnisse der dritten Projektphase, die als Themenkomplex die Auswertung der gewonnenen Informationen aus den Experimenten behandelt. Dabei stehen Künstliche Neuronale Netze, als zentrales Element der Datenauswertung, sowie die verschiedenen Datenverarbeitungsverfahren im Fokus. Auswirkungen der KNN-Topologie sowie der Datenvorverarbeitung auf die Qualität der Zustandsprognosen der Getränkekästen finden hier Erläuterung.

## 4.1 Ergebnisse der numerischen Simulation

Der erste Teil dieses Unterkapitels beschäftigt sich mit der Fragestellung, wie ein Versuchstand prinzipiell realisierbar ist und ob Schäden an den Untersuchungsobjekten damit detektierbar sind. Diese Darstellung von grundlegenden Erkenntnissen geschieht anhand der Ergebnispräsentation aus Simulationen mit Getränkekastenmodell 2. Anschließend erfolgt die Erläuterung der Ergebnisse aus Simulationen mit Versuchskastenmodell 1. Diese zeigen die Feinabstimmungen der Simulationen und deren Übertragbarkeit auf einen realen Versuchstand. Ein Vergleich verschiedener Schadensbilder zeigt auf, ob KNN in der Lage sind anhand der aufgenommenen Daten eine Klassifizierung des Zustandes der Getränkekästen vorzunehmen.

### 4.1.1 Eigenmoden

Grundsätzlich ist die Zahl der berechenbaren Eigenmoden eines Modells so groß wie dessen Anzahl an Freiheitsgraden einschließlich aller Translations-, Rotations- und Festkörperbewegungen. Der größte Teil dieser Moden tritt aber nicht messbar in Erscheinung [47-49]. Ihre Richtung und Stärke ist deswegen vernachlässigbar. Mit Hilfe der Eigenmoden bzw. der Eigenfrequenzen können grundlegende Erkenntnisse über das Schwingungsverhalten des Kastens gewonnen werden. In den folgenden Abbildungen sind einige ausgewählte Eigenformen illustriert. Um die Abweichungen von der ursprünglichen Geometrie zu verdeutlichen, ist jeweils ein FEM-Netzmodell unterlegt, das die Ruheposition wiedergibt. Zusätzlich sind die Verformungen bzw. die dimensionslosen Amplituden der Eigenvektoren farblich skaliert dargestellt.

Bei der ersten auftretenden Eigenform schwingt das System Getränkekasten mit einer Eigenfrequenz von 40,26 Hz. Dabei bewegen sich die jeweils gegenüberliegenden Ecken aufeinander zu bzw. voneinander weg (Abbildung 4-1, links). Regt man den Getränkekasten bei höheren Frequenzen an, setzt eine Schwingung der Seitenteile, bevorzugt im oberen Bereich, ein. Bei einer Anregungsfrequenz von 164,73 Hz schwingen die Vorder- und die Rückseite synchron, während auf der linken und rechten Seite nur eine geringe Reaktion zu beobachten ist (Abbildung 4-1, rechts). Mit einer etwas höheren Frequenz von 198,3 Hz dagegen zeigen auch die linke und die rechte Seite Eigenformen. Dies kann man auch bei 209,9 Hz, einer weiteren Eigenfrequenz, beobachten. Hier bewegen sich alle vier Seiten gegengleich (Abbildung 4-2).

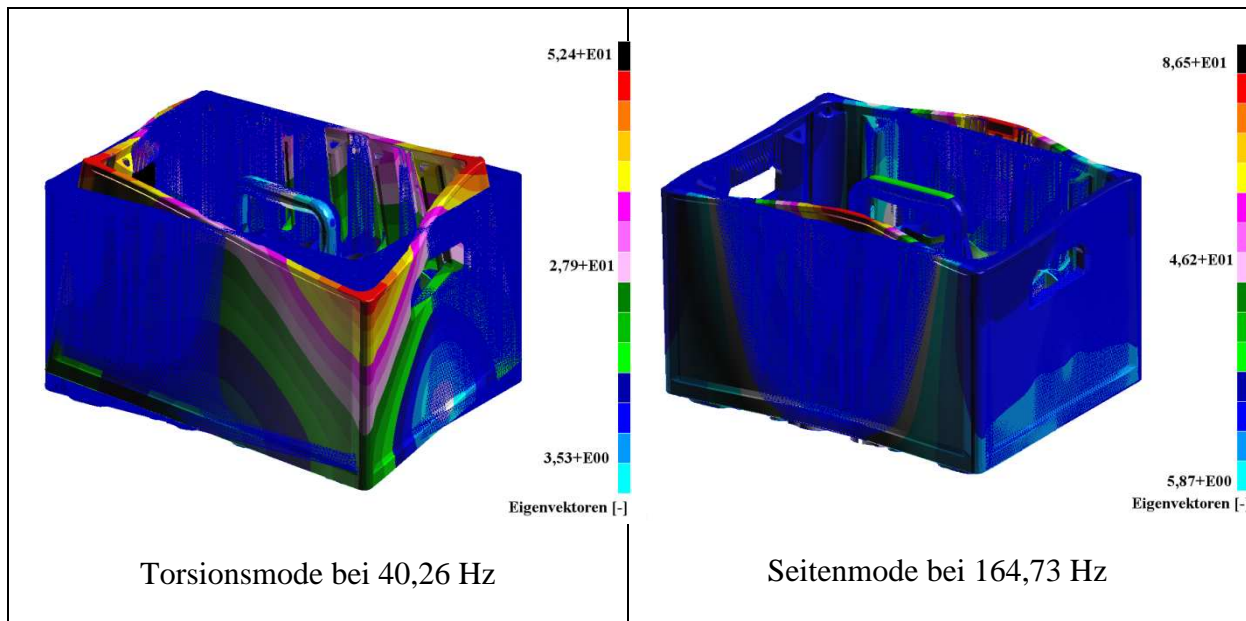


Abbildung 4-1: Auswahl von Eigenmoden des Getränkekastens berechnet mit Hilfe der numerischen Modalanalyse auf Basis der FEM




Abbildung 4-2: Auswahl von Eigenmoden des Getränkekastens berechnet mit Hilfe der numerischen Modalanalyse auf Basis der FEM

Schwingt das System mit höheren Frequenzen, nimmt die Anzahl der Schwingungsbäuche zu (Abbildung 4-3). Während bei den Frequenzen unter 200 Hz nur ein Bauch zu beobachten ist, treten bei 225,25 Hz und 284,62 Hz auf jeder Seite jeweils zwei Schwingungsbäuche auf. Es zeigt sich, dass z. B. bei 164,67 Hz die Mitte der Vorderseite als Sensorposition wegen der großen Auslenkung sehr gut geeignet ist. Dagegen ist die Reaktion bei z.B. 225,29 Hz, trotz der großen Auslenkung links und rechts, in diesem Punkt sehr gering.



Wie Abbildung 4-3 verdeutlicht, fangen bei höheren Frequenzen zusätzlich die Gefache im inneren des Getränkekastens sowie der Mittelgriff zu schwingen an. Auch hier treten einfach und mehrfach Schwingbäuche in gleicher oder entgegengesetzter Richtung auf.

Mit steigender Frequenz werden die Wellenlängen kleiner und die Zahl der Schwingungsknoten (Nulldurchgang einer Welle) auf einem Kastenabschnitt steigt. Die Schwingungsbäuche weisen hierbei größere Amplituden als die Knotenpunkte auf. Dies ist für die Wahl einer geeigneten Sensorposition von großer Bedeutung.

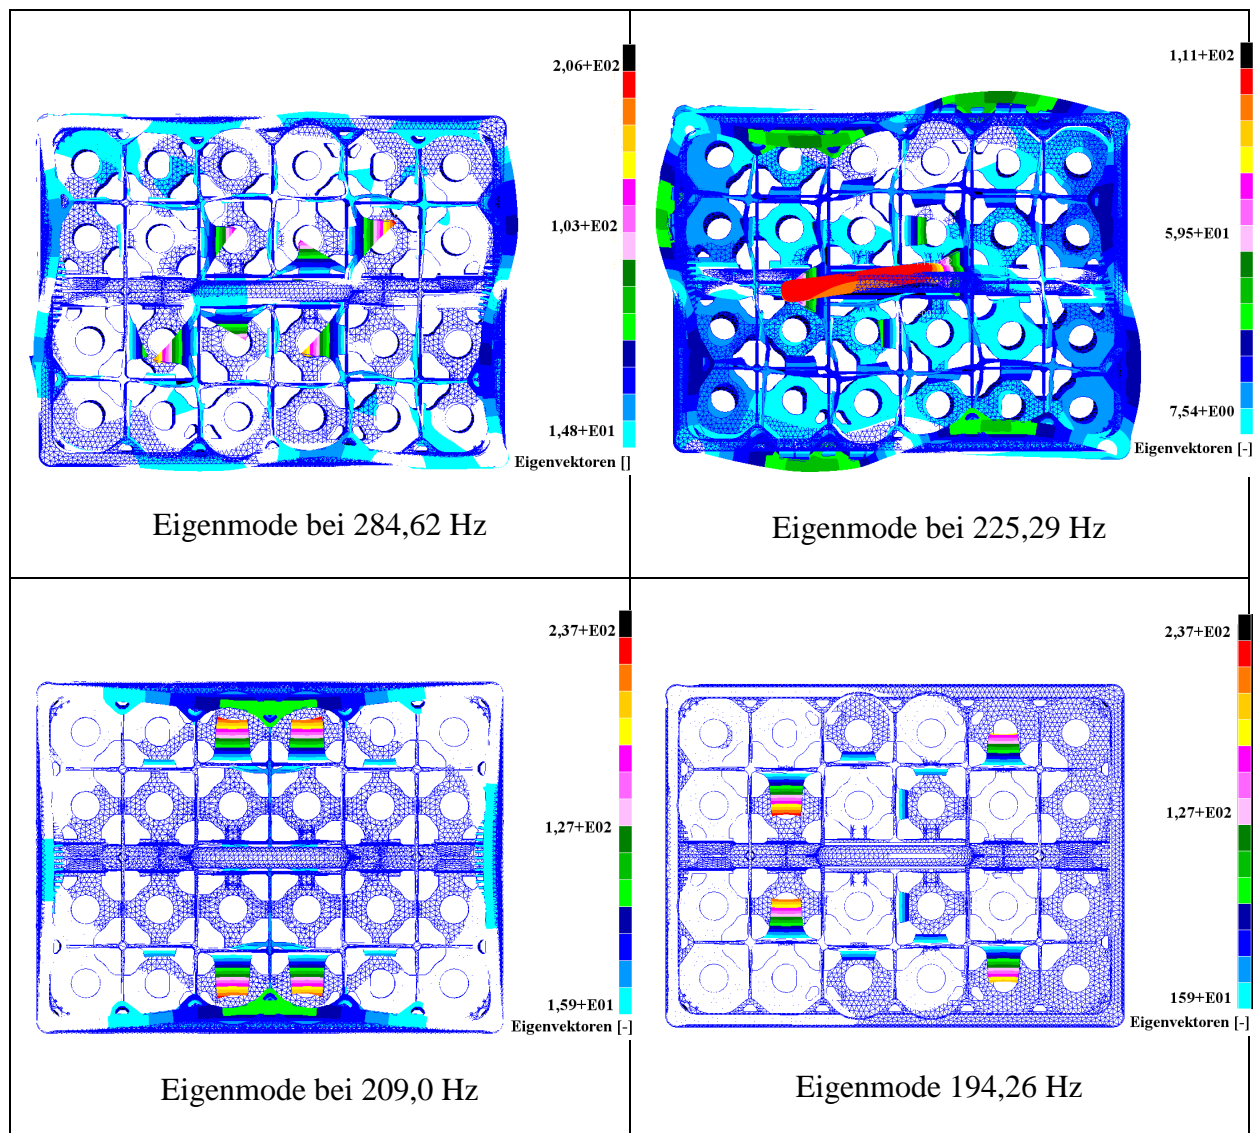


Abbildung 4-3: Auswahl von Eigenmoden des Getränkekastens berechnet mit Hilfe der numerischen Modalanalyse auf Basis der FEM

## 4.1.2 Definition der Versuchsparameter für die numerischen Simulationen

Wie in Kapitel 2.3 erläutert spielen die Versuchsparameter neben dem eigentlichen Modell eine große Rolle bei der Simulation. Der Ort und die Art der Schwingungsanregung sowie die Fixierung des Getränkekastens aber auch die anschließende Auswertung ausgewählter Bewegungsinformationen sind dabei zu berücksichtigen.

### 4.1.2.1 Anregungsorte

Die Wahl der Kraftangriffspunkte zur Einleitung des Anregungsimpulses erfolgt nach Gesichtspunkten der konstruktiven Umsetzbarkeit. Als Anregungsorte bzw. Angriffspunkte der Kraft werden aus diesem Grund zur Modellierung die in Abbildung 4-4 mit blauem Pfeil gekennzeichneten Positionen untersucht. Die Wirkungslinien der Kraft stehen dabei jeweils senkrecht zu den Angriffsflächen.




Abbildung 4-4: Untersuchte Positionen E1, E2, E3 zur Schwingungsanregung

Gängige Kenntnisse aus der Strukturanalyse [49, 118, 121] zeigen, dass die Annahmen von Punktbelastungen bei Konstruktionen zu überhöhten Verformungen führen. Damit in der vorliegenden Arbeit keine unrealistisch großen Verformungen bzw. Verschiebungen zustande kommen, wurden die Kräfte nicht in einem einzelnen Knotenpunkt sondern als Flächenlast auf die Oberfläche von mehreren aneinander liegenden Elementen eingeleitet. Dies entspricht im Experiment dem Durchmesser des Anregungsstößels. Die Angriffspunkte unterscheiden sich sehr stark durch die an dieser Stelle vorliegende Steifigkeit des Getränkekastens.

Während Position E3 an der Kante des Prüflings eine versteifte Stelle repräsentiert und somit die Anregungskraft sehr gut auf den Kasten überträgt, sind E1 und vor allem E2 eher weiche Stellen, die sich durch das Einwirken der äußeren Kraft stärker verformen und diese dadurch abdämpfen.

#### 4.1.2.2 Anregungssignal

Den zeitlichen Verlauf der am Anregungsort wirkenden Beschleunigung zeigt Abbildung 4-5. Hier wirkt während einer relativ kurzen Zeitdauer von 4 ms eine maximale Beschleunigung von ca. 400 m/s<sup>2</sup> auf den Prüfling ein.




Abbildung 4-5: Zeitverlauf des Anregungssignals

Idealerweise besitzt die Anregung die Form eines einzelnen Halbsinusimpulses. Die gemessene tatsächliche Beschleunigung des Stößels zeigt jedoch außerhalb des eigentlichen Anregungssignals zusätzliche Bewegungen, welche die Messung beeinflussen. Um das spezifizierte Signal exakt umzusetzen und die nötige Beschleunigung erreichen zu können, führt der Stößel leichte Vorbewegungen aus. Nach dem eigentlichen Impuls sind Nachschwingungen nicht völlig vermeidbar. Da der Stößel in Ruhelage direkt am Prüfling anliegt, wirkt jede Bewegung nach oben als Schwingungsanregung. In der Simulation wird somit ein auf der Grundlage der realen Beschleunigung erstellter Kraftverlauf ebenfalls mit mehreren Impulsen eingesetzt. Bei der Anregung ist zu beachten, dass nur die positiven Beschleunigungen des

Stößels auf den Prüfling wirken. Abweichungen von der realen funktionellen Abhängigkeit begründen sich in der Idealisierung des Modells, um den zur Erhaltung der Linearität der Simulation nicht modellierten Wechselwirkungen mit dem Boden des Versuchsstandes Rechnung zu tragen. Offensichtlich werden im Versuch hohe Frequenzen stärker angeregt als in der Simulation mit der direkt übernommenen Anregungsfunktion. Kürzere Schockimpulse gleichen dies aus. Bei Simulationsläufen mit höheren Kräften aber gleichem Verlauf vergrößern sich die Amplituden der Schwingungsantwort proportional, da für die FE-Simulation lineares Verhalten vorausgesetzt wird. Die Betrachtung des Anregungssignals im Frequenzbereich (vgl. Abbildung 4-6) zeigt, dass sein Frequenzinhalt den Bereich von 0 – 2 kHz abdeckt. Die Intensität der Schwingungen nimmt aber zu höheren Frequenzen hin stark ab. Dieses Erscheinungsbild findet sich auch in den Antwortspektren der Kästen und in den Differenzsignalen wieder. So kann eine Anregung der in diesem Bereich liegenden Eigenfrequenzen des Kastens realisiert werden.




Abbildung 4-6: Fouriertransformiertes Anregungssignal

#### 4.1.2.3 Fixierung des Getränkekastens

Damit der Getränkekasten aufgrund der Stoßanregung seine Lage im Raum nicht verändert, erfolgt, wie auch im realen Versuchsaufbau, eine Fixierung. Der Kasten soll sich, nachdem die Schwingung abgeklungen ist, wieder in seiner ursprünglichen Ausgangslage befinden.

Hierzu dient eine am unteren Saum auf der Vorder- und Rückseite (vgl. Abbildung 4-7, grauer Balken) angebrachte Klemmbackenvorrichtung. Diese bewirkt eine Einschränkung der Bewegungsfreiheit der Knotenpunkte auf der Oberfläche des Kastens analog zum realen Experiment.




Abbildung 4-7: Fixierung des Getränkekastens

#### 4.1.2.4 Signalerfassung auf dem Getränkekasten

Die für die Experimente vorgesehene Signalerfassung zieht in der Simulation zwei Einschränkungen nach sich. Da das eingesetzte Laservibrometer nur Bewegungen der Objekt-oberfläche in Richtung des Laserstrahles erfassen kann, findet in den Auswertungen der Simulationsergebnisse nur diese Komponente Berücksichtigung.

Weiterhin erfolgt wegen der hohen anfallenden Datenmenge (ca. 60 GB pro Simulation) eine Einschränkung bei der Protokollierung der Bewegungsvektoren. Das Simulationsprogramm ist so konfiguriert, dass es nur die Ergebnisse der Punkte ausgibt, welche auf der Oberfläche einer der vier von außen sichtbaren Seiten und dort innerhalb definierter Quadrate liegen. Die Anzahl der betrachteten Knotenpunkte konnte so von 751.729 auf ca. 5000 reduziert werden. Zum besseren Verständnis zeigt Abbildung 4-8 die auf der Vorderseite des Kastens erfassten Knotenpunkte.




Abbildung 4-8: Sensorpunkte zur Erfassung des Schwingverhaltens

Bei diesen Einschränkungen handelt es sich lediglich um die Verringerung der zur weiteren Auswertung gespeicherten Datenmenge. Dies hat keine Auswirkungen auf die Berechnungsverfahren bzw. deren Genauigkeit. Für alle berechneten Modelle bleiben die Materialparameter konstant, d. h. Alterungseffekte finden vorerst keine Berücksichtigung. Modellmäßig finden nur Änderungen an der Geometrie statt, um Beschädigungen zu imitieren.

### 4.1.3 Numerische Simulation des Schwingungsverhaltens eines Getränkekastens

Die Informationen der numerischen Simulation des Schwingungsverhaltens von Getränkekästen lassen aussagekräftige Schlüsse über die Verfassung eines Prüflings zu. Die Geometrie der Getränkekästen ist dabei in finite, diskrete Elemente unterteilt, die durch Knotenpunkte definiert sind. Die Bewegung der Knotenpunkte liegt am Ende der Simulation als Vektortabelle mit äquidistantem Zeitstempel zur Auswertung vor. Eine Fourier-Transformation wandelt die zeitabhängigen Ortsinformationen in ein frequenzabhängiges Amplitudenspektrum um, das als Grundlage weiterer Verarbeitungsschritte dient.

In Abbildung 4-9 sind exemplarisch die Amplitudenspektren eines Knotens auf der Oberfläche der rechten Seite eines unbeschädigten Kastens des Modells 2 dargestellt. Dabei handelt es sich um die resultierenden Bewegungssignale drei verschiedenartiger Anregungen. Die

Frequenzspektren der Signale verlaufen ähnlich. Die Struktur des Anregungssignals ist deutlich zu erkennen. In der beobachteten Intensität gibt es jedoch größere Abweichungen. Die beiden Anregungssignale E01 und E03 lösen durch ihre horizontale Krafteinwirkung eine Reaktion in gleicher Größenordnung aus, wobei E03 eher höherfrequente, E01 niederfrequente Schwingungen hervorruft. E02 mit einer vertikalen Kraftwirkungslinie dagegen regt den Knotenpunkt deutlich stärker zum Schwingen an, obwohl hier nur Schwingungen in der horizontalen Ebene betrachtet werden.




Abbildung 4-9: Darstellung der Amplitudenspektren eines Knotens auf der rechten Seite eines unbeschädigten Kastens angeregt in unterschiedlichen Kraftangriffspunkten

In Abbildung 4-10 ist das Ergebnis für einen Knotenpunkt auf der Vorderseite von zwei Kästen illustriert, die sich in ihrem Zustand unterscheiden. Es handelt sich dabei um einen Kasten der nicht defekt ist (rote Linie) und einen Getränkekasten, der einen Schaden in der Griffleiste aufweist. Es ist deutlich zu sehen, dass dieser Schaden sich auf das Schwingverhalten des defekten Kastens auswirkt, da sich die Amplituden der Fourierdiagramme unterscheiden.

Wie stark dieser Unterschied ausfällt, zeigt das Differenzsignal, welches im Diagramm als grüne Linie dargestellt ist.




Abbildung 4-10: Darstellung der Frequenz eines unbeschädigten sowie eines beschädigten Kastens und das resultierende Differenzsignal

#### 4.1.4 Ermittlung der besten Sensorposition in Abhängigkeit von Anregungssignal und Fixierung

Auf Basis der erläuterten Verfahren erfolgt in diesem Teil der Arbeit eine Betrachtung des Schwingungsverhaltens eines Getränkekastens bei unterschiedlichen Positionen der Schockanregung. Da es im Gegensatz zur Simulation in der Praxis meist nicht möglich ist, das Antwortsignal des gesamten Kastens zu erfassen, sondern nur wenige Punkte die benötigten Informationen über den Zustand des Prüflings liefern sollen, gebietet es sich vor der aufwändigen Konstruktion eines entsprechenden Messaufbaus zu wissen, wo sich die geeigneten Stellen zur Signalerfassung auf dem Kasten befinden und wo die Stoßanregung einzukoppeln ist. Zu diesem Zweck wurden die Simulationsergebnisse gemäß Kapitel 2.3.5 ausgewertet. Einen systematischen Überblick der durchgeführten Simulationsläufe gibt Tabelle 4-1.



Tabelle 4-1: Übersicht der betrachteten Ergebnisdateien

	<b>S01</b>	<b>S02</b>	<b>S03</b>	<b>S04</b>
E01	1, 2, 3, 4	1, 2, 3, 4	1, 2, 3, 4	1, 2, 3, 4
E02	1, 2, 3, 4	1, 2, 3, 4	1, 2, 3, 4	1, 2, 3, 4
E03	1, 2, 3, 4	1, 2, 3, 4	1, 2, 3, 4	1, 2, 3, 4

*E01, E02, E03 = verschiedene Angriffspunkte der Anregung (vgl. Abschn. 4.1.2.1)*

*S01, S02, S03, S04 = verschiedene Schadensfälle (vgl. Abschn. 2.3.4 bzw. 6.1)*

*1 = Knotenpunkte auf der Vorderseite des Getränkekastens (FRONT) (vgl. Abschn. 4.1.2.4)*

*2 = Knotenpunkte auf der Rückseite des Getränkekastens (REAR) (vgl. Abschn. 4.1.2.4)*

*3 = Knotenpunkte auf der linken Seite des Getränkekastens (LEFT) (vgl. Abschn. 4.1.2.4)*

*4 = Knotenpunkte auf der rechten Seite des Getränkekastens (RIGHT) (vgl. Abschn. 4.1.2.4)*

Bei den hier beschriebenen Simulationen werden lediglich der Kraftangriffspunkt sowie die Beschädigungszustände verändert, um die Auswirkungen bzw. Unterschiede zu detektieren. Aus den einzelnen Kombinationen resultiert jeweils eine Ergebnisdatei pro Seite, die für den visuellen Vergleich grafisch aufbereitet wird. In den einzelnen Grafiken sind die Oberflächen der jeweiligen Seiten bzw. die betrachteten Knotenpunkte dargestellt. Der Koordinatenursprung liegt dabei am Kastenboden auf der Symmetrieachse der Kastenseite. Der Wert für die je Punkt berechnete Kenngröße  $I_A$  ist nach der Regenbogenskala farbcodiert. Die Skalierung erstreckt sich in jedem Diagramm auf den Wertebereich von 0 bis  $I_{Amax}$ . Dies bedeutet, je mehr sich das Schwingverhalten von dem eines unbeschädigten Kastens unterscheidet, desto weiter oben (rot) ist die Farbe des jeweiligen Knotens in der Farbskala zu finden. Eine dunkelblaue Färbung bedeutet demzufolge, dass an dieser Stelle kein Unterschied auftritt. Beim Vergleich zweier Diagramme ist die unterschiedliche Skalierung zu berücksichtigen, da sich die Maximalwerte in den unterschiedlichen Fällen zum Teil stark unterscheiden. Die Abbildungen in den folgenden Abschnitten zeigen zumeist exemplarisch die Verteilung der Kenngröße  $I_A$  auf der Vorderseite des Getränkekastens. Die weiteren Diagramme der Auswertung finden sich im Anhang 6.1.

#### 4.1.4.1 Bruch der Griffleiste - Modellschaden S01

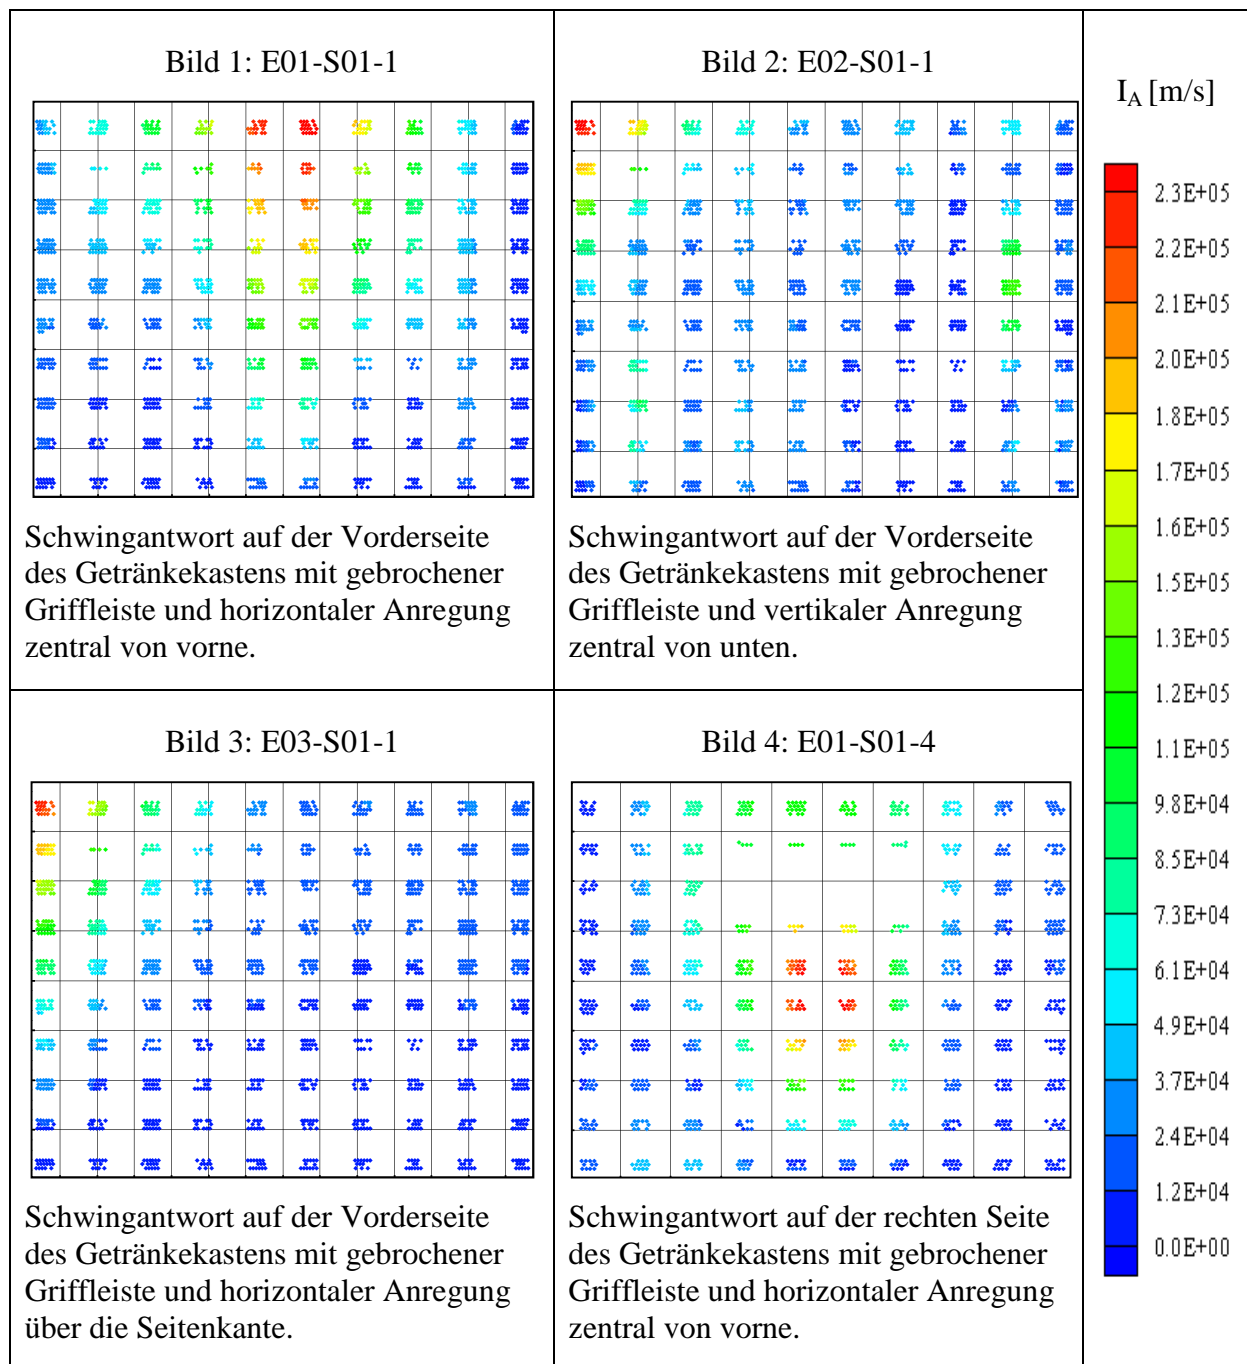
In Tabelle 4-2 (Bild 3) ist das Ergebnis der Auswertung für die Vorderseite des Getränkekastens dargestellt. Es handelt sich bei diesem Modell um die Simulation eines Griffbruches auf der linken Seite bei Stoßanregung an der rechten Kante des Kastens. In der Nähe der schadhafte Stelle (linke obere Ecke) zeigt sich ein deutlicher Unterschied (rot) zum Schwingverhalten eines unbeschädigten Kastens.

Liegt der Angriffspunkt der Kraft in der Mitte der Frontplatte, so ist dort im oberen Bereich auch der größte Unterschied im Schwingenspektrum detektierbar (vgl. Tabelle 4-2 - Bild 1). Dies deutet darauf hin, dass der gebrochene Griff auf der linken Seite über die sehr steife Kante mit diesem oberen Teil des Kastens wie ein Winkel um einen festen Drehpunkt schwingt. Auch die Anregung einer Eigenfrequenz in diesem Bereich des defekten Kastens kann Auslöser dieser Reaktion sein. Bei der zentralen Anregung von unten in vertikaler Richtung (vgl. Tabelle 4-2 - Bild 2) gleicht das Differenzspektrum wiederum dem der Anregung über die Ecke. Auch hier ist die stärkste Reaktion in der Nähe des Schadens lokalisiert und nimmt mit zunehmender Entfernung vom Schadensort ab. Jedoch treten auch im rechten, mittleren Bereich Abweichungen vom Schwingverhalten des neuen Getränkekastens auf. Dies lässt die Anregung in einer Eigenfrequenz vermuten.

Beim Vergleich dieser drei Ergebnisse fällt auf, dass die veränderten Reaktionen je nach Anregung in ganz unterschiedlichen Teilen des Prüflings mit unterschiedlicher Stärke auftreten. Es wird deutlich, dass der Kasten im oberen Bereich stärkere Reaktionen zeigt als im unteren. Dies wird durch die versteifende Wirkung des Kastenbodens auf die gesamte Geometrie ausgelöst. Außerdem ist der Prüfling im unteren Bereich durch die beschriebenen Klemmbacken fixiert und dadurch in seiner Bewegungsfreiheit eingeschränkt.

Berücksichtigt man die unterschiedliche Skalierung, zeigt sich, dass die Anregung in der Mitte der Platte (E01) mit Abstand die größten Unterschiede in der Schwingungsantwort hervorruft. Betrachtet man den ganzen Kasten in Bezug auf die stärkste auftretende Reaktion, so stellt man fest dass diese nicht, wie erwartet, im Bereich des Schadens auftritt, sondern auf der gegenüber liegenden Seite unterhalb des Griffes (vgl. Tabelle 4-2 - Bild 4). Durch die Anregung in der Mitte der Frontplatte werden die Kräfte hier symmetrisch auf beide Seiten übertragen. Die Antwort fällt von der Größenordnung her auf beiden Seiten gleich aus. Die Art der Reaktion unterscheidet sich aber bedingt durch den defekten Griff.

Tabelle 4-2: Ergebnisplots (gebrochene Griffleiste)

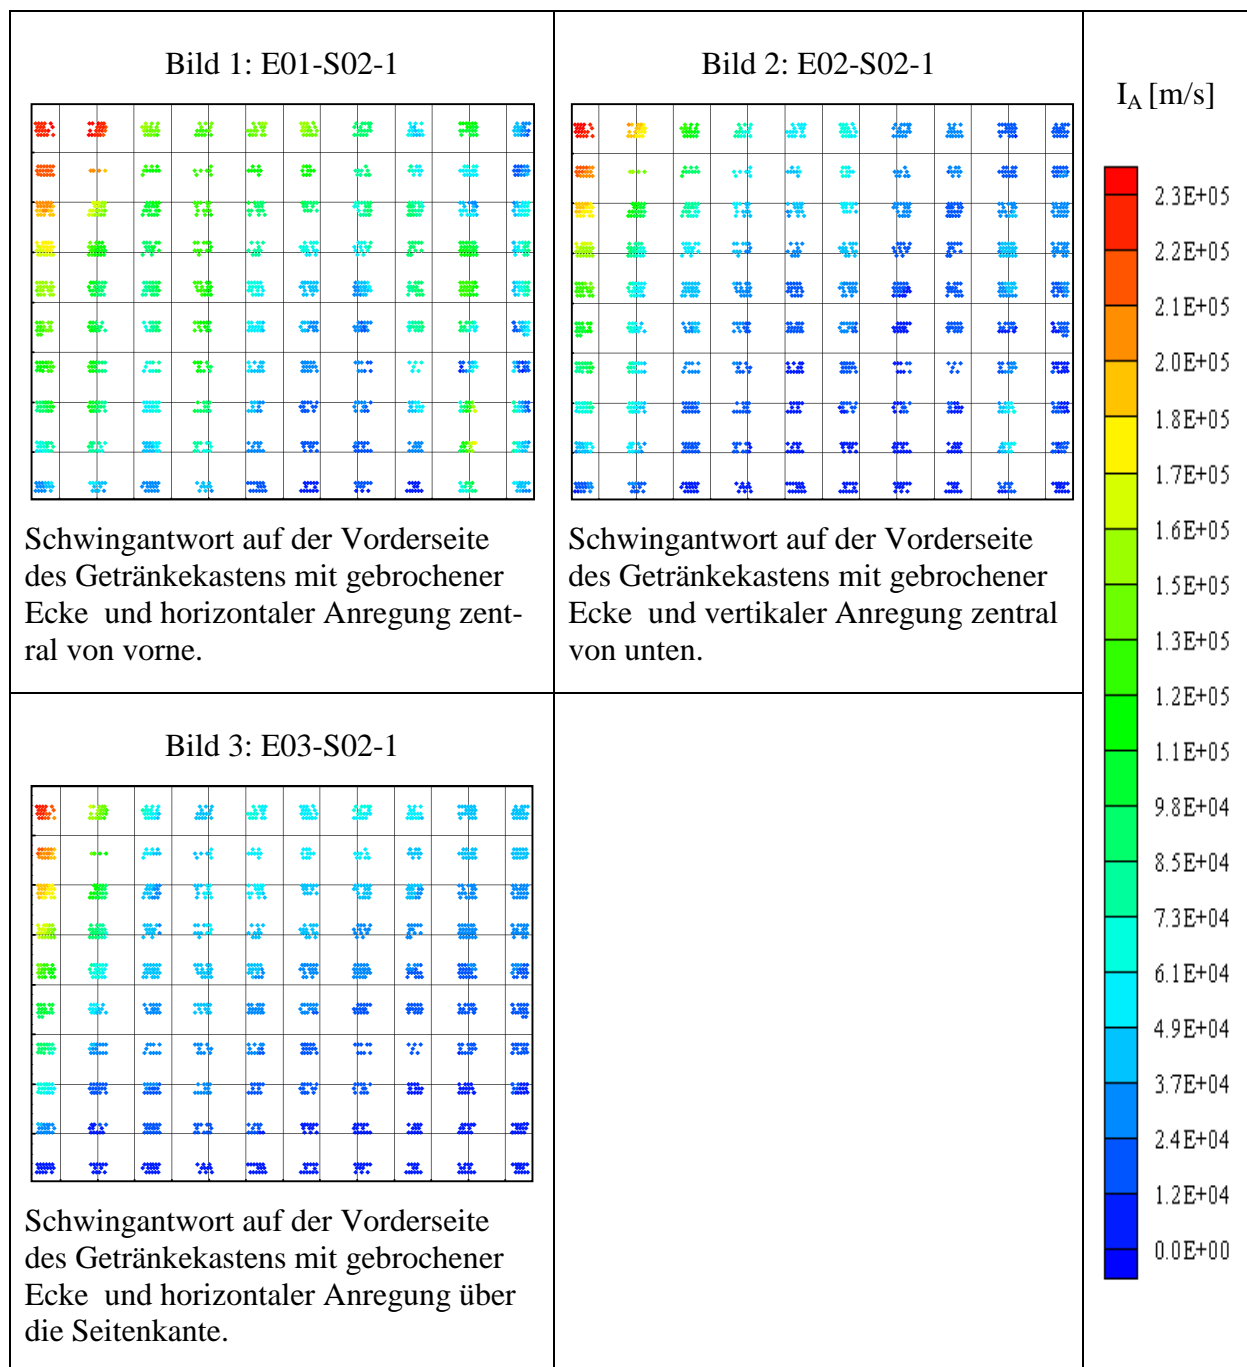


#### 4.1.4.2 Bruch an der Ecke - Modellschaden S02

Beim zweiten betrachteten Modellschaden handelt es sich um eine abgebrochene Ecke auf der Rückseite des Getränkekastens. Da sich Schäden jeglicher Art im Schwingverhalten des ganzen Kastens auswirken, müssen diese auch auf den nicht direkt betroffenen Teilen detektierbar sein. In Tabelle 4-3 (Bild 3) ist bei Stoßanregung an der Kante wiederum die örtliche Verteilung von  $I_A$  auf der Frontseite des Kastens aufgetragen.

Die stärkste Reaktion auf der Vorderseite zeigt sich auch hier, wie beim Griffschaden, am linken oberen Eck. Weiterhin wird deutlich, dass auf ca. zwei Drittel der Fläche eine Abweichung vom normalen Schwingspektrum auftritt. Das bestätigt, dass es bei der Schwingungsanalyse nicht notwendig ist, in der Nähe einer schadhaften Stelle zu messen, um diese zu detektieren. Wie in Tabelle 4-3 (Bild 1 und 2) aufgezeigt, sehen die Reaktionen bei den anderen Anregungsarten ähnlich aus. Dies lässt darauf schließen, dass der Kraftvektor der Anregung in diesem Fall nur eine untergeordnete Rolle spielt.

Tabelle 4-3: Ergebnisplots (gebrochene Ecke)

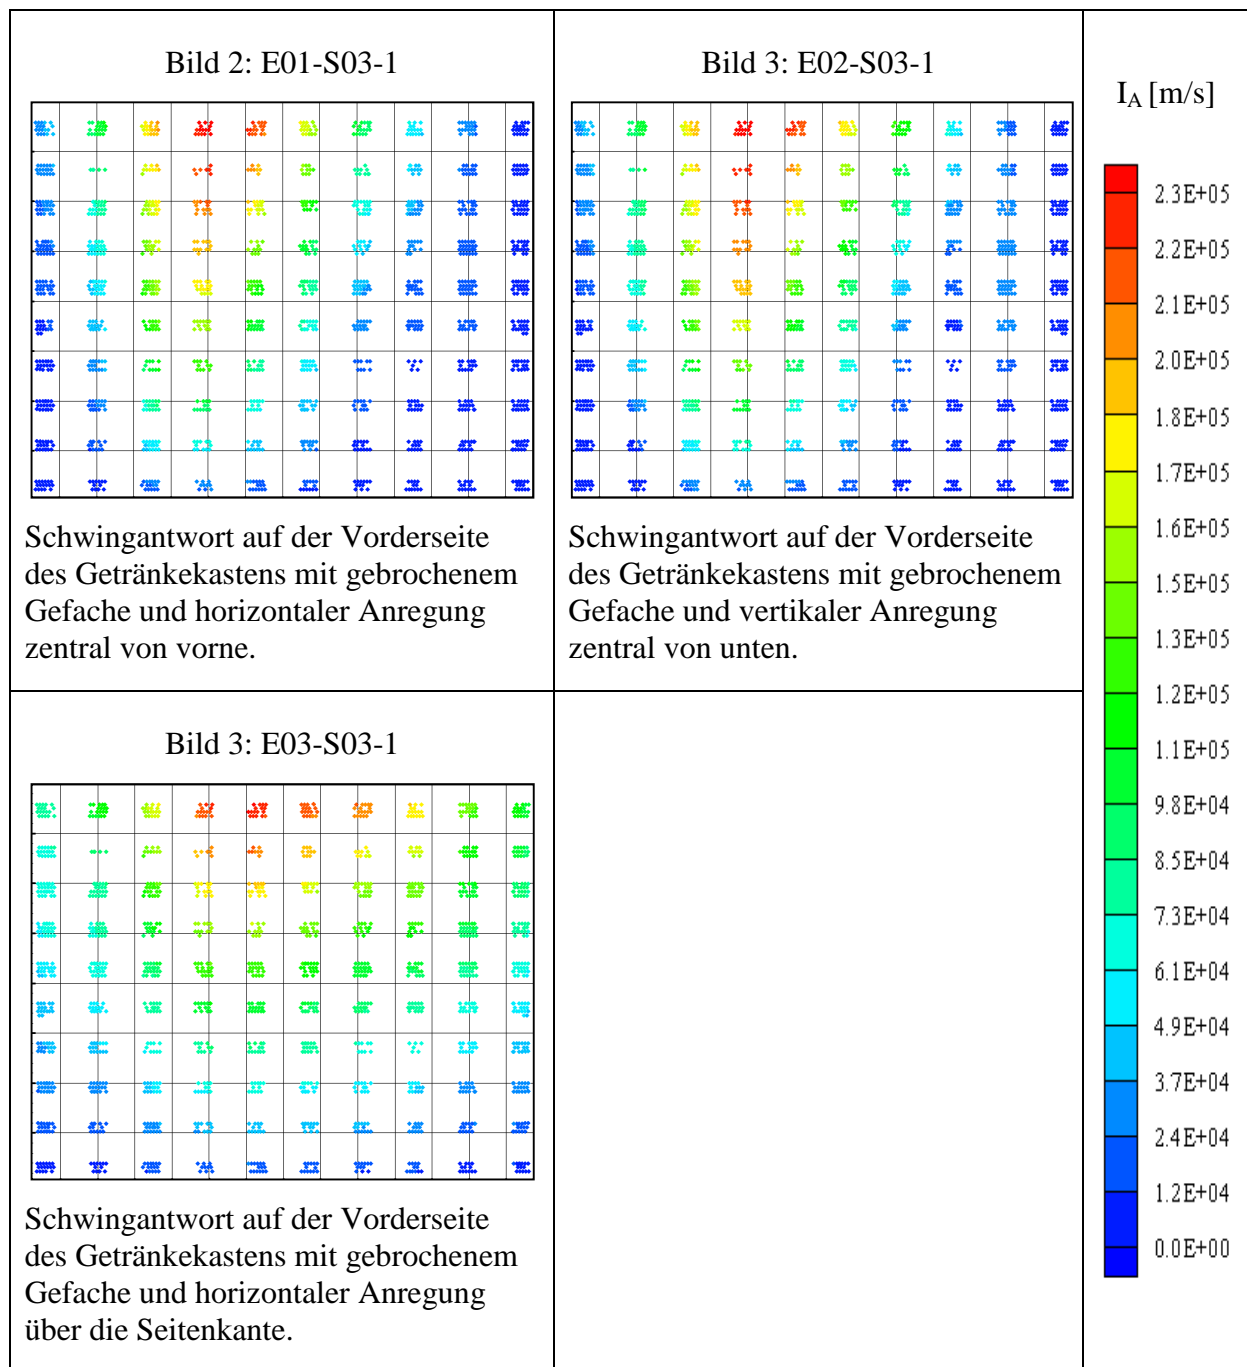


#### **4.1.4.3 Brüche im Gefache - Modellschaden S03**

Besteht am Getränkekasten ein Schaden im Gefache, so wirkt sich das vorwiegend auf das Schwingverhalten der innen liegenden Teile aus. Auch auf den betrachteten Oberflächen kann man jedoch eine Beeinflussung der Schwingantwort beobachten.

In Tabelle 4-4 (Bild 1-3) sind die Ergebnisse der Auswertung für die Vorderseite gezeigt. Anders als bei den Schäden auf der Außenseite ist hier, unabhängig von der Art der Anregung, auf der Vorderseite immer die Mitte im oberen Bereich am stärksten betroffen. Durch die fehlenden Gefacheteile können die noch bestehenden Gefachefragmente bei einer Anregung relativ frei schwingen. Da sie mit der Wand weiterhin noch verbunden sind, wirken an den Verbindungsstellen Momente, welche die Wand in ihrer normalen Schwingung stören und damit einen Unterschied zum Spektrum des intakten Kastens hervorrufen. Auch hier kann man beobachten, dass diese Beschädigung, unabhängig von der Art der Anregung, Unterschiede in der Schwingungsantwort im gleichen Bereich auf der Vorderseite des Kastens hervorruft. Die Stärke der Abweichung des Reaktionsunterschiedes ist, wie im vorherigen Abschnitt, bei der vertikalen Anregung (E02) am größten.

Tabelle 4-4: Ergebnisplots (Gefachebrüche)

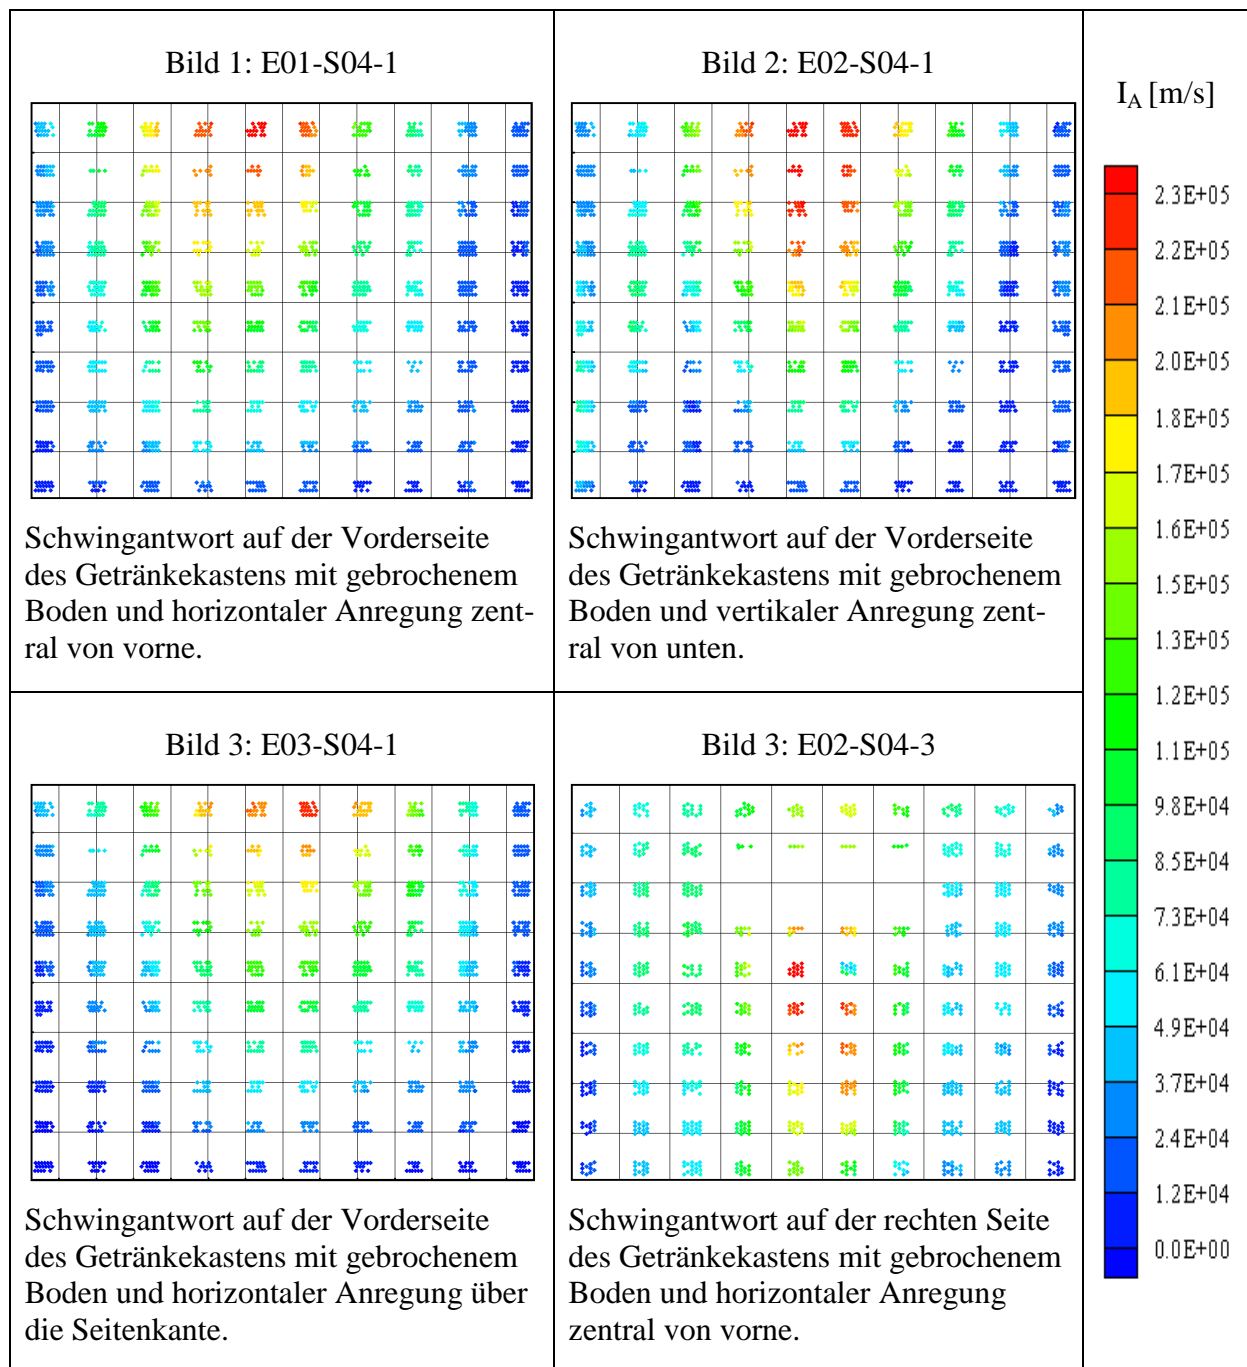


#### 4.1.4.4 Brüche am Kastenboden - Modellschaden S04

Beim vierten untersuchten Schaden handelt es sich um fehlende Bodenteile. Auch dieser Schaden liegt nicht direkt auf den vier betrachteten Seiten, kann dort aber durchaus detektiert werden. Eine Übersicht geben die Bilder in Tabelle 4-5, sowie weitere Abbildungen im Anhang dieser Arbeit. Wie bei den fehlenden Gefacheteilen macht sich dieser Schaden auf der Vorderseite besonders im oberen Mittelteil bemerkbar. Auch hier spielen frei schwingende Teile und übertragene Momente eine wichtige Rolle bei der Schwingungsänderung. Wiede-

rum ist die relative Verteilung von  $I_A$  weitgehend unabhängig von Ort der Anregung, nicht jedoch das absolute Ausmaß. Der Maximalwert wird durch Anregung von unten erreicht. Die größte Differenz der Schwingspektren ist auf der linken Seitenwand unterhalb des Griffes zu detektieren. Auf der Innenseite ist in diesem Bereich keine Versteifung angebracht. Daher kann diese Fläche bei Beschädigungen leichter zum Schwingen angeregt bzw. in ihrer normalen Schwingung gestört werden.

Tabelle 4-5: Ergebnisplots (Bodenbrüche)



### 4.1.5 Vergleich der Modellschäden

Stellt man die Ergebnisse der einzelnen Simulationen gegenüber, zeigt sich, dass die Schwingungsantwort von beschädigten Kästen sich nicht nur in der unmittelbaren Umgebung des Schadens von einem intakten Kasten unterscheidet. Wie anhand einiger ausgewählter Diagramme gezeigt, können Auswirkungen der Defekte, abhängig vom Schadensbild, auf dem ganzen Kasten lokalisiert werden. Dabei stellt sich heraus, dass auf der Vorderseite der obere Bereich sehr sensibel auf Störungen durch Defekte reagiert. Die Überprüfung der Ergebnisse von der Rückseite des Getränkekastens (siehe Anhang 6.1) bestätigt diese Hypothese. Auch hier zeigen sich die stärksten Abweichungen im oberen Bereich.

Bei der Betrachtung der Seitenwände kommt man zu dem Schluss, dass es nicht möglich ist, für alle Schäden eine gemeinsame beste Sensorposition anzugeben. Doch haben sich die Bereiche um den Griff als besonders geeignete Gebiete heraus kristallisiert, da dort die stärksten Unterschiede in den Spektren festgestellt werden konnten. Tabelle 4-6 fasst für alle betrachteten Schäden die jeweils maximal auftretenden Unterschiede zum unbeschädigten Getränkekasten in Abhängigkeit von der Anregung für jede Seite zusammen.

Tabelle 4-6: Übersicht der auftretenden Maxima der ermittelten Kenngröße

		<b>S01</b>	<b>S02</b>	<b>S03</b>	<b>S04</b>
1	E01	2,08E+05	3,34E+01	3,62E+03	1,19E+02
	E02	1,15E+04	6,23E+03	1,67E+05	8,02E+03
	E03	2,52E+01	1,11E+01	1,42E+01	2,30E+00
2	E01	2,23E+05	5,07E+01	2,01E+03	1,08E+02
	E02	8,97E+03	2,78E+03	9,95E+04	2,44E+03
	E03	2,36E+01	1,26E+01	5,34E+01	1,64E+00
3	E01	8,09E+04	3,77E+01	8,55E+02	5,58E+01
	E02	5,68E+04	7,56E+03	3,29E+04	2,03E+04
	E03	2,55E+02	2,33E+01	7,01E+01	3,69E+00
4	E01	2,44E+05	3,09E+01	1,83E+02	2,97E+01
	E02	9,82E+03	3,74E+03	2,33E+04	1,22E+04
	E03	1,42E+01	1,01E+01	6,40E+01	3,37E+00

E01, E02, E03 = verschiedene Angriffspunkte der Anregung (vgl. Abschn. 4.1.2.1)

S01, S02, S03, S04 = verschiedene Schadensfälle (vgl. Abschn. 2.3.4 bzw. 6.1)

1 = Knotenpunkte auf der Vorderseite des Getränkekastens (FRONT) (vgl. Abschn. 4.1.2.4)

2 = Knotenpunkte auf der Rückseite des Getränkekastens (REAR) (vgl. Abschn. 4.1.2.4)

3 = Knotenpunkte auf der linken Seite des Getränkekastens (LEFT) (vgl. Abschn. 4.1.2.4)

4 = Knotenpunkte auf der rechten Seite des Getränkekastens (RIGHT) (vgl. Abschn. 4.1.2.4)



Betrachtet man die Zahlenwerte bezüglich der verschiedenen Anregungsorte, fällt vor allem E02 mit durchwegs großen Beträgen auf. Die Wirkungsrichtung bei dieser Stoßanregung ist im Gegensatz zu den anderen beiden in vertikaler Richtung.

Nach den bisherigen Ergebnissen erscheint ein Punkt, der auf der Vorderseite im oberen Bereich in der Mitte des Getränkekastens lokalisiert ist, sowie die Stoßanregung von unten am besten geeignet, um eine Beschädigung des Getränkekastens zu detektieren. Abbildung 4-11 stellt für einen solchen Punkt und die vier Modellschäden die frequenz aufgelöste Abweichung der Schwingung von der eines intakten Kastens dar.

Vor allem im niederen Frequenzbereich besteht ein großer Unterschied zur Schwingantwort des unbeschädigten Kastens. Wie in den voran gegangenen Abschnitten gezeigt, treten in diesem Bereich die Eigenformen der Kastenseiten mit nur einem Schwingungsbauch und großer Amplitude in Erscheinung. Der betrachtete Punkt 88214 liegt in diesem Fall im Bereich einer großen Auslenkung. Daraus folgt, dass die Beschädigungen hier zu einer Verstärkung oder einer Dämpfung der maximalen Auslenkungen und somit zu großen Differenzen im Frequenzspektrum führen. Es lässt sich in diesem Bereich aber nicht nur eine Abweichung von einem intakten Kasten feststellen. Auch die Werte von  $A_{US}$  differieren untereinander. Bei Frequenzen unter 100 Hz liegt die Abweichung für den Modellschaden 04 um etwa den Faktor 10 über der des Schadentyps S03 und sogar um des 100-fache höher als bei den Schäden S01 und S02. Betrachtet man dagegen die Frequenzbereiche um 500 Hz bzw. 800 – 900 Hz, lassen sich auch die beiden letzteren Schadenstypen unterscheiden. So erscheint nicht nur die Detektion defekter Getränkekästen möglich, sondern sogar Festlegung auf eine Schadensart.




Abbildung 4-11: Darstellung der Differenzspektren eines Knotens auf der jeweiligen Vorderseite eines beschädigten Kastens (S01 – S04) angeregt vertikal von unten

#### 4.1.6 Ergebnisse der numerischen Simulationen mit Kastenmodell 1

Die grundlegenden Untersuchungsergebnisse aus den beschriebenen Simulationen kamen in anschließenden Versuchen mit Getränkekastenmodell 1 zum Einsatz. Abbildung 4-12 zeigt in einer Abwicklungsdarstellung aller Seiten des Getränkekastens die Untersuchungsdetails. Das rot gekennzeichnete Kreuz (Nr. 1) zeigt dabei die am Kastenboden verwendete Stelle zur Einleitung des Anregungsimpulses. Die beiden roten Balken (2, 3) deuten die Stellen zur Fixierung des Kastens an. Die kleinen roten Kreuze (4 – 8) markieren die Positionen zur Erfassung der Schwingungsdaten. Diese Untersuchung diente in erster Linie dazu, heraus zu finden, wie der Getränkekasten auf verschiedene Anregungssignale reagiert und welche Messposition die meisten Informationen über den Zustand des Prüflings liefert. Dazu kamen insgesamt 26 verschiedene Zustandsmodelle (siehe Abschnitt 2.3.4) zum Einsatz.

Der Vergleich der Frequenzspektren (siehe nachfolgende Auswertungen und Bilder) von Kästen mit verschiedenen Beschädigungen und unbeschädigten Exemplaren gibt Auskunft über Frequenzbereiche, in denen sich die Beschädigungen hauptsächlich auswirken und dient somit als Basis für die anschließenden Auswertungen mit Hilfe Künstlicher Neuronaler Netze.

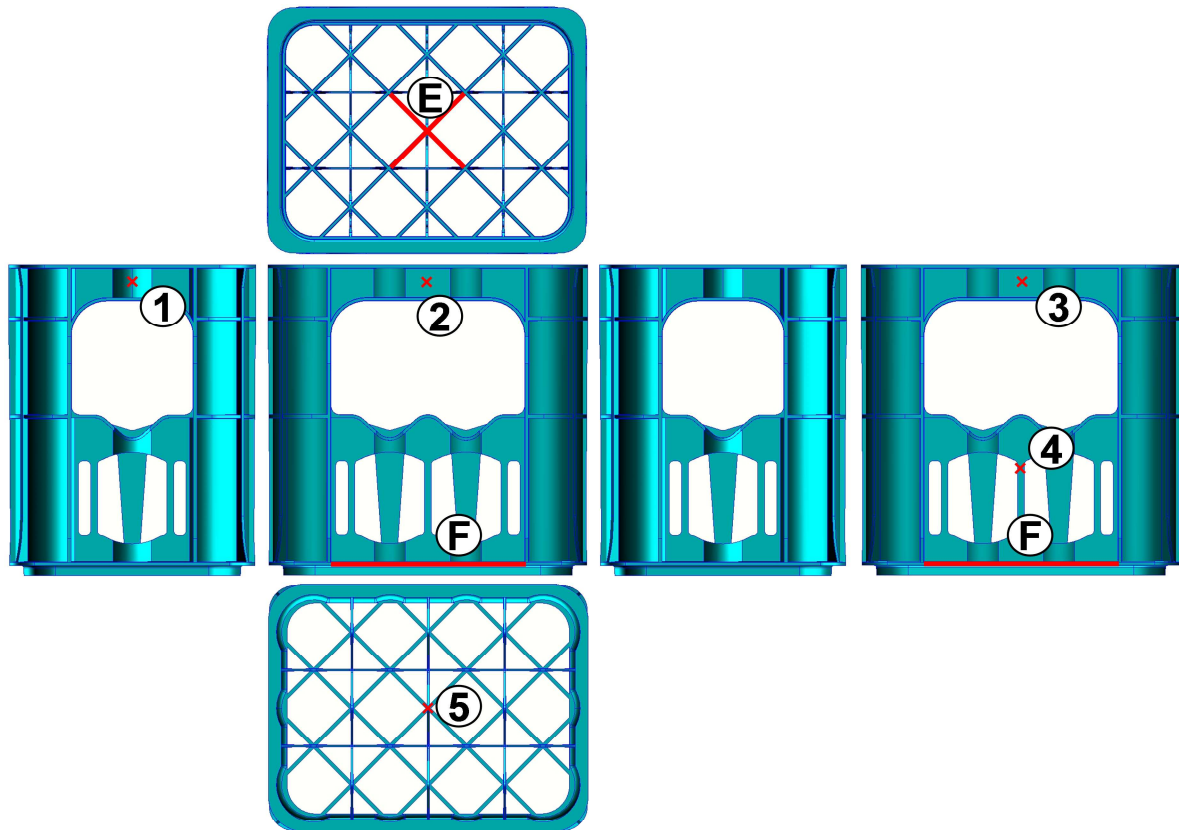


Abbildung 4-12: Versuchsparameter der Simulationen mit Kastenmodell 1

- E) Bereich der Schwingungsanregung von unten vertikal nach oben
- F) Angriffspunkte der Klemmbacken zur Fixierung
- 1) Datenerfassungspunkt auf der kurzen Griffleiste
- 2) 3) Datenerfassungspunkte auf der langen Griffleiste
- 4) Datenerfassungspunkt im Gefache des Kastens
- 5) Datenerfassungspunkt am Boden des Kastens

#### 4.1.6.1 Untersuchung verschiedener Schadensbilder

Die Untersuchung verschiedener Schadensbilder zeigt die Unterschiede der Schwingungen von einigen defekten Kästen im Messpunkt 1 (vgl. Abbildung 4-12).

Die stärksten Auswirkungen auf das Fourierspektrum haben dabei Schäden in den kurzen und langen Griffleisten. Diese rufen deutlich sichtbare Veränderungen des Verlaufs und der Höhe im gesamten Bereich bis ca. 400 Hz hervor. Auffällig sind die bei sonst keinem Schaden in dieser Deutlichkeit auftretenden Peaks unter 200 Hz (vgl. Abbildung 4-13).




Abbildung 4-13: Simulation verschiedener Beschädigungen

Schäden in den Seitenwänden wirken sich hauptsächlich auf Schwingungen im Bereich von 300 – 350 Hz aus, wohingegen Risse in den Ecken zusätzlich den Peak bei 200 Hz dämpfen. Schwingungen bei höheren Frequenzen bleiben nahezu unverändert (vgl. Abbildung 4-14).

Bei den Gefacheschäden hängt die Veränderung im Spektrum vom Ort der Beschädigung ab. Exemplarisch führt Abbildung 4-15 zwei Extreme auf: Der Gefacheteil direkt über der Anre-

gungsfläche trägt maßgebliche Verantwortung für die Übertragung der Schwingung vom Boden auf den gesamten Kasten. Fehlt dieser, verändert sich das gesamte Schwingungsbild. Der Hauptpeak bei ca. 200 Hz wird deutlich kleiner, dafür erscheinen Schwingungen bei hohen Frequenzen. Erweist sich ein am Rand liegender Teil des Gefaches als beschädigt, sind die Veränderungen im Spektrum von weit geringerem Ausmaß. Wie bei den Rissen in den Seitenwänden treten die größten Unterschiede zwischen 300 und 350 Hz auf. Beide Schäden erzeugen leichte Schwingungen im niedrigen Frequenzbereich (vgl. Abbildung 4-15).




Abbildung 4-14: Simulation verschiedener Beschädigungen




Abbildung 4-15: Simulation verschiedener Beschädigungen

Diese Erkenntnisse aus den numerischen Simulationen tragen maßgeblich zu einer erfolgreichen konstruktiven Umsetzung der Prototypen bei. Die Auswirkungen der einzelnen Schäden auf das Schwingverhalten, bzw. die Änderung des Fourierspektrums, dienen zur Feinabstimmung der Auswertung mithilfe Künstlicher Neuronaler Netze und haben zukünftig enormes Potenzial zur Datenreduktion und Steigerung der Auswertegeschwindigkeit.

#### 4.1.6.2 Vergleich verschiedener Signalerfassungspositionen

Vergleicht man die Schwingungssignale verschiedener Messpunkte auf einem Kasten zeigt sich auch hier ein deutlicher Unterschied der ausgeführten Bewegungen hervorgerufen durch die vertikal von unten einwirkende Anregungskraft. Anhand von vier häufigen Beschädigungsbildern (vgl. Tabelle 2-3) sollen die Auswirkungen auf die Schwingungen in vier potentiellen Messpunkten (vgl. Abbildung 4-12) für den experimentellen Versuchsaufbau charakterisiert werden. In Tabelle 4-7 sind für jede Messstelle und jede Beschädigung in einer Matrix jeweils fünf charakteristische Frequenzen mit den höchsten Beschleunigungen aufgelistet. Es handelt sich hierbei um die ersten fünf lokalen Maxima des Spektrums.

Tabelle 4-7: Fünf lokale Maxima der größten Schwingungen bei verschiedenen Beschädigungen

	Messpunkt 1		Messpunkt 2		Messpunkt 3		Messpunkt 4	
	f [Hz]	a [ $\text{m/s}^3$ ]	f [Hz]	a [ $\text{m/s}^3$ ]	f [Hz]	a [ $\text{m/s}^3$ ]	f [Hz]	a [ $\text{m/s}^3$ ]
U00	180.7	21.7	307.6	17.3	317.4	17.9	317.4	20.2
	322.3	6.2	180.7	11.0	180.7	11.3	283.2	11.3
	419.9	4.0	415.0	4.3	415.0	4.5	732.4	10.3
	620.1	3.2	625.0	1.6	625.0	1.6	415.0	7.5
	283.2	2.9	73.2	1.2	73.2	1.2	517.6	5.5
S06	185.5	24.6	180.7	18.8	317.4	24.9	317.4	20.5
	302.7	9.8	302.7	5.5	185.5	9.2	732.4	10.3
	327.1	8.9	283.2	5.0	117.2	6.3	415.0	8.6
	278.3	7.5	410.2	2.8	78.1	2.8	517.6	5.4
	122.1	4.7	112.3	2.1	410.2	2.1	180.7	4.9
S08	180.7	12.2	312.5	20.3	307.6	5.0	317.4	29.3
	312.5	8.1	180.7	12.6	278.3	3.6	205.1	12.8
	278.3	6.7	195.3	10.1	205.1	2.9	732.4	10.2
	117.2	4.9	112.3	5.6	175.8	2.6	415.0	7.6
	107.4	3.1	102.5	4.8	244.1	2.2	629.9	5.0
S10	180.7	11.9	180.7	7.3	307.6	18.8	307.6	20.4
	307.6	11.2	327.1	3.4	195.3	4.5	732.4	10.3
	195.3	6.6	293.0	2.9	210.0	3.6	415.0	8.3
	210.0	5.7	410.2	2.5	410.2	2.7	200.2	6.5
	620.1	3.5	210.0	2.4	620.1	2.0	517.6	5.3
S18	322.3	10.7	312.5	20.1	317.4	21.8	127.0	59.0
	190.4	6.9	415.0	6.2	415.0	6.4	322.3	37.6
	419.9	6.0	190.4	2.9	190.4	3.1	283.2	21.8
	620.1	3.3	625.0	1.7	170.9	1.6	185.5	21.7
	512.7	3.3	170.9	1.6	625.0	1.5	214.8	13.7

In Abbildung 4-16 sind die Schwingungsantworten eines unbeschädigten Getränkekastens dargestellt. Während die Griffleiste (Messpunkt eins) eine signifikante Schwingung bei 180 Hz aufweist, befinden sich die größten Amplituden der langen Griffleiste (Messpunkt zwei und drei) bei ca. 300 Hz. Der beinahe identische Schwingungsverlauf in beiden langen Griffleisten zeigt, dass es sich um einen unbeschädigten Kasten handelt und dass diese durch die zentrisch eingeleitete Anregung die gleichen Bewegungen ausführen. Da das vernetzte Modell durch Ungenauigkeiten im FEM-Modell sowie Berechnungsungenauigkeiten keine hundertprozentige Symmetrie aufweist, weichen auch diese Schwingungen etwas voneinander ab. Das Gefache des Prüflings offenbart ebenso wie die langen Griffleisten seine charakteristische Schwingung bei 317 Hz auf, schwingt aber im Gegensatz zu den Griffleisten auch in den höheren Frequenzen noch sehr ausgeprägt.




Abbildung 4-16: Vergleich verschiedener Messpositionen am unbeschädigten Kasten

Im Vergleich zu den Schwingungen eines unbeschädigten Getränkekastens sind in den nachfolgenden Abbildungen Spektren von defekten Kästen dargestellt. Abbildung 4-17 präsentiert die Auswirkungen einer defekten kurzen Griffleiste. Der Messpunkt auf der gegenüberliegenden Seite des Defektes zeigt sowohl in der Hauptfrequenz als auch in den höheren Frequenzen sichtbare Verschiebungen der Beschleunigungen. Der charakteristische Peak von Messpunkt 2 bei 300 Hz nimmt an Intensität ab bzw. verschiebt sich durch die Beschädigung zu der niedrigeren Frequenz von 180 Hz. Die Schwingungen in Messpunkt drei und vier hingegen erfahren keine starken Veränderungen in ihren Charakteristika. Während die lange Griffleiste



(Messpunkt 3) eine Erhöhung der Beschleunigung bei 300 Hz erklärt, ändert die Beschädigung an der kurzen Griffleiste an den Schwingungen im Gefache (Messpunkt 4) nur sehr wenig. Hier kann man nur einige zusätzliche, niederfrequente Schwingungen im Bereich unter 200 Hz anhand der Fourier-Darstellung erkennen.

Abschließend lässt sich aus den Ergebnissen dieses Beschädigungsbildes schließen, dass hier die signifikantesten Änderungen im Vergleich zum unbeschädigten Kasten in der kurzen Griffleiste (Messpunkt 1) und auch in den langen Griffleisten (Messpunkt 2 und 3) stattfinden. Im Gefache macht sich der Schaden nur wenig bemerkbar.




Abbildung 4-17: Vergleich verschiedener Messpositionen am beschädigten Kasten mit Griffriß in der kurzen Griffleiste

Das nächste untersuchte Schadensbild ist die Beschädigung der langen Griffleiste am Getränkekastens (vgl. Abbildung 4-18). In Messpunkt eins gehen die Schwingungsamplituden bei dieser Beschädigung in allen Frequenzbereichen erheblich zurück. Die hochfrequenten Amplituden nehmen zugunsten der niederfrequenten Ausschläge ab. Messpunkt zwei, auf der langen Griffleiste gegenüber der beschädigten Griffleiste zeigt in den beiden charakteristischen Hauptpeaks bei 307 und 180 Hz eine kleine Erhöhung. Auch hier verschwinden Schwingungen mit großen Beschleunigungen und es tauchen neue Peaks im unteren Frequenzbereich auf. Der Messpunkt drei auf der defekten Griffleiste deutet an, dass der Griff durch seine Beschädigung nur noch mit niedrigen Frequenzen schwingt. Die Beschleunigungen der Schwingungen nehmen generell stark ab. Dies expliziert, dass die Beschädigung die

Steifigkeit des Bauteils verringert und dieses durch fehlende Rückhaltekräfte frei schwingen kann. Bei den Gefacheschwingungen nimmt der Hauptpeak bei 317 Hz um ein Drittel zu, der Peak bei 283 Hz verschiebt sich in den niederen Frequenzbereich auf 205 Hz.




Abbildung 4-18: Vergleich verschiedener Messpositionen am beschädigten Kasten mit Griffriß in der langen Griffleiste

Ein weiteres Schadensbild stellt die Beschädigung in der Ecke der untersuchten Getränkekästen dar. In Abbildung 4-19 sind wiederum die Fourierspektren der jeweiligen Schwingungsinformationen der verschiedenen Bereiche auf dem Prüfling illustriert. Auch hier zeigt sich wie beim vorangegangenen Schaden eine Halbierung der Beschleunigung bei der Schwingfrequenz von 180 Hz. Weiterhin auffällig ist die Verdopplung der Beschleunigung der Schwingungen mit einer Frequenz von 300 Hz. In den langen Griffleisten ist generell eine leichte Verschiebung der Schwingfrequenzen zu erkennen und die Beschleunigungen der Schwingungen nehmen durchgehend ab. Die Gefacheschwingungen werden von der beschädigten Ecke nicht stark beeinflusst, lediglich im niederfrequenten Bereich bei ca. 200 Hz zeigen sich erhöhte Beschleunigungen.




Abbildung 4-19: Vergleich verschiedener Messpositionen am beschädigten Kasten mit Riss an der Ecke

Die letzte hier vorgestellte Beschädigung ist im Inneren des Untersuchungsobjektes lokalisiert. Dabei handelt es sich um ein fehlendes Teil des Gefaches in der Kastenmitte (vgl. Abbildung 4-20). Wie in der Abbildung deutlich wird, wirkt sich diese Beschädigung sehr stark auf den dort befindlichen Messpunkt 04 aus. Es gestaltet sich eine sehr hohe charakteristische Schwingung bei 127 Hz mit einer Beschleunigung von annähernd  $60 \text{ m/s}^3$  aus. Die restlichen Schwingungsmaxima sind wiederum etwas verschoben und durchgehend alle um ein vielfaches angestiegen. Dies expliziert, dass der Teil des Gefaches durch die Anregung nun viel heftiger zu schwingen vermag als bei einem unbeschädigten Exemplar. Die beiden langen Griffleisten offenbaren hier ähnliches Schwingverhalten. Während der Peak bei 300 Hz verstärkt und in seiner Frequenz etwas verschoben wird, nehmen die Beschleunigungen in den anderen Frequenzen ab. Der Messpunkt eins auf der kurzen Griffleiste weist ebenso eine Verschiebung und Abschwächung der charakteristischen Frequenzen auf.




Abbildung 4-20: Vergleich verschiedener Messpositionen am beschädigten Kasten mit defektem Gefache

Generell lässt sich zusammenfassen, dass bei dieser Untersuchung die verschiedenen Beschädigungen vor allem in den Schwingfrequenzen von 50 bis 500 Hz messbar sind. Die Unterschiede zum Schwingungsbild eines intakten Kastens präsentieren sich hier durch die Verschiebung von charakteristischen Schwingfrequenzen sowie der Veränderung der Beschleunigung, mit der die Bewegung der jeweiligen Kastensegmente durch die erzwungene, definierte Anregung stattfindet. Je näher ein Messpunkt am Schaden lokalisiert ist, desto stärker sind diese Veränderungen im Vergleich zu einem unbeschädigten Kasten. Es besteht die Möglichkeit, anhand der Amplituden von einigen, ausgesuchten charakteristischen Frequenzen eine Klassifizierung des Zustandes vorzunehmen oder anhand des kompletten Schwingbildes bzw. der Kombination der verschiedenen Peaks. Für den konstruktiven Aufbau einer experimentellen Versuchsanlage bestätigt sich die Idee der symmetrisch von unten eingeleiteten Anregungskraft. Des Weiteren scheint die Erfassung der Schwingungen auf den Griffleisten eine sehr gute und vor allem umsetzbare Lösung zu sein.

## 4.2 Ergebnisse der experimentellen Schwingungsanalyse

Aufbauend auf der Arbeit von Zacharias erfolgten zu Beginn dieser Arbeit umfangreiche numerische Simulationen mit Kastenmodell 2. Durch großes Interesse an dem Forschungsprojekt von Seiten der GDB, die wie bereits erwähnt ein großes Problem mit defekten Kästen in ihrem Mehrwegbestand beklagen, fiel die Entscheidung für das experimentelle Untersuchungsobjekt auf Kastenmodell 1. Die praktischen Ergebnisse in der vorliegenden Arbeit wurden ausschließlich aus Experimenten mit Kastenmodell 1 gewonnen und werden im Folgenden ausführlich erläutert. Dazu entstanden im Laufe der Versuche 3 Versuchskastenpools, die sich jeweils aus defekten und intakten Kästen des Modells 1 zusammensetzen. Eine Übersicht gibt Tabelle 4-8.

Zu Beginn der Experimentierphase dienten die 30 Kästen aus Versuchspool 1 als Untersuchungsobjekte. Mit Hilfe dieses Versuchskastenpools entstand sukzessive der erste Laboraufbau zur Ausarbeitung eines industrietauglichen Verfahrens zur Schadensdetektion. Im nächsten Schritt erfolgte mit der Versuchsanlage eins der erste Feldversuch im Flaschenkeller der Firma Frankenbrunnen in Neustadt an der Aisch, um die entwickelte Methode unter realen Umgebungsbedingungen und einer großen Anzahl an Prüflingen zu testen. Der untersuchte Kastenpool 2 stammte direkt aus dem dortigen Kastenmagazin und umfasste insgesamt 302 defekte sowie 320 intakte Kästen.

Aus den Erkenntnissen dieser Versuche entstand im nächsten Schritt eine industrietaugliche Applikation. Für die Experimente diente hierzu der Kastenpool 3. Dieser besteht aus ausgewählten Kästen des Kastenpools 2. Er enthält 39 defekte und 95 intakte Exemplare.

Tabelle 4-8: Übersicht über die Versuchskastenpools

<b>Kastenpool ID</b>	<b>I</b>	<b>II</b>	<b>III</b>
Anzahl defekter Kästen	10	302	39
Anzahl intakter Kästen (neu)	10	-	8
Anzahl intakter Kästen (gebraucht)	10	320	87
Anzahl Kästen gesamt	30	478	134
Gemessene Datensätze	179	4908	1481

### 4.2.1 Schwingspektren

Stellvertretend für alle gemessenen Getränkekästen aus den verwendeten Versuchskastenpools (vgl. Tabelle 4-8) illustriert Abbildung 4-21 exemplarisch vier typische Schadensbilder. Bei den Schäden an den Kästen Nr. 10 und 20 handelt es sich um schwer detektierbare Risse in den Griffleisten. Kasten Nr. 14 und 23 weisen hingegen fehlende Kastenelemente auf, was sie für eine Weiterbenutzung im Mehrwegkreislauf unbrauchbar macht.

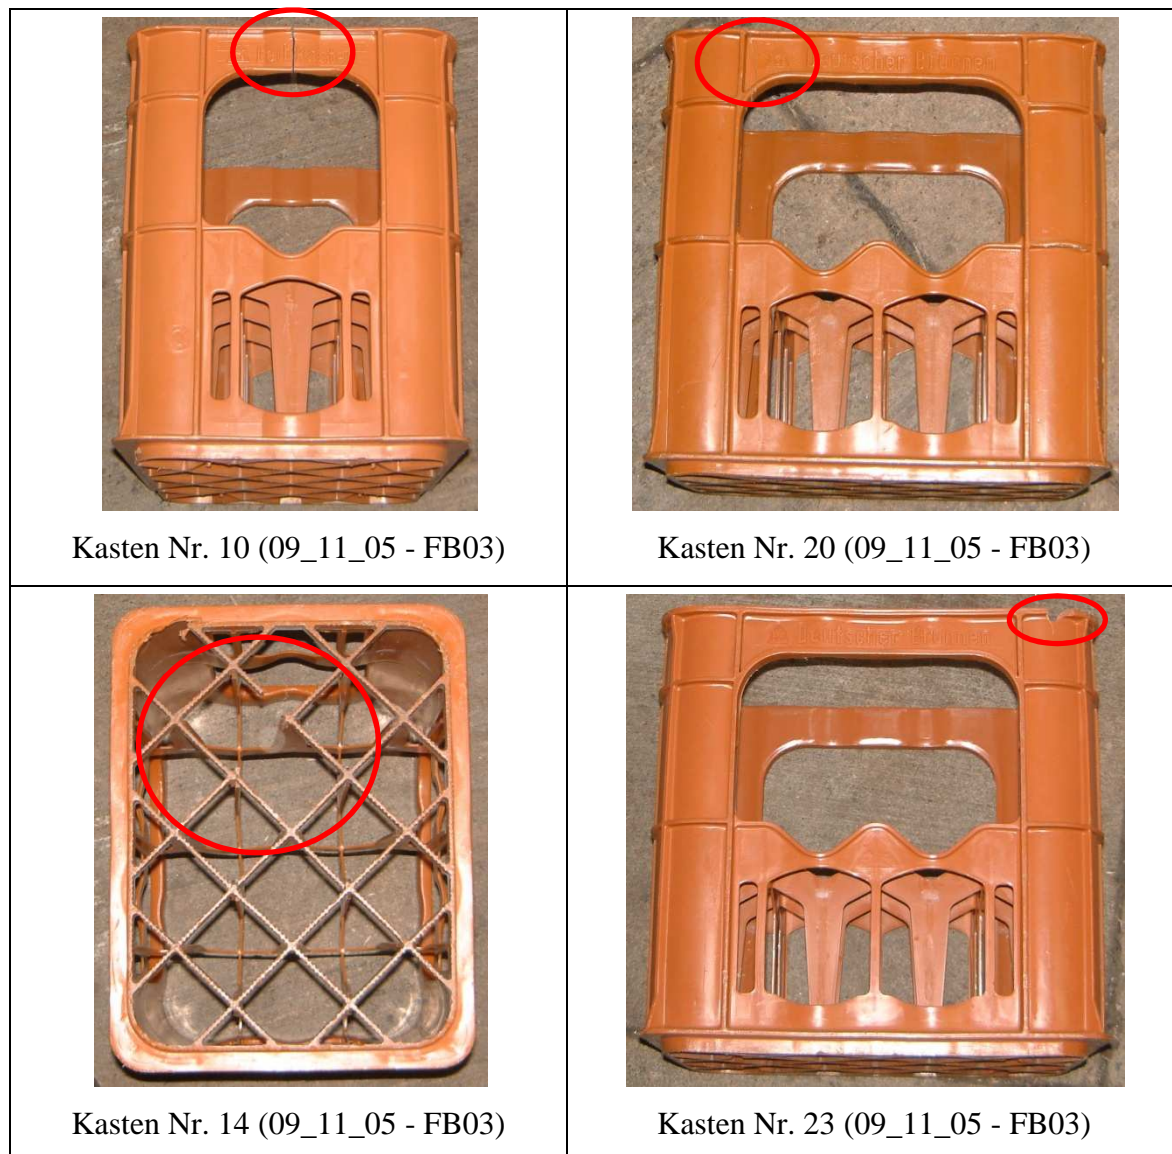


Abbildung 4-21: Schadensbilder

Wie in den vorherigen Kapiteln ausgeführt, spiegelt sich der Zustand der Kästen im Antwortverhalten auf eine definierte Schwingungsanregung wider. Abbildung 4-22 veranschaulicht den zeitlichen Verlauf der Beschleunigung, wie ihn das Laservibrometer liefert, für die vier Schadensbilder.




Abbildung 4-22: Beschleunigungsverlauf in den Griffleisten

Das in die entwickelte Software integrierte, automatische Verfahren zur Fouriertransformation dient zur Darstellung des Frequenzinhalts der Schwingungsantwort an den Griffleisten der Getränkekästen und dient zur Vorverarbeitung der Daten für die kognitive Mustererkennung (vgl. Abbildung 4-23).




Abbildung 4-23: Frequenzspektren der gemessenen Schwingungen in den Griffleisten

Nach der beschriebenen Fouriertransformation erfolgte mit Hilfe der numerischen Integration eine Zusammenfassung der zu Anfang vorliegenden 1024 Amplituden. Sie dienen als Eingangsdatensatz für die eingesetzten KNNs (Tabelle 4-9). Abbildung 4-24 stellt die resultierenden Zahlenkolonnen nach der numerischen Integration exemplarisch für einen defekten Kasten dar. Je kleiner die Eingangsschicht des jeweils verwendeten KNN ist, desto stärker müssen die ursprünglichen Frequenzspektren komprimiert werden. Im vorliegenden Beispiel sind die Anzahl der Eingangsknoten der drei KNN 16, 32 oder 64 Knoten. In der vorliegenden Arbeit kommt zusätzlich noch ein KNN mit 128 Eingangsneuronen zum Einsatz.




Abbildung 4-24: Komprimierte Spektren eines defekten Kastens



In Abbildung 4-25 ist das Mittelwertspektrum über alle Datensätze von intakten Kästen des Versuchskastenpools 1 dargestellt. Die Standardabweichungen, in der Grafik als schwarzer Bereich um das Spektrum abgebildet, geben die Schwankungsbreite der einzelnen Spektren wieder.




Abbildung 4-25: Mittelwert und Standardabweichung der Frequenzspektren intakter Kästen

Abbildung 4-26 zeigt das Mittelwertspektrum aller defekten Kästen und die Standardabweichungen als schwarzen Bereich. Vergleicht man diese mit Abbildung 4-25 wird deutlich, dass vor allem die Schwingungen im Bereich zwischen 0 und 500 Hz große Unterschiede in den Amplituden aufweisen. Während bei den intakten Kästen Amplituden bis 25 m/s<sup>2</sup> erscheinen, ist der höchste Wert in diesem Bereich bei den defekten Kästen 17 m/s<sup>2</sup>. Die Standardabweichung ist bei den defekten Kästen deutlich breiter gestreut, als es bei den intakten der Fall ist. Im Bereich über 2.5 kHz sind beide Spektren ziemlich ähnlich.

Die Mittelwertbildung über alle gemessenen Spektren von defekten und intakten Kästen aus Versuchskastenpool 2 weisen auch sehr deutlich die Unterschiede zwischen den beiden Kategorien aus. Die mehrwegfähigen Exemplare des Versuchskastenpools 2 schwingen mit Frequenzen im Bereich bis 1.5 kHz mit einer maximalen mittleren Amplitude von 15 m/s<sup>2</sup> bei ca. 200 Hz. Die Spannweiten der Standardabweichungen ist hierbei sichtbar größer als bei den

Labordaten was sich mit der viel größeren Auswahl an Versuchsobjekten und der damit verbundenen Bandbreite an untersuchten Schadensbildern begründen lässt (vgl. Abbildung 4-27).




Abbildung 4-26: Mittelwert und Standardabweichung der Frequenzspektren defekter Kästen

Da der Zustand einer großen Anzahl an Prüflingen nahe an der Grenze zwischen den beiden Kategorien „intakt“ und „defekt“ rangiert, ist sehr deutlich zu erkennen, dass es unmöglich ist, anhand einer einzelnen Amplitude eine Aussage über den Zustand zu machen. Vielmehr ist es die Kombination aus Frequenzen und Amplituden die hier eine Unterscheidung ermöglichen.

Die nicht mehr mehrwegfähigen Getränkekästen aus Versuchskastenpool 2 weisen ebenso den höchsten charakteristischen Peak mit einer Amplitude von  $11 \text{ m/s}^2$  bei ca. 200 Hz auf (vgl. Abbildung 4-28). Auch bei diesen Frequenzspektren sind die Anteile an der Gesamtschwingung über 2.5 kHz im Gegensatz zu dem unteren Frequenzbereich ziemlich gering. Auch die Standardabweichung um den Mittelwert ist hier in einem engen Band begrenzt, was eine Kategorisierung der Prüflinge in diesem Bereich unmöglich erscheinen lässt. Daraus ist zu folgern, dass der Informationsgehalt im oberen Frequenzbereich für diese Aufgabe sehr gering und demnach, wie schon erwähnt, vernachlässigbar ist. Eine differenzierte Untersuchung dieser Aussage erfolgt in Kapitel 4.2.6.2.




Abbildung 4-27: Mittelwert und Standardabweichung der Frequenzspektren  
intakter Kästen




Abbildung 4-28: Mittelwert und Standardabweichung der Frequenzspektren  
defekter Kästen

### 4.2.2 Reproduzierbarkeit

Eine vollständige Reproduzierbarkeit ist gegeben, wenn eine Messung unter gleichen Bedingungen dieselben Ergebnisse liefert. Wird ein Untersuchungsobjekt z.B. durch die Untersuchung verändert bzw. zerstört kann keine Wiederholungsmessung stattfinden und demnach ist das Ergebnis nicht reproduzierbar außer das Untersuchungsobjekt ist mehrfach verfügbar. Im vorliegenden Fall sind die Untersuchungsobjekte Getränkekasten zwar vielfach verfügbar, doch unterscheiden sich diese im Detail. So sind Herstellungsschwankungen in Form und Material vom Hersteller toleriert, wirken sich aber auf das Schwingverhalten aus. Die Beanspruchung der Kästen beim Kunden sowie die unterschiedliche Behandlung und Lagerung der einzelnen Abfüller bewirkt demzufolge, dass jeder Kasten ein Unikat darstellt. Außerdem kann das Messsystem in der rauen Umgebung einer Flaschenabfüllanlage nicht gänzlich gegen Fremdschwingungen der Umgebung abgeschottet werden. Dabei spielen einerseits die dauerhaft auftretenden Vibrationen der laufenden Maschinen und Bänder aber auch zufällig auftretenden Erschütterungen z.B. durch Ladefahrzeuge eine Rolle.

Daraus folgt, dass es keine vollständig identischen Schwingspektren zweier Getränkekästen gibt. Es kann lediglich ein Bereich festgelegt werden, in dem sich die Schwingungsantwort je nach Zustand des Kastens bewegt. Zwar ist das KNN durch seine Generalisierungsfähigkeit in der Lage diese Schwankungen auszugleichen, doch erwies es sich als vorteilhaft bzw. wird in der Literatur sogar empfohlen, aufgenommene Datensätze künstlich zu verrauschen um diese Generalisierungsfähigkeit zu verbessern. Der positive Nebeneffekt dieses Vorgehens ist die Vergrößerung des Datenpools zur Konstitutionierung der KNN.

Die Datenerfassung, unter Einsatz des Laservibrometers, erfolgte auf den kurzen Griffleisten der insgesamt 30 Getränkekästen. Da die Kästen auf den Bändern in Querlage transportiert werden, ist diese Seite durch den Laserstrahl einfach zugänglich. Jeder Getränkekasten besitzt zwei kurze Griffleisten und dient somit, jede Griffleiste separat vermessen, als zweifaches Versuchsobjekt. Da die Getränkekästen symmetrische Geometrie aufweisen, müssten die Schwingspektren eines idealen Kastens, aufgenommen auf den gegenüberliegenden Griffleisten, identisch sein. Durch Verlust dieser Symmetrie aufgrund von Herstellungsschwankungen und auftretenden Beschädigungen, unterscheiden sich diese Spektren jedoch.

Ebenfalls zu kleinen Unterschieden in den Spektren eines Getränkekastens führt eine Abweichung im Einspann- und Messvorgang, da eine 100 %ig exakte Positionierung unter diesen gegebenen Bedingungen nur unter erhöhtem zeitlichem und apparativem Aufwand realisier-

bar ist. Aus diesem Grund erfolgten von jeder Kastenseite jeweils drei Mehrfachmessungen, um diese Schwankungen zu berücksichtigen.

Abbildung 4-29 zeigt exemplarisch den Mittelwert aus einer Vierfachbestimmung und die normierte (auf den Mittelwert bezogene) Standardabweichung. Gerade im oberen Frequenzbereich schwanken die Messungen sehr stark, was vor allem auf das Hintergrundrauschen und die Fremdschwingungen zurückzuführen ist. Im niederen Frequenzbereich treten die größten Schwankungen in den Schwingungen mit den hohen Amplituden auf. Dies resultiert vor allem aus der veränderten Dämpfung durch die ungenaue Einspannung.




Abbildung 4-29: Mittelwert und normierte Standardabweichung einer Mehrfachmessung

### 4.2.3 Eingangsdaten für die KNN

Die erfassten Schwingenspektren der zu untersuchenden Getränke Kästen dienen nach der beschriebenen Vorverarbeitung als Eingangsdaten für die KNN zur Zustandsprognose bzw. zum Netzwerktraining (vgl. Tabelle 4-8). Die Aufteilung der Datensätze erfolgte in je einen Trainingsdatensatz, einen Validierungsdatensatz und einen Testdatensatz. Die Trainingsdaten dienen zum Anpassen der Gewichte zwischen den Knoten. Die Validierungsdaten ermöglichen während des Trainingsvorganges eine Prüfung des Lernfortschrittes und geben einen Anhaltspunkt über die Vorhersagegüte der trainierten KNNs. Er enthält, durch die Mehrfachmessung bedingt, Datensätze von Kästen die in ähnlicher Form auch in den Trainingsdaten vorhanden sind. Jeder Datensatz wird aber insgesamt nur einmal verwendet. Die Aufteilung in Trainings- und Validierungsdaten erfolgt zufällig nach einem vorgegebenen Verhältnis von 9 zu 1. Nach jedem Lernzyklus folgt ein Validierungszyklus mit dem lernenden KNN. Es findet anhand der Validierungsdaten keine Anpassung der Gewichte statt, dies geschieht ausschließlich durch die Trainingsdaten. Die Abweichung der KNN-Ausgabe vom Vorgabewert dient als Fehlermaß und zeigt nach jedem Trainingszyklus den Lernfortschritt. Der Trainingsfehler nimmt im Lauf des Trainings stetig ab, bis er im Regelfall nach einer endlichen Anzahl an Trainingszyklen ein globales Minimum erreicht hat. Der Validierungsfehler hingegen nimmt im Regelfall, wie der Trainingsfehler, ab und steigt im Laufe des Trainings wieder an. Daraus lässt sich ableiten, dass zugunsten einer verbesserten Erkennung der Trainingsdaten eine schlechtere Prognose aller nicht in den Trainingsprozess integrierten Datensätze resultiert (vgl. Kapitel 2.5.2).

In den nachfolgend beschriebenen Kapiteln wurden die KNN jeweils bis zur Erreichung einer minimalen Fehlerrate von 0,05 trainiert. Dabei erfolgte alle 50 Trainingszyklen eine Abspeicherung der Netzwerkkonfiguration, um die Fehlerentwicklung zu protokollieren.

Bei den Testdaten handelt es sich um unbekannte, nicht in den Trainingsprozess integrierte Daten. Im Regelfall dienen die Testdaten dazu, eine abschließende Bewertung von fertig trainierten KNNs vorzunehmen. Es handelt sich demgemäß um eine finale Offline-Validierung aller berechneten KNN-Parameter. Im vorliegenden Fall wurden alle während des Trainings abgespeicherten KNNs offline validiert, um den Verlauf des Testfehlers während der KNN-Entwicklung besser darstellen zu können.

#### 4.2.4 Verwendete KNN

Tabelle 4-9 listet die Details zu den eingesetzten KNNs auf. Die Zahl der Eingangsneuronen variiert zwischen 16 und 128. Je kleiner diese Schicht ausfällt, desto stärker muss das Frequenzspektrum mit ursprünglich 1024 Datenpunkten komprimiert werden um als Eingabe für das KNN zu dienen. Dazu kommt das numerische Integrationsverfahren nach Simpson zum Einsatz. Jedes einzelne Eingangsneuron ist mit jedem Neuron in der ersten verdeckten Schicht verbunden. Diese Schicht wurde in den vorliegenden Versuchen immer halb so groß wie die Eingangsschicht gewählt. Sie umfasst acht Neuronen in KNN eins und 64 Neuronen in KNN sechs. In KNN vier und sechs ist nach der ersten verdeckten Schicht eine zweite verdeckte Schicht angeordnet. Die Anzahl der Knoten sind hier ebenfalls halb so viele wie in der vorangegangenen Schicht. Die Neuronen der ersten sind mit den Neuronen der zweiten Schicht wiederum über die veränderbaren Knotenverbindungen vernetzt. In der Ausgangsschicht befindet sich ein Neuron, welches vollständig mit den Knoten der vorangegangenen Schicht verbunden ist. Das Ausgangsneuron gibt nach außen den approximierten Zustand des zu Grunde liegenden Getränkekastens bekannt. Ein Wert größer 0.5 wird mit dem Zustand „Intakt“, ein Wert kleiner 0.5 mit dem Zustand „Defekt“ substituiert.

Tabelle 4-9: Übersicht der eingesetzten KNN

Anzahl der Neuronen in der ...	KNN ID					
	1	2	3	4	5	6
Eingangsschicht	16	32	64	64	128	128
1. verdeckten Schicht	8	16	32	32	64	64
2. verdeckten Schicht	-	-	-	16	-	32
Ausgangsschicht	1	1	1	1	1	1
Neuronen Gesamt	25	49	93	113	193	225
Neuronenverbindungen	136	528	2080	2576	8256	10272

Tabelle 4-9 verdeutlicht den Zusammenhang zwischen der Anzahl an Neuronen und der Anzahl der trainierbaren Gewichte. So stehen im KNN eins nur 136 Knotenverbindungen zur Informationsabbildung zur Verfügung, wohingegen KNN sechs insgesamt 10272 trainierbare Gewichte enthält. Während des Trainings erfolgt ausschließlich eine Anpassung der Verbindungsgewichte zwischen den Neuronen. Nehmen diese einen negativen Wert an, wirkt sich die Verbindung hemmend auf die Aktivität des Zielneurons aus. Ein positives Verbindungs-

gewicht bewirkt demnach einen verstärkenden Effekt der Aktivität. Knotenverbindungen mit dem Wert null unterbrechen die Informationsweitergabe im KNN und können letztendlich aus dem Netzwerk entfernt werden. Dieses Verfahren nennt sich „Pruning“ und bewirkt bei Netzen mit einer großen Anzahl an Neuronen eine Verringerung des Speicher- und Rechenaufwandes, da jedes Gewicht eine Gleitkommazahl mit einem Speicherverbrauch von 64 Bit belegt.

In den Auswertungen der Labordaten lieferten KNN eins bis drei sehr gute Ergebnisse. Bei den folgenden Auswertungen eines repräsentativeren Datenpools zeigte sich, dass diese KNN nicht ausreichen, um eine vollständige Abbildung der aufgenommenen Schadensmuster zu gewährleisten. Schlechte Erkennungsraten belegten dies. Deswegen kamen weitere KNN mit größeren Eingangsschichten sowie mit einer zweiten verdeckten Schicht für die Auswertungen zum Einsatz. Dabei tauchte unter anderem die Fragestellung nach der Abhängigkeit der Erkennungsrate von der Größe der Eingangsschicht sowie der Anzahl der verdeckten Schichten bzw. der verdeckten Knoten in einem Netzwerk und der damit zusammenhängenden Anzahl an trainierbaren Verbindungsgewichten zwischen den Neuronen auf. Diese finden in Kapitel 4.2.6.1 nähere Betrachtung.

Zur Vollständigkeit sei hier erwähnt, dass prinzipiell jede erdenkliche Netzwerktopologie bezüglich der Anzahl der Schichten, als auch der Anzahl der Knoten in den Schichten möglich ist. Die Untersuchungen zeigten aber sehr eindeutig, dass diese Konfigurationen im Vergleich mit den hier diskutierten keine Verbesserung der Erkennungsrate hervorbrachten. Auch die Größe der verdeckten Schichten, z.B. in einer Konfiguration 32-64-1 oder 32-64-128-1 usw., resultierten in einer nicht nennenswerten Änderung des Ergebnisses. Aus diesem Grund wurden diese Untersuchungen verworfen und sind nicht Teil der folgenden Ergebnisdiskussion.



## 4.2.5 Funktionsmuster 1

### 4.2.5.1 Versuche im Labor

Mit der in Kapitel 3 beschriebenen Anlage entstand durch Messungen am Versuchskastenpool I (vgl. Tabelle 4-8) eine Messdatensammlung bestehend aus 179 Einzelspektren, die in Rohdatenform die zeitlich aufgelösten Beschleunigungsdaten der kurzen Griffleisten in horizontaler Richtung enthalten. Die Aufteilung der Datensätze erfolgt nach dem beschriebenen Schema in Trainings-, Validierungs- und Testdaten. Eine Übersicht gibt Tabelle 4-10.

Tabelle 4-10: Zusammensetzung der KNN Eingangsdatensätze

Datensatz	Training		Validierung		Test	
	defekt	intakt	defekt	intakt	defekt	intakt
Anzahl	32	111	5	14	9	8

In Tabelle 4-11 sind die Ergebnisse dieses Netzwerktrainings aufgelistet. In den Spalten erscheinen die von den fertig trainierten Netzwerken ausgegebenen positiven Prognosen in Prozent bezogen auf die Anzahl der Datensätze (vgl. Tabelle 4-10).

Es zeigt sich, dass nur KNN 1 mit der Topologie 16-8-1 insgesamt fünf Datensätze falsch prognostiziert. Bei drei davon handelt es sich um defekte Kästen im Trainingsdatensatz und zwei defekte im Validierungsdatensatz. Die Kästen im Testdatensatz hingegen werden richtig erkannt. Scheinbar ist das kleine KNN mit nur 136 trainierbaren Verbindungsgewichten nicht fähig, den Zusammenhang zwischen allen Trainingsdatensätzen richtig abzubilden. Die erlernbaren Möglichkeiten an verschiedenen Schadensbildern sind in diesem Netzwerk begrenzt. Durch die Komprimierung der Datensätze von ursprünglich 1024 Werten auf 16 geht zu viel Information verloren, um eine differenzierte Aussage über den Zustand der einzelnen Prüflinge treffen zu können.

Tabelle 4-11: Vergleich der Prognosen der verschiedenen KNN

KNN ID	Daten	Positive Prognose (richtige Klassifizierung) [%]			
		Training	Validierung	Test	Gesamt
1 16-8-1	gesamt	97.9	89.5	100.0	97.2
	intakt	100.0	100.0	100.0	100.0
	defekt	90.6	60.0	100.0	89.1
2 32-16-1	gesamt	100.0	100.0	100.0	100.0
	intakt	100.0	100.0	100.0	100.0
	defekt	100.0	100.0	100.0	100.0
3 64-32-1	gesamt	100.0	100.0	100.0	100.0
	intakt	100.0	100.0	100.0	100.0
	defekt	100.0	100.0	100.0	100.0

Abbildung 4-30 illustriert den Verlauf des mittleren quadratischen Netzwerkfehlers im Verlauf der Trainingszyklen. Auch daraus ist klar ersichtlich, dass die Lernfähigkeit der KNNs von ihrer Topologie und dem Informationsgehalt in den verwendeten Daten abhängig ist. Während beim kleinsten KNN 1 mit nur 16 Eingangsknoten nach ca. 30 Trainingszyklen keine Abnahme des Trainingsfehlers mehr erkennbar ist, sinkt dieser bei den anderen beiden Netzen mit steigender Trainingsdauer. Die Verläufe sind bei KNN 2 und KNN 3 bis zum 30. Trainingszyklus ähnlich. Danach fällt der Trainingsfehler von KNN 3 sehr schnell ab, während der Trainingsfehler von KNN 2 flacher abnimmt. Nach 100 Trainingszyklen ist der Netzwerkfehler bei beiden Netzen so klein, dass alle Datensätze richtig erkannt werden.

Auch der Testfehler ist bei allen Netzwerkkonfigurationen nach 100 Trainingszyklen sehr klein. Das trainierte KNN ist damit in der Lage, alle 17 Test-Datensätze richtig zu prognostizieren. Da es sich dabei um Daten handelt, die nicht in den Trainings- und Validierungsdaten vorhanden sind, lässt sich daraus schließen, dass sich die benutzten Testkästen in einem Zustand befinden, der den Trainingskästen sehr ähnlich ist. Durch ihre Abstraktionsfähigkeit sind die Netze also in der Lage, aus ähnlichem Frequenzmuster eine Klassenbildung bzw. eine Kategorisierung vorzunehmen.




Abbildung 4-30: KNN-Fehler aufgetragen über Trainingszyklen

Der mittlere quadratische Testfehler (vgl. Tabelle 2-6) fällt hier in allen drei Fällen schneller ab als die jeweiligen Test- und Validierungsfehlerraten. Dies deutet darauf hin, dass sich in den Trainings- und Validierungsdatensätzen Spektren befinden, die nicht eindeutig erkannt werden und somit einen Fehler erzeugen. Die Testdaten hingegen scheinen ausschließlich aus Datenspektren zu bestehen, die das KNN während der Trainingsphase erlernt hat. Weiterhin ist an Abbildung 4-30 auffällig, dass bei KNN 1 der Testfehler mit steigender Anzahl an Trainingszyklen abnimmt, obwohl sich am Validierungs- und Trainingsfehler nichts bzw. nur noch sehr wenig ändert. Auch hier stehen die Problemdatensätze im Trainingsdatensatz in der Verantwortung. Der Trainingsalgorithmus versucht während des Trainings durch eine Änderung der KNN eine bessere Parametrierung zu finden, um den Fehler zu minimieren. Diese Parameteränderung bewirkt eine bessere Erkennung der Trainingsdaten und damit eine Verringerung des mittleren quadratischen Testfehlers, aber nicht, wie erwartet, eine Verbesserung der Erkennungsrate der Trainingsdaten.

### 4.2.5.2 Versuche auf Feldebene

In diesem Arbeitsschritt erfolgte der Transfer der bis dahin entwickelten Versuchsanlage in den Flaschenkeller des Mineralbrunnenbetriebes Frankenbrunnen in Neustadt an der Aisch. Hier fand erstmals der Test im industriellen Umfeld mit einer Vielzahl von Prüflingen aus allen Zustandskategorien statt. Da die Aussortierung der defekten Getränkekästen in diesem Betrieb zum Großteil noch von Hand erfolgt, liegt ein beträchtliches Interesse an einem zuverlässigen, automatischen Sortiersystem vor. Neben Temperaturschwankungen, Vibrationen durch den Anlagenbetrieb und den Transportverkehr beeinflussen auch Feuchtigkeit und Schmutz das Messsystem. Daher wurden die im Labor vorkalibrierten KNN im Betrieb mit dort aufgenommenen Messspektren nachkalibriert.

Auch bei dieser Auswertung erfolgte die Aufteilung der Datensätze nach dem bekannten Schema in Trainings-, Validierungs- und Testdaten. Eine Übersicht gibt Tabelle 4-12.

Tabelle 4-12: Zusammensetzung der KNN Eingangsdatensätze

Datensatz	Training		Validierung		Test	
	defekt	intakt	defekt	intakt	defekt	intakt
Anzahl	1359	1502	159	160	248	328

In Tabelle 4-13 sind die Ergebnisse dieses Netzwerktrainings aufgelistet. In den Spalten erscheinen die von den fertig trainierten Netzwerken ausgegebenen positiven Prognosen in Prozent bezogen auf die Anzahl der Datensätze (vgl. Tabelle 4-12).

Tabelle 4-13: Vergleich der Prognosen der verschiedenen KNN

KNN ID	Daten	Positive Prognose (richtige Klassifizierung) [%]			
		Training	Validierung	Test	Gesamt
1 16-8-1	gesamt	84.3	74.6	63.2	80.2
	intakt	85.8	79.4	73.8	83.3
	defekt	82.6	69.8	49.2	76.7
2 32-16-1	gesamt	94.7	83.1	62.2	88.7
	intakt	96.7	84.0	78.0	92.5
	defekt	92.6	82.0	41.1	84.5
3 64-32-1	gesamt	95.3	84.6	64.9	89.8
	intakt	96.6	82.6	78.4	92.5
	defekt	93.9	86.5	47.2	86.6
4 64-32-16-1	gesamt	98.8	90.3	60.8	92.3
	intakt	99.3	90.6	69.2	93.7
	defekt	98.3	90.0	49.6	90.7
5 128-64-1	gesamt	95.0	86.5	63.5	89.5
	intakt	94.4	85.4	75.3	90.5
	defekt	95.6	87.8	48.0	88.3
6 128-64-32-1	gesamt	94.9	85.9	65.3	89.6
	intakt	95.2	85.4	78.1	91.5
	defekt	94.7	86.5	48.4	87.5

Betrachtet man die Ergebnisse zeigt sich, dass KNN 4 mit der Konfiguration 64-32-16-1 in der Trainingsphase die besten Ergebnisse erreicht. Da für alle Netzwerke das gleiche Abbruchkriterium galt, ist hieraus zu folgern, dass sich der mittlere quadratische Fehler, der über alle Patterns berechnet wird, bei den verschiedenen Netzen unterschiedlich auswirkt. Während bei KNN 4 viele Patterns einen kleinen bleibenden Fehler in ihrer Prognose aufweisen, der durch die gewählte Kategoriengrenze bei 0.5 nicht zu einer Falschklassifizierung führt, haben die anderen Netzwerke anscheinend bei einigen Datensätzen größere Probleme diese einer Kategorie zuzuordnen. Diese Prognoseabweichungen wirken sich somit zwar gleich auf den mittleren quadratischen Netzwerkfehler aus, haben aber auf das Gesamtprognoseergebnis einen entscheidenden Einfluss, da die entsprechenden Datensätze einer anderen Kategorie zugeordnet werden. Dies zeigt sich auch in den Validierungsergebnissen, bei denen ebenso das KNN 4 mit einer positiven Erkennungsrate von ca. 90 % am besten abschneidet. Die

Testergebnisse von KNN 4 fallen aber neben einigen anderen mitunter am schlechtesten aus. Das KNN vermag in diesem Stadium vor allem defekte Kästen nur noch mit einer Rate von ca. 50 % richtig zu klassifizieren. Die Ursache für diese schlechten Ergebnisse ist zweifelsfrei mit dem „Overfitting-Effekt“ zu erklären. Das bedeutet, das KNN hat sich während der Trainingsphase so gut an die präsentierten Schadensfälle angepasst, dass seine Generalisierungsfähigkeit dabei verloren ging. Da die Validierungsdaten im Zufallsprinzip aus den Trainingsdaten entnommen wurden, erreicht die Validierungsrate einen ähnlich guten Wert. Die Validierungsdaten haben aber nach wie vor keinen Einfluss auf den Trainingsvorgang, sondern dienen nur zur Überwachung während des Trainings. Die Testdaten sind aus insgesamt zwei kompletten Messreihen zusammengestellt. Dabei kamen bis dato ungeprüfte Kästen aus dem Kastenmagazin zum Einsatz. Darin hat sich mit hoher Wahrscheinlichkeit eine große Anzahl an schadhafte Exemplaren befunden, deren Frequenzmuster sich von den Trainingsdatensätzen so stark unterscheiden, dass das KNN mit seiner Generalisierung an seine Grenzen gerät. Dies bestätigt die Aussage, dass ein KNN nur mit einem repräsentativen Datenpool optimal trainierbar ist, der das gesamte Spektrum an auftretenden Schadensbildern abbildet.




Abbildung 4-31: Mittlerer quadratischer Trainingsfehler

Betrachtet man neben den Endergebnissen zusätzlich die Verläufe des mittleren quadratischen Netzwerkfehlers, aufgetragen über die Anzahl der Trainingszyklen, wird deutlich, dass mit Vergrößerung der Eingangsschicht, welche eine Vergrößerung der bereitgestellten Informati-

onen bedeutet, die Anpassung der Verbindungsgewichte zur Erreichung eines vorgegebenen mittleren Netzwerkfehlers mit wenigen Trainingszyklen erreicht wird (vgl. Abbildung 4-31 bis Abbildung 4-33). Der große Sprung zwischen KNN 3 und 4, welche beide eine Eingangsschicht von 64 Knoten besitzen und damit die gleichen Informationen zum Training zur Verfügung hatten, lässt darauf schließen, dass nicht nur die Eingangsschicht eine Rolle spielt, sondern auch die Anzahl der Knoten im Netzwerk sowie die Gewichte als Verbindungen zwischen den Knoten.




Abbildung 4-32: Mittlerer quadratischer Validierungsfehler

Der Verlauf des mittleren quadratischen Validierungsfehlers ist den Verläufen der Trainingsfehler sehr ähnlich, stagniert aber mit zunehmender Anzahl an Trainingszyklen oder steigt, wie im Fall KNN 6 und KNN 2, wieder an. Daraus lässt sich die These des Auswendiglernens untermauern, bei dem das Netzwerk seine Generalisierungsfähigkeit verliert. Das globale Minimum im betrachteten Funktionsbereich der Validierungsfunktion von KNN 6 liegt bei ca. 300 Trainingszyklen. Dabei werden 87,15 % aller Validierungsdatensätze, 67,19 % aller Testdatensätze und 91,51 % der Trainingsdatensätze vom KNN richtig prognostiziert. Da die Trainingsdatensätze den anderen beiden aber zahlenmäßig weit überwiegen, wirkt sich die geringfügig gesunkene Erkennungsrate der Trainingsdaten negativ auf die Gesamterkennungsrate aus. Diese sinkt in diesem Beispiel auf einen Wert von 87,41 %. Einer verbesserten Erkennung der Schäden aus den Testdaten steht demnach eine schlechtere Erkennung der

Standardschäden aus den Trainingsdaten gegenüber.

Betrachtet man den Verlauf des mittleren quadratischen Testfehlers, so zeigt sich nochmals sehr deutlich, dass die eingesetzten KNN ohne Ausnahme mit zunehmenden Trainingszyklen die Fähigkeit verlieren, die Testdatensätze richtig zu prognostizieren (vgl. Abbildung 4-33).




Abbildung 4-33: Mittlerer quadratischer Testfehler

Abschließend lässt sich aus diesen Ergebnissen zusammenfassen, dass eine optimale Vorhersage der Zustände von Getränkekästen sehr stark von der Vorverarbeitung der aufgenommenen Frequenzspektren abhängig ist. Eine zu hohe Komprimierung führt dabei zu einem Verlust von essentiellen Informationen. Benutzt man hingegen große Eingabeschichten, führt dies einerseits zu einem hohen Informationsgehalt in den Eingabedaten, hat aber auch zur Folge, dass die Anzahl der Verbindungsgewichte stark ansteigt (vgl. Tabelle 4-9). Dies hat zur Folge, dass ein KNN sehr schnell lernt, bekannte Datensätze richtig zu prognostizieren, seine Generalisierungsfähigkeit jedoch abnimmt. Eine tiefer gehende Untersuchung dieser Aussagen erfolgt in den folgenden Kapiteln.



## 4.2.6 Funktionsmuster 2

Bei Funktionsmuster 2 handelt es sich, wie bereits beschrieben, um den Transfer der aufgebauten Experimentieranlagen in ein praxistaugliches Linienaggregat. Mit Hilfe eines Kastenpools, bestehend aus 40 defekten und 89 intakten Kästen, entstand eine Datensammlung aus 1483 Einzelspektren, die im weiteren Verlauf zur Auswertung dienen. Eine Übersicht der Zusammensetzung gibt Tabelle 4-14. Der Trainingsdatensatz mit 1206 Einzelspektren enthält Spektren von defekten und intakten Getränkekästen. Der Validierungsdatensatz ist aus demselben Datenpool wie der Trainingsdatensatz nach dem Zufallsprinzip entnommen und enthält 135 Messungen. Der Testdatensatz wurde in dieser Untersuchung in drei Teile aufgeteilt, um eine differenzierte Aussage über die Prognosefähigkeit der trainierten Netze machen zu können. Dabei handelt es sich um drei Datensätze mit insgesamt 142 Messungen. Test 1 enthält ausschließlich Schwingungsdaten von defekten Kästen. Die Datensätze 2 und 3 enthalten Informationen von intakten Kästen, wobei der Datensatz Test 2 ausschließlich mit fabrikneuen und Test 3 mit gebrauchten Kästen erzeugt wurde.

Tabelle 4-14: Zusammensetzung der KNN Eingangsdatensätze

Datensatz	Training	Validierung	Test 1	Test 2	Test 3
Zustand	defekt + intakt		defekt	intakt (neu)	intakt (gebraucht)
Anzahl	1206	135	45	48	49

Die Zusammenfassung der ursprünglich 1024 Datenpunkte fassenden Frequenzspektren erfolgt wie in den vorangegangenen Untersuchungen mit Hilfe der numerischen Integration nach Simpson. Je nach eingesetztem KNN (Übersicht in Tabelle 4-9) erfolgte die Komprimierung in 16, 32, 64 oder 128 Datenpunkte der kompletten Frequenzspektren von 0 bis 5 kHz. Während des Trainings erfolgte alle 50 Trainingsschritte eine Abspeicherung der trainierten Gewichte, um danach den Trainingsverlauf berechnen und mit den anderen KNNs vergleichen zu können. Abbruchkriterium für das KNN-Training war wie schon zuvor der mittlere quadratische Trainingsfehler, der in den vorliegenden Versuchsreihen einen Wert unter 0.05 einnehmen musste. Tabelle 4-15 zeigt, wie viele Trainingszyklen beim Training der verschiedenen KNNs dazu notwendig waren.

Tabelle 4-15: Übersicht der durchgeführten Trainingszyklen

KNN ID	1	2	3	4	5	6
Trainingszyklen	15.000	650	650	400	300	200

Vergleicht man die Gesamtzahl der Knotenverbindungen (siehe Tabelle 4-9) mit der Anzahl der benötigten Trainingszyklen wird deutlich, dass diese umgekehrt zueinander proportional sind. Da in einem Trainingszyklus die Anpassung aller Gewichte erfolgt, ist die Gesamtzahl der neu berechneten Gewichte pro Zyklus abhängig von der Netzwerkgröße. Wie in Tabelle 4-15 zu erkennen ist, nimmt mit zunehmender Netzwerkgröße die Anzahl der benötigten Lernzyklen zur Erreichung eines vorgegebenen Trainingsfehlers ab. Während bei KNN 6 der mittlere quadratische Fehler nach ca. 200 Lernzyklen den Wert 0.05 erreicht, benötigt KNN 1 ca. 15.000 Lernzyklen. Vergleicht man die Anzahl der insgesamt vorgenommenen Gewichtsveränderungen, zeigt sich, dass KNN 2 zur Erreichung des vorgegebenen Kriteriums mit Abstand den geringsten Rechenaufwand verursacht (vgl. Abbildung 4-34).




Abbildung 4-34: Angepasste Gewichte in den KNN

#### 4.2.6.1 Auswirkung der KNN-Topologie auf die Prognosefähigkeit

Das vorgegebene Kriterium für den Trainingsabbruch war die Unterschreitung des mittleren quadratischen Fehlers bei einem Wert von 0.05. Das bedeutet, dass das KNN in der Lage ist, den vorgegebenen Trainingsdatenpool richtig abzubilden.

Aussagen über die Gesamtprognosefähigkeit gibt die Berechnung des Validierungs- und des Testfehlers, da diese Daten nicht für das Training eingesetzt werden und somit ein Maß für die Generalisierungsfähigkeit des KNN darstellen. Erreicht der mittlere quadratische Netzfehler hierbei ähnlich gute Werte wie im Training, so ist das KNN optimal parametrisiert und für die Anwendung zur Prognose des Zustandes unbekannter Getränkekästen fähig.

In Tabelle 4-16 sind die Ergebnisse dieses Netzwerktrainings aufgelistet. In den Spalten erscheinen die von den fertig trainierten Netzwerken ausgegebenen positiven Prognosen in Prozent bezogen auf die Anzahl der Datensätze.

Eine Analyse der Ergebnisse aus Tabelle 4-16 erklärt KNN 3 mit der Topologie 64-32-1 mit insgesamt 93 Neuronen und 2080 Neuronenverbindungen zum Auswerteverfahren mit der besten Gesamterkennungsrate von 95.14 %. Es ist in der Lage, aus dem vorliegenden Datenmaterial 97.98 % der intakten und 88.46 % der defekten Getränkekästen richtig zu klassifizieren. Bei der Erkennung der Validierungsdaten erreicht dieses Netzwerk sowohl bei den defekten als auch bei den intakten Prüflingen im Vergleich zu den anderen KNNs immer die höchste Erkennungsrate. Bei der Klassifizierung von unbekanntem Schadensbildern zeigt diese Netzkonfiguration Schwächen. So erreicht es bei den defekten Kästen aus Testdatensatz 1 nur ein Ergebnis im Mittelfeld. Mit einer Erkennungsrate von nur 80 % steht es hinter dem KNN 4, das diesen Testdatensatz zu 84,44 % richtig zu klassifizieren vermag.

Bei der Erkennung der neuen Getränkekästen aus Testdatensatz 2 zeigt sich KNN 2 mit 97,92 % als die am besten geeignete Möglichkeit und KNN 5 erreicht 97,96 % mit Abstand das beste Erkennungsergebnis bei der Kategorisierung der gebrauchten Prüflinge aus Testdatensatz 3.

Es zeigt sich auch hier die Tendenz, dass mit steigender Erkennungsrate während der Trainingsphase die Generalisierungseigenschaften der KNN verloren gehen und als Resultat die nicht erlernten Muster nur noch unzureichend eingestuft werden können. Die Prognoseergebnisse der Testdatensätze untermauern dies.

Die Tatsache, dass in den Testdatensätzen nicht erlernte Schwingspektren enthalten sind, verdeutlicht, wie wichtig eine ausgewogene Verteilung der Trainingsdatensätze ist. KNN 5 und KNN 6 zeigen, dass die unbekanntes Schwingspektren durch Generalisierung zum Großteil richtig erkannt werden. Die durchgehend schlechten Ergebnisse bei der Erkennung der defekten Kästen aus Testdatensatz 3 belegen, dass die untersuchten Konfigurationen nur unzureichend in der Lage sind, die darin enthaltenen Beschädigungen an den Getränkekästen zu klassifizieren. Eine Erweiterung der Testdaten mit Spektren aus dieser Klasse kann diesem Manko Abhilfe schaffen und somit eine Verbesserung aller Schadenskategorien herbeiführen.

Tabelle 4-16: Vergleich der Prognosen der verschiedenen KNN

KNN ID	Daten	Positive Prognose (richtige Klassifizierung) [%]					
		Training	Validierung	Test 1	Test 2	Test 3	Gesamt
1	gesamt	95.19	91.85	75.56	77.08	87.76	93.46
	intakt	99.18	98.88	--	77.08	87.76	97.60
	defekt	85.47	78.26	75.56	--	--	83.71
2	gesamt	94.86	88.89	68.89	81.25	91.84	92.99
	intakt	98.82	96.88	--	81.25	91.84	97.50
	defekt	85.47	69.23	68.89	--	--	82.35
3	gesamt	96.19	97.04	80.00	81.25	91.84	95.14
	intakt	99.17	99.03	--	81.25	91.84	97.98
	defekt	89.23	90.63	80.00	--	--	88.46
4	gesamt	95.77	94.81	84.44	85.42	51.02	93.53
	intakt	98.81	96.12	--	85.42	51.02	95.68
	defekt	88.77	90.63	84.44	--	--	88.46
5	gesamt	96.02	88.89	82.22	79.17	97.96	94.47
	intakt	98.47	93.48	--	79.17	97.96	97.12
	defekt	90.11	79.07	82.22	--	--	88.24
6	gesamt	96.68	91.85	82.22	97.92	95.92	90.18
	intakt	99.18	97.83	--	97.92	95.92	96.34
	defekt	90.68	79.07	82.22	--	--	75.39

Der Verlauf des mittleren quadratischen Netzwerkfehlers während der Trainingsvorgänge gestaltet sich ähnlich der im vorherigen Abschnitt gezeigten (vgl. Abbildung 4-35). Anhand der Abnahme des Fehlers mit steigender Anzahl an Trainingszyklen, was durch das Training beabsichtigt wird, lässt sich die zuvor aufgestellte These bestätigen, dass sich mit zunehmender Anzahl an trainierbaren Gewichten eine schnellere Konditionierung der KNN durchführen lässt. Während KNN 6 zur Unterschreitung des vorgegebenen Netzwerkfehlers 200 Trainingszyklen durchlaufen muss, benötigt der Netzwerktrainer für das KNN 5 ca. 300 Durchgänge. Da beide Netze mit derselben Information gefüttert werden, muss der Unterschied in der Anzahl der Neuronenverbindungen begründet liegen. Diese Tatsache ist ebenso zwischen den KNN 4 und 5 zu beobachten. In KNN 1 nimmt der mittlere quadratische Netzwerkfehler nur sehr langsam ab und erreichte nach ca. 50.000 Zyklen einen Fehler von ca. 0.06. Die Eignung dieser Topologie scheint fragwürdig, da eine Konditionierung des KNN sehr viel Zeit in Anspruch nimmt.




Abbildung 4-35: Mittlerer quadratischer Trainingsfehler beim Trainingsprozess

Der Verlauf des mittleren quadratischen Netzwerkfehlers in der Validierungsphase weist die gleichen Tendenzen wie der in der Trainingsphase auf (vgl. Abbildung 4-36). Da die Validierungsdatensätze nicht aktiv zum Training der KNN herangezogen werden, ist die Abnahme des Fehlers ein positives Zeichen für den Lernerfolg der KNN, da diese indiziert, dass das KNN auch in der Lage ist, unbekannte Spektren zu klassifizieren. KNN 4 weist dabei den

besten Verlauf des Fehlers auf. Der Graph des Fehlers von KNN 6 endet bereits nach 200 Trainingszyklen, da das KNN dann einen mittleren quadratischen Trainingsfehler von unter 0,05 erreicht hat und das Training somit endet, obwohl der Validierungsfehler bei 0,08 stehen bleibt. Ebenso endet das Training von KNN 5 schon nach 300 Lernzyklen und der Validierungsfehler beträgt dann ca. 0,09.




Abbildung 4-36: Mittlerer quadratischer Validierungsfehler beim Trainingsprozess

Auch die Testfehler haben keinen aktiven Einfluss auf den Trainingsverlauf. Ihre Berechnung erfolgt in der Regel nach dem Training mit dem vollständig ausgebildeten KNN. Um den Verlauf des Testfehlers zu verschiedenen Trainingsphasen nachstellen zu können, ist es deswegen nötig, die KNN während des Trainings immer wieder abzuspeichern, um diese quasi fertigen KNN für die Berechnung heranzuziehen. Da sich in den Testdatensätzen, wie schon erwähnt, gänzlich unbekannte Spektren von Kästen mit besonderen Schäden, aber auch fabrikneuer Exemplare befinden, sind die Verläufe des mittleren quadratischen Fehlers nicht so streng fallend wie bei der Trainings- oder Validierungskurve. Es geschieht sogar, dass der Fehler in extremen Fällen wieder stark zunimmt. Den Verlauf der Testfehler zeigen die folgenden Abbildungen.




Abbildung 4-37: Mittlerer quadratischer Testfehler nach dem Trainingsprozess

(Testdatensatz 1)




Abbildung 4-38: Mittlerer quadratischer Testfehler nach dem Trainingsprozess

(Testdatensatz 2)




Abbildung 4-39: Mittlerer quadratischer Testfehler nach dem Trainingsprozess

(Testdatensatz 3)

Aus dieser Untersuchung folgt, dass das Erlernen der Einstufung des Zustandes von Getränkekästen anhand der vorliegenden Datenspektren möglich ist. Die Abbildung der Zusammenhänge zwischen Schaden und Schwingbild kann in neuronalen Netzen abgebildet werden, welche durch ihre Generalisierungsfähigkeit in der Lage sind, zu klassifizieren. Je mehr Knotenverbindungen in einem KNN vorhanden sind, desto weniger Lernzyklen sind zur Anpassung der Gewichte notwendig. Dies kann damit begründet werden, dass jede Knotenverbindung pro Zyklus einmal angepasst wird. Bei mehr Knoten gibt es mehr Verbindungen und deswegen ist die Anzahl der angepassten Knoten pro Zyklus größer. Daraus lässt sich schließen, dass die Anzahl der Knotenanpassungen als Kriterium herangezogen werden muss, um eine Bewertung des Rechenaufwandes vorzunehmen.

Mit größeren Eingangsschichten sind die Informationen, welche das KNN zur Klassifizierung zur Verfügung gestellt bekommt, durch eine größere Anzahl an Datenpunkten differenzierbarer, was eine Verbesserung der Erkennungsrate zur Folge hat. Größere Eingangsschichten fordern einen geringeren Komprimierungsgrad der Originaldaten und haben somit eine verbesserte Informationszugänglichkeit zur Folge. Die Auswirkungen der Komprimierung auf die Erkennungsrate der KNN findet im Folgenden deswegen gesondert Beachtung.



#### 4.2.6.2 Auswirkungen der Datenkomprimierung auf die Prognosefähigkeit

Um die mittels Laser erfassten Schwingungen der Getränkekästen für eine Auswertung mittels KNN nutzbar zu machen, erfolgt eine Datenvorverarbeitung, welche im Abschnitt 2.4 beschrieben ist. Mittels einer Fourieranalyse wird das Beschleunigungssignal in seine Einzelteile zerlegt und anhand einer Frequenz-Amplituden-Auftragung dargestellt. Dieses Signal enthält alle Schwingamplituden bis zu einer Frequenz von 5 kHz, welches durch ein Komprimierungsverfahren in ein Datenspektrum für die KNN umgewandelt wird.

Dieser Abschnitt behandelt die Auswirkungen auf die Prognosefähigkeit bei Auswertung von nur einem Teil des Gesamtspektrums. In Tabelle 4-17 sind die vier benutzten Datensätze beschrieben. Bei K0 handelt es sich um das Originalspektrum mit den Amplituden von 0 bis 5 kHz. Damit dieses Spektrum in einem KNN mit der Topologie 32-16-1 zum Training herangezogen werden kann, wird es komprimiert, so dass sich nun in einer Klasse die Amplituden von jeweils 156,25 Hz befindet. In K1 befinden sich die Informationen aus dem Spektrum von 0 bis 1562,5 Hz und es geschieht auch hier eine Komprimierung auf 32 Klassen mit einer Frequenzbreite von jeweils 48,83 Hz. Genauso erfolgte die Vorverarbeitung der Daten im Eingangsdatensatz K2 und K3, wobei immer weniger Informationen des Gesamtspektrums in die neuen Datensätze übernommen wurden.

Tabelle 4-17: Komprimierung der Eingangsdaten der KNN

	$f_u$ [Hz]	$f_o$ [Hz]	$\Delta f_{neu}$ [Hz]	$\Delta f_{original}$ [Hz]	Komprimierung	Eingangsknoten
K0	0	5000	156.25	4.88	32	32
K1	0	1562.5	48.83	4.88	10	32
K2	0	937.5	29.29	4.88	6	32
K3	0	625	19.53	4.88	4	32

Eine Zusammenfassung der Ergebnisse zeigt Tabelle 4-18. Die beste Gesamterkennungsrate von 98,38 % erreicht in dieser Untersuchung das Datenmaterial K1. Die Spektren der defekten als auch die der intakten Getränkekästen im Trainingsdatensatz werden vom benutzten KNN mit über 99prozentiger Sicherheit klassifiziert. Auch Spektren, die in den anderen Datensätzen der Datensammlung K1 enthalten sind, weist das KNN überwiegend den richtigen Zustand zu. Im Vergleich zum ursprünglichen Verfahren, das im vorherigen Abschnitt diskutiert wurde, erweist sich diese Methode der Datenvorverarbeitung als geeignet, die Erkennungsrate zu verbessern. Vergleicht man die Gesamterkennungsraten des vorherigen KNN 3

(vgl. Tabelle 4-16), so verdeutlicht sich eine Steigerung um fast 3 %. Die Erkennung der Spektren in allen Kategorien, lediglich der Validierungsdatensatz macht hier eine Ausnahme, weisen eine verbesserte Klassifizierung auf.

Tabelle 4-18: Ergebnisse des KNN-Trainings

KNN ID	Daten	Positive Prognose (richtige Klassifizierung) [%]					
		Training	Validierung	Test 1	Test 2	Test 3	Gesamt
K0	gesamt	94.86	88.89	68.89	81.25	91.84	92.99
	intakt	98.82	96.88	--	81.25	91.84	97.50
	defekt	85.47	69.23	68.89	--	--	82.35
K1	gesamt	99.83	94.07	86.67	91.67	91.84	98.38
	intakt	99.88	97.83	--	91.67	91.84	98.94
	defekt	99.72	86.05	86.67	--	--	97.06
K2	gesamt	95.27	87.41	84.44	58.33	91.84	92.92
	intakt	97.88	94.74	--	58.33	91.84	95.49
	defekt	89.08	70.00	84.44	--	--	86.88
K3	gesamt	95.44	92.59	86.67	93.75	97.96	94.94
	intakt	98.21	98.13	--	93.75	97.96	97.98
	defekt	89.16	71.43	86.67	--	--	87.78

Daraus lässt sich ableiten, dass die für eine Klassifizierung eines Getränkekastens aussagekräftigsten Informationen im Frequenzbereich unter 1562 Hz liegen. Weiterhin lässt sich folgern, dass bei einer Verringerung der Informationen zu kleineren Frequenzen wichtige Informationen abgeschnitten werden, die für eine optimale Klassifizierung nötig sind. Die Auswahl von allen Frequenzen bis 5 kHz, wie bei K0 der Fall, enthält zwar ein Maximum an Informationen zur Einstufung der Zustände, diese gehen aber durch die Komprimierung zugunsten einer möglichst kleinen Eingangsschicht wieder verloren. Daraus lässt sich folgern, dass es nicht darauf ankommt, möglichst viele Frequenzen als Eingangsdaten zu verwenden, sondern nur die informationstragenden. Eine Komprimierung macht nur dann Sinn, wenn dadurch ein Informationserhalt gewährleistet ist. Die Zusammenfassung korrelierender Informationen bietet sich hier an.

Ein Verfahren für diese gefolgerten Verbesserungen ist die Hauptkomponentenanalyse, welche im nächsten Kapitel ausführlich Erläuterung findet. Die Verläufe der Trainingsdiagramme zu diesem Abschnitt befinden sich im Anhang 6.3.

### 4.2.6.3 Hauptkomponentenanalyse

Wie in Kapitel 2.4.2.2 beschrieben, dient die Hauptkomponentenanalyse dazu, die problem-spezifischen Eigenschaften von Daten herauszuarbeiten. Dabei ist meist nicht ein einzelner direkter Zusammenhang zwischen einer gemessenen Größe und einer gesuchten Lösung gegeben, sondern vielmehr die Kombination mehrerer Messgrößen. Hauptkomponenten sind Linearkombinationen, also neue, künstlich erschaffene Variablen der ursprünglich gemessenen Merkmale. Diese neuen Merkmale sind selbst nicht direkt messbar und werden aus den zur Verfügung stehenden Messdaten errechnet. Betrachtet man das Frequenzspektrum der Schwingungen eines Kastens als einen Vektor mit 1024 Dimensionen, so hat die Hauptkomponentenanalyse eine Reduzierung der Dimensionen zum Ziel, ohne dabei den darin enthaltenen Informationsgehalt zu verringern. Der Informationsgehalt der Daten wird hierbei mit der Variation der Datensätze bei einzelnen Schwingfrequenzen festgelegt. Redundante Informationen hoch korrelierter Vektoren fasst man deswegen zusammen und ist somit in der Lage, die Dimension der einzelnen Messdatensätze zu verringern.

In der vorliegenden Anwendung kommen die Frequenzspektren, die zuvor zur Auswertung mit den KNN genutzt wurden, zum Einsatz (vgl. Tabelle 4-19).

Tabelle 4-19: Verwendetes Datenmaterial

Zeilenvektoren	Spaltenvektoren $V_{Mm}$							
	$V_{M1}$	$V_{M2}$	$V_{M3}$	$V_{M4}$	$V_{M5}$	$V_{Mm}$	$V_{M1024}$	
$V_{Nn}$	Frequenz [Hz]							
	4,88	9,77	14,65	19,53	24,41	$\Delta f = 4,88$	5000	
$V_{N1}$	Messdatensatz 1	M1	M2	M3	M4	M5	.....	M1024
$V_{N2}$	Messdatensatz 2	M1	M2	M3	M4	M5	.....	M1024
$V_{N3}$	Messdatensatz 3	M1	M2	M3	M4	M5	.....	M1024
$V_{N4}$	Messdatensatz 4	M1	M2	M3	M4	M5	.....	M1024
...	...	<p><math>N \times M</math>-Messdatenmatrix nach der Fouriertransformation als Ausgangsmatrix für die Hauptkomponentenanalyse. In den <math>N</math> Zeilen sind die Datensätze aus 1482 Messungen angeordnet.</p> <p>In den <math>M</math> Spalten finden sich 1024 Merkmale pro Messdatensatz, die die Amplituden der Teilschwingungen bei der jeweiligen Frequenz in <math>[m/s^2]</math> enthalten.</p> <p>Addiert man die 1024 Einzelschwingungen auf, so erhält man das ursprünglich gemessene Schwingungssignal.</p> <p>Zentrierung und Standardisierung geschieht mit dem Spaltenmittelwert bzw. der Standardabweichung pro Spalte.</p>						
...	...							
...	...							
$V_{Nn}$	Messdatensatz n...							
...	...							
...	...							
$V_{N1024}$	Messdatensatz 1482	M1	M2	M3	M4	M5	.....	M1024
Mittelwert		MW1	MW2	MW3	MW4	MW5	MWm	MW1024
Standardabweichung		SD1	SD2	SD3	SD4	SD5	SDm	SD1024

Bevor die Frequenzspektren einer Hauptkomponentenanalyse unterzogen werden, geschieht eine essentielle Vorbereitung der Daten. Dazu findet eine Zentrierung sowie Standardisierung der Merkmale (Spalten) statt. Im Folgenden findet dieses Verfahren anhand einer Frequenzkurz Erläuterung.

Der Gesamtdatensatz mit allen Frequenzspektren ist in einer NxM-Matrix zusammengefasst. Die einzelnen Spektren n sind zeilenweise angeordnet und bestehen jeweils aus 1024 diskreten Schwingungsamplituden, welche durch Zerlegung des Beschleunigungssignals mit Hilfe der Fourier-Transformation berechnet wurden. Abbildung 4-40 zeigt exemplarisch diese Schwingungsanteile bei 488 Hz für alle 1482 Datensätze. Es zeigt sich, dass bei dieser Frequenz manche Kästen mit sehr hoher Amplitude (bis 130 m/s<sup>2</sup>) aber auch mit sehr niedrigen Amplituden, die gegen 0 m/s<sup>2</sup> gehen schwingen.




Abbildung 4-40: Amplituden der Originaldatensätze bei  $f=488$  Hz

Als erster Vorverarbeitungsschritt erfolgte eine spaltenweise Zentrierung der Originaldatenmatrix um den jeweiligen arithmetischen Spaltenmittelwert  $m_m$ .

$$x_i^z = x_i - m_m \text{ mit } m_m = \frac{1}{N} \sum_{i=1}^N x_i^o$$

Bei der Zentrierung rückt die Objektpunktmenge mit ihrem Mittelwert in den Koordinatenursprung, wodurch alle Objekte nicht mehr Absolutgrößen darstellen, sondern eine Abweichung

von einem Durchschnittsobjekt. Der Mittelwert jedes Spaltenvektors ist somit 0. Hierdurch wird vermieden, dass Frequenzanteile mit einem hohen Mittelwert gegenüber kleinen Amplituden dominieren. Außerdem kommen dabei v. a. Frequenzen zum Vorschein, deren Amplitude in den einzelnen Spektren stark variiert und somit ein Anzeichen für eine veränderte Geometrie darstellt.

Nach der Zentrierung erfolgt in einem weiteren Verfahrensschritt die Standardisierung der Spaltenvektoren mit der Standardabweichung  $s(x)$  der jeweiligen Spalte  $m$ .

$$x_i^s = \frac{x_i^z}{s_m(x^z)} \text{ mit } s_m(x^z) = \sqrt{\frac{\left(N \sum_{i=1}^N (x_i^z)^2\right) - \left(\sum_{i=1}^N x_i^z\right)^2}{N(N-1)}}$$

Die Spaltenvektoren haben nun jeweils eine Standardabweichung von 1, wodurch Frequenzen mit einer durchschnittlich niedrigen Amplitude in gleichem Maße Berücksichtigung finden wie die Hauptschwingungen mit einer großen Amplitude. Abbildung 4-41 zeigt wiederum diesen Vorverarbeitungsschritt anhand der Amplitude bei 488 Hz für alle Messungen. Bei Verfahren mit Variablen verschiedenen Ursprungs bzw. unterschiedlicher Skalierung erreicht man mit diesem Verfahren eine Entdimensionierung der Variablen und macht diese somit untereinander vergleichbar.

Aus dem nach Vorbehandlung der Rohdaten gewonnenen Datensatz  $X$  mit  $M$  Spalten (entspricht den Frequenzklassen aus der Fouriertransformation) und  $N$  Zeilen (entspricht den einzelnen Messungen) wird durch die Operation

$$K = \frac{X^{zT} X^z}{n-1} \text{ bzw. } R = \frac{X^{zsT} X^{zs}}{n-1}$$

eine symmetrische Matrix mit  $M$  Spalten und  $M$  Zeilen gebildet. Im Falle zentrierter Daten handelt es sich um die Kovarianz-Matrix  $K$ , bei zusätzlich standardisierten Daten um die Korrelationsmatrix  $R$  (vgl. Tabelle 4-20).




Abbildung 4-41: Zentrierte und standardisierte Amplituden der Originaldatensätze bei  $f=488$  Hz

Tabelle 4-20: Korrelationsmatrix R berechnet aus den Originaldaten

	$V_{M1}$	$V_{M2}$	$V_{M3}$	$V_{Mm}$	$V_{M1024}$
$V_{M1}$	Kor (1,1)	Kor (1,2)	Kor (1,3)	Kor (1,m)	Kor (1,1024)
$V_{M2}$	Kor (2,1)	Kor (2,2)	Kor (2,3)	Kor (2,m)	Kor (2,1024)
$V_{M3}$	Kor (3,1)	Kor (3,2)	Kor (3,3)	Kor (3,m)	Kor (3,1024)
...	Die Korrelationsmatrix enthält die Abhängigkeiten der einzelnen Spaltenvektoren (entspricht den Amplituden bei einer bestimmten Frequenz) zueinander. Eine positive Korrelation (Wert geht gegen 1) zeigt an, dass die Amplituden gemeinsam anwachsen bzw. stagnieren. Deswegen ist die Diagonale (Kor (m,m)) in dieser Matrix 1, da ein Vektor zu sich selbst maximal korreliert ist. Eine negative Korrelation ( Wert -1) zeigt ein gegeneinander laufen zweier Vektoren. Unabhängigkeit zweier Vektoren liegt vor, wenn die Korrelation 0 ist.				
...					
$V_{Mm}$					
...					
...					
$V_{M1024}$	Kor (1024,1)	Kor (1024,2)	Kor (1024,3)	Kor (1024,m)	Kor (1024,1024)

In dieser Matrix sind die Kovarianzen bzw. Korrelationen der vorverarbeiteten Spaltenvektoren zueinander aufgelistet. Diese bewegt sich zwischen -1 und 1 und zeigt, ob die Spaltenvektoren voneinander abhängig sind. Eine positive Korrelation bedeutet ein „Miteinanderlaufen“ der Vektoren, eine negative Korrelation das „Gegeneinanderlaufen“. Der Wert null zeigt, dass die Spaltenvektoren unabhängig voneinander sind. Die Diagonalelemente der Matrix haben einen Wert von eins und zeigen die Autokorrelation des Vektors zu sich selbst. Vereinfacht ausgedrückt zeigt diese Matrix, welche Frequenzen bzw. Frequenzklassen voneinander abhängig sind und somit einen ähnlichen, redundanten Informationsgehalt besitzen, und welche voneinander unabhängig sind und den Informationsgehalt erhöhen. Abbildung 4-42 zeigt die Korrelationsmatrix der Spaltenvektoren der vorbehandelten Daten aus Versuchskastenpool 3 als farbigen Konturplot.




Abbildung 4-42: Konturplot der Korrelationsmatrix der skalierten Daten

Die Korrelationswerte sind darin als farbige Punkte dargestellt. Eine vollständige positive Korrelation zweier Vektoren wird hier mit einem hellen Gelb eine negative Korrelation mit einem dunklen Rot dargestellt. Bewegen sich die Werte im Bereich von 0, was eine Unkorreliertheit der Vektoren bedeutet, so ist die Farbe in diesem Plot orange gewählt. Ziel der Hauptkomponentenanalyse ist es, aus den vorhandenen Vektoren neue Vektoren zu finden, die voneinander vollständig unabhängig bzw. unkorreliert sind. Eine überflüssige Datenredundanz lässt sich damit eliminieren und die Effektivität folgender Auswertungen somit verbessern.

Der numerische Kern der Hauptkomponentenanalyse besteht in der Bestimmung der  $M$  Eigenwerte und der normierten Eigenvektoren der Korrelationsmatrix  $R$ . Da es zu jedem Eigenwert unendlich viele Eigenvektoren gibt, benutzt man die normierten Vektoren als Repräsentant für alle Eigenvektoren zu einem Eigenwert. Eigenwert und normierter Eigenvektor nennt man Eigenpaar.




Abbildung 4-43: Eigenwerte der Korrelationsmatrix

Die Komponenten der normierten Eigenvektoren enthalten die gesuchten optimalen Gewichte der Ausgangsvariablen bei der Bildung der jeweiligen Hauptkomponente, während die dazugehörigen Eigenwerte ein Maß für die Varianz bzw. Streuung angeben, die diese Hauptkomponente in Bezug auf die Originaldatenmatrix beschreibt. Wie Abbildung 4-44 illustriert, erklären die ersten 50 Hauptkomponenten schon mehr als 75 % der Variation der Originaldaten aus Versuchskastenpool 3, welche als ein Maß für den darin enthaltenen Informationsgehalt dient. Die Verdopplung der Hauptkomponenten von 50 auf 100 erhöht die erklärte Varianz nur noch um etwa 10 %. Hauptkomponenten mit einem Index größer als 100 tragen in diesem Beispiel nur noch sehr wenig zur Erhöhung des Informationsgehaltes bei ( $< 0,15$  %) und können demzufolge aus den Spektren entfernt werden. Eine damit angestrebte Reduzierung der Datendimensionen unter Wahrung des Informationsgehaltes ist damit realisierbar.






Abbildung 4-44: Eigenwerte aus der Korrelationsmatrix (absteigend sortiert)

Die Bestimmung der Eigenwerte erfolgt über die Lösung der allgemeinen Gleichung

$$R \cdot v = \lambda \cdot v$$

wobei  $R$  die quadratische Korrelationsmatrix,  $v$  die Eigenvektoren und  $\lambda$  die dazugehörigen Eigenwerte bezeichnet. Eigenvektor einer Matrix ist demnach jeder Vektor, der mit der Matrix multipliziert in ein Vielfaches von sich selbst übergeht. Dieses Vielfache ist der Eigenwert  $\lambda$  des Eigenvektors  $v$ . Durch die Berechnung der Eigenwerte über die Auflösung des charakteristischen Polynoms erfolgt in einem zweiten Schritt die Berechnung der dazugehörigen, normierten Eigenvektoren.

Das eingesetzte Softwarepaket „R“<sup>1</sup> verwendet zur Bestimmung nicht die Methode über die Eigenwertbestimmung, sondern arbeitet nach dem Prinzip der Singulärwertzerlegung, welche zu den gleichen Ergebnissen kommt.

Betrachtet man das Ergebnis der Hauptkomponentenanalyse, die neu erschaffene Datenmatrix, so zeigt sich, dass unter Verwendung aller Hauptkomponenten der Informationsgehalt,

<sup>1</sup> R Development Core Team (2009). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. ISBN 3-900051-07-0, URL <http://www.R-project.org>.

also die Variation in den Daten, unverändert ist. Bei der Berechnung der Korrelation der neuen Vektoren zeigt sich aber, dass zwischen den einzelnen Vektoren keine Korrelationen mehr auftreten. In Abbildung 4-45 ist dies wiederum als farbiger Konturplot dargestellt. Außer der Autokorrelation als gelbe Winkelhalbierende zeigt die Grafik Unkorreliertheit als orange Fläche.




Abbildung 4-45: Konturplot der Korrelationsmatrix der Hauptkomponenten

Wie viele der Hauptkomponenten signifikant sind, um die Originaldatenstruktur bzw. den Informationsgehalt der Originaldaten angemessen abzubilden, ist von großer Bedeutung und kann auf verschiedenen Wegen bestimmt werden. Bezeichnet man die Zahl aller Hauptkomponenten mit dem Index  $p$  und berücksichtigt man die Tatsache, dass die Eigenwerte absteigend sortiert sind und somit mit steigendem Index  $p$  der Informationsgehalt bzw. die Variation der Originaldaten, die diese Hauptkomponente  $p$  erklärte, abnimmt, so ist es das Ziel, herauszufinden wie viele signifikante Hauptkomponenten  $r$  existieren und daraus resultierend um wie viel Dimensionen sich das Modell verkleinern lässt.

Die einfachste Methode um  $r$  zu bestimmen ist das Kaiser-Kriterium [138]. Dabei werden nur Hauptkomponenten gezählt, deren Streuung überdurchschnittlich ist, also über dem mittleren Eigenwert liegt. Im vorliegenden Fall ist der mittlere Eigenwert gleich eins, da mit standardisierten Daten gearbeitet wurde und somit die Summe aller Eigenwerte gleich der Zahl der Variablen (1024) ist. Folglich wären die ersten 118 Eigenwerte signifikant und damit die ersten 118 Hauptkomponenten für die Weiterverarbeitung von Bedeutung (vgl. Abbildung 4-43).

Daraus resultiert eine Verkleinerung der Datensätze um ca. 90 %. Die erklärte Varianz der ersten 118 Hauptkomponenten beträgt ca. 90 % der Varianz der Originaldatenmatrix.

Die zweite Methode zur Bestimmung der signifikanten Hauptkomponenten  $r$  ist der Scree-Test [139]. Dieser stellt die Behauptung auf, dass Eigenwerte von Korrelationsmatrizen von Datensätzen die nur Zufallszahlen enthalten, wie z.B. Messrauschen usw., flach gegen Null abfallen. Das bedeutet, ab Beginn dieses Phänomens beginnt der nicht-informative Teil der Datenstruktur. So genannte „Ellenbogenstellen“, also Stellen an denen sich die Steigung im Kurvenverlauf ändert, indizieren diesen Punkt im Scree-Diagramm. In Abbildung 4-46 sind die ersten 50 Eigenwerte über die dazugehörigen Hauptkomponenten  $p$  aufgetragen. Wie zu erkennen ist, gibt es in diesem Fall mehrere Steigungswechsel im Kurvenverlauf. Während sich im Bereich der ersten 30 Eigenwerte die Steigung dreimal gravierend ändert, verläuft die Kurve danach bis zum 1024. Eigenwert ziemlich konstant fallend gegen 0. Die erklärte Varianz der ersten 30 Hauptkomponenten beträgt ca. 68 % der Varianz der Originaldatenmatrix.




Abbildung 4-46: Screeplot für den Scree-Test

Um die Leistungsfähigkeit bzw. die Verbesserung der Erkennungsrate der Getränkekästen mit den Ergebnissen aus den vorherigen Kapiteln vergleichbar zu machen, wurde im Folgenden mit denselben KNNs gearbeitet (vgl. Tabelle 4-9). Die Wahl der benutzten Hauptkomponenten ist in diesem Fall durch die Eingangsschicht festgelegt und beträgt 16, 32, 64 und 128 Eingangsknoten. Tabelle 4-21 listet die dazugehörigen Daten zu diesen Hauptkomponenten auf.

Die Eingangsschicht für das KNN 2 mit der Topologie 32-16-1 hat 32 Eingangsknoten und kann somit die ersten 32 Hauptkomponenten als Eingangsdatensatz verarbeiten. Diese erklären einen Anteil von 69,3 % der Variation der Originaldatenmatrix. Somit beträgt im Mittel der Informationsgehalt (gleichgesetzt mit der Variation) der pro Eingangsknoten aufgenommen wird 2,2 %. Ausgehend von einer Variation von maximal 17,9 % pro Knoten (was nur mit der ersten Hauptkomponente erreichbar ist) beträgt die Effektivität der Datenaufnahme in das KNN somit nur noch 12,1 %. Die erklärte Varianz pro Eingangsknoten nimmt mit jeder Vergrößerung der Eingangsschicht ab und demzufolge auch die Effektivität, mit der das KNN Informationen aufnimmt und verarbeitet. Stellt man Kosten, in Form von zeitlichem und finanziellem Aufwand, dem Nutzen, also der effektiv verarbeiteten Information gegenüber, so kommt man zu dem Schluss, dass ab einem gewissen Punkt eine weitere Vergrößerung der Eingangsschicht in keinem reellen Verhältnis zum dadurch erzielten Nutzen steht.

Tabelle 4-21: Gesamtvariation in Abhängigkeit von signifikanten Hauptkomponenten

<b>Anzahl der Hauptkomponenten p bzw. KNN-Eingangsknoten</b>	<b>Kumulierte Gesamtvariation aller Knoten [%]</b>	<b>Variation pro Einzelknoten [%]</b>	<b>Effektivität [%]</b>
1	17.9	17.9	100.0
2	23.3	11.6	64.9
4	31.5	7.9	44.0
8	42.0	5.3	29.3
16	55.6	3.5	19.4
32	69.3	2.2	12.1
64	82.1	1.3	7.2
128	91.8	0.7	4.0
1024	100	0,0	0.1

Die Ergebnisse aus den KNN-Trainings fielen in diesem Fall unerwartet aus. Der Theorie zufolge sollte eine Erhöhung der Eingangsknoten eine Erhöhung der Informationen bewirken und somit die Klassifizierung der Getränkekästen positiv beeinflussen. Die Kenndaten in Tabelle 4-22 belegen, dass KNN 3 mit der Topologie 64-32-1 in der Gesamtbewertung die besten Ergebnisse erzielt. Die Gesamterkennungsrate liegt bei 98.52 % aller Getränkekästen. Darin sind 99.62 % der intakten und 95.92 % der defekten Prüflinge enthalten. Damit ist dieses KNN in allen Kategorien der Gesamterkennungsrate an erster Stelle.

Tabelle 4-22: Ergebnisse des KNN-Trainings

KNN ID	Daten	Positive Prognose (richtige Klassifizierung) [%]					
		Training	Validierung	Test 1	Test 2	Test 3	Gesamt
1	gesamt	95.6	87.4	84.4	77.1	100.0	94.1
	intakt	97.7	89.0	--	77.1	100.0	96.0
	defekt	90.8	80.8	84.4	--	--	89.6
2	gesamt	99.6	92.6	86.7	72.9	93.9	97.5
	intakt	100.0	98.9	--	72.9	93.9	98.4
	defekt	98.6	80.0	86.7	--	--	95.5
3	gesamt	99.6	96.3	80.0	93.8	100.0	98.5
	intakt	100.0	98.8	--	93.8	100.0	99.6
	defekt	98.6	91.8	80.0	--	--	95.9
4	gesamt	99.5	94.8	75.6	87.5	91.8	97.7
	intakt	100.0	100.0	--	87.5	91.8	99.0
	defekt	98.3	85.7	75.6	--	--	94.6
5	gesamt	99.3	94.8	82.2	89.6	100.0	98.1
	intakt	100.0	98.9	--	89.6	100.0	99.4
	defekt	97.7	86.4	82.2	--	--	95.0
6	gesamt	99.4	94.1	80.0	89.6	98.0	98.0
	intakt	99.9	96.7	--	89.6	98.0	99.0
	defekt	98.3	88.6	80.0	--	--	95.5

Bei der Betrachtung der einzelnen Datensätze wiesen aber auch die anderen KNN bessere Erkennungsfähigkeiten vor. So schnitt bei der Prognose der Trainingsdatensätze das KNN 2 am besten ab und erreichte bei der Einstufung der intakten Kästen eine Erkennungsrate von 100 %. Bei den Validierungsdaten zeigt sich, dass die KNN einige Getränkekästen auch nach

der Vorverarbeitung durch die Hauptkomponentenanalyse nicht richtig einzustufen vermögen. Vor allem die beschädigten Exemplare scheinen hier Probleme zu bereiten. So konnte KNN 3 in diesem Bereich nur 91.84 % der Datensätze der korrekten Kategorie zuweisen. Nach wie vor am schlechtesten erkannt wurden die defekten Prüflinge aus Testdatensatz 1. Hier konnte zwar durch die PCA eine Steigerung erzielt werden, aber das Endergebnis ist auch hier noch nicht zufrieden stellend. Wie im vorherigen Abschnitt schon erwähnt, handelt es sich bei diesen Datensätzen um Schwingenspektren von Getränkekästen mit teilweise seltenen Beschädigungen. Da diese in den Trainingsdaten nicht vorkommen, haben die KNN hier besondere Schwierigkeiten bzw. die Generalisierungsfähigkeit stößt hier an seine Grenzen. Die Testdatensätze mit den Schwinginformationen von intakten Getränkekästen werden ebenso durch das KNN 3 am besten eingeordnet.

Den Verlauf des mittleren quadratischen Fehlers während der Trainingsphase präsentiert Abbildung 4-47. Es zeigt sich, je mehr Knoten ein KNN enthält und je größer die Eingangsschicht ausfällt, desto schneller geht die Minimierung des mittleren quadratischen Fehlers über alle Knoten im Netz vonstatten. Einzige Ausnahme ist KNN 3, welches mit den besten Ergebnissen abgeschnitten hat. Der Fehler bei diesem KNN ist schon nach 50 Lernzyklen viel kleiner als bei den anderen Netzen und nimmt im Verlauf des Lernvorganges sehr schnell ab. Die kleinen Netze, welche anscheinend zu wenige Informationen durch ihre relativ kleine Eingangsschicht erhalten, benötigen zur Fehlerminimierung mehr als doppelt so lange wie die größeren Netze. Auffällig ist ebenfalls, dass KNN 3, 5 und 6 in etwa die gleiche Anzahl an Lernzyklen benötigen, um die gewünschte Minimierung des mittleren quadratischen Netzwerkfehlers zu erreichen.




Abbildung 4-47: Mittlerer quadratischer Fehler während des Trainingsprozesses (Trainingsdatensatz)

Auch in der Abbildung des Validierungsfehlers ist dieses Phänomen zu beobachten, wobei hier der Validierungsfehler von KNN 6 etwas höher ausfällt. Der Validierungsfehler von KNN 3 ist wie im Training nach 50 Zyklen schon sehr niedrig im Vergleich zu den anderen und nimmt auch hier sehr schnell ab. Die kleinen Netze benötigen auch hier viel mehr Durchgänge um einen akzeptablen Fehlerwert zu erreichen.




Abbildung 4-48: Mittlerer quadratischer Fehler während des Trainingsprozesses (Validierungsdatensatz)




Abbildung 4-49: Mittlerer quadratischer Fehler während des Trainingsprozesses (Testdatensatz 1)



In den Verläufen der Testfehler zeigt sich, wie schon im vorherigen Abschnitt diskutiert, ein Anstieg des mittleren quadratischen Netzwerkfehlers während des Trainings.

Dies bedeutet konkret, dass es für die Erkennung der Testkästen in diesen Datensätzen durchaus sinnvoll ist, den Trainingsvorgang in einem früheren Stadium zu unterbrechen. Damit erreicht das KNN bei den Trainings- und Validierungsergebnissen nicht so gute Resultate wie in Tabelle 4-22. Es bleibt aber flexibler was die Erkennung fremder Spektren anbelangt. Dies ist wiederum mit dem Overfitting-Effekt und dem Verlust der Generalisierungsfähigkeit zu Begründen.




Abbildung 4-50: Mittlerer quadratischer Fehler während des Trainingsprozesses (Testdatensatz 2)

In der grafischen Darstellung von Testfehler 3 verlaufen die Kurven der Fehler von KNN 5 und 6 gleich zu Beginn auf sehr niedrigem Niveau (vgl. Abbildung 4-51). Daraus ergibt sich auch das gute Erkennungsergebnis von KNN 5, welches diesen Datensatz zu 100 Prozent richtig klassifiziert.

KNN 4 hingegen nimmt während der letzten 50 Zyklen nochmals sehr stark zu und bleibt dann bei einem relativ hohen Endwert stehen. Das spiegelt sich in der schlechten Erkennungsrate von 91,8 % wider.




Abbildung 4-51: Mittlerer quadratischer Fehler während des Trainingsprozesses  
(Testdatensatz 3)

Die Ergebnisse in diesem Abschnitt zeigen, dass die Vorbehandlung der Schwingungsdaten von Getränkekästen durch eine Hauptkomponentenanalyse eine Verbesserung der Klassifizierungsfähigkeiten der eingesetzten KNN bewirken. Außerdem zeigt sich, dass die Anzahl der benutzen Hauptkomponenten nicht mit der Erkennungsrate korreliert. Vielmehr scheint es eine optimale Anzahl von Hauptkomponenten zu geben, deren Informationsgehalt den Zustand eines Getränkekastens abbilden. Den Ergebnissen nach liegt diese Anzahl bei 64 Eingangsknoten.

Weiterhin sind nicht alle Informationen, die das Schwingenspektrum eines Getränkekastens enthält, relevant für die Bestimmung seines Zustandes. Vielmehr scheinen einige Informationen sogar eine störende Wirkung auf die Prognose zu haben. Die PCA versucht aus dem gesamten Spektrum über Korrelationen der einzelnen Vektoren Informationen zu verdichten, dabei erfolgt aber keinerlei Berücksichtigung, welche neu geschaffenen Vektoren Informationen über den untersuchten Sachverhalt enthalten. Des Weiteren zeigt sich, wie auch schon in den vorhergehenden Abschnitten, dass die Güte der Trainingsdatensätze den alles entscheidenden Einfluss auf die Erkennungsrate der trainierten KNN ausübt. Je besser diese Datensätze den kompletten Problembereich abdecken, desto besser können die Netze zur Lösung des Problems vorbereitet werden.

## **5 Zusammenfassung und Ausblick**

### **Einleitung – kurzer Gesamtabriss mit Problemstellung**

Die meisten derzeit eingesetzten Verfahren zur Erkennung von Schäden an Getränkekästen der Getränkeindustrie arbeiten anhand von Bilderkennungsverfahren. Diese durchsuchen digitalisierte Photographien der Prüflinge nach Abweichungen in Farbe, Form und Geometrie und leiten daraus Beschädigungen ab. Die schlechte Erkennungsrate dieser Methode liegt darin begründet, dass viele auftretende Schäden für diese Art der Schadenserkenkung unsichtbar und deshalb nicht erfassbar sind. Deswegen verbleiben betroffene Kästen im Mehrwegbestand der Unternehmen und gelangen über den Einzelhandel zum Kunden.

Das Ziel der vorliegenden Arbeit ist die Entwicklung einer industrietauglichen Kasteninspektionsmaschine, die sowohl sichtbare als auch unsichtbare Schäden an Getränkekästen zuverlässig erkennt, die betroffenen Objekte aus dem Mehrwegkreislauf entfernt und einer geeigneten Wiederverwertung zuführen kann. Hauptanforderung an diese Maschine ist primär die zuverlässige Zustandsprognose und die daran gekoppelte Aussortierung der betreffenden schadhafte Getränke Kästen. Daneben spielt die Integration in bestehende Abfüllanlagen der Getränkeindustrie eine erhebliche Rolle, deren zentrales Aggregat die Füllmaschine darstellt und nach der sich der komplette Anlagenbetrieb ausrichtet. Um den störungsfreien Betrieb von Abfüllanlagen zu gewährleisten, muss die Kasteninspektionsmaschine eine Taktrate von ca. einer Sekunde einhalten. Störende äußere Einflüsse, wie z.B. schwankende Umgebungstemperaturen oder Fremdschwingungen, welche die Durchführung der Kasteninspektion negativ beeinflussen, müssen ebenfalls berücksichtigt werden.

### **Grundlagen und Methoden**

Aufbauend auf den Forschungsarbeiten von Zacharias et. al. [35-37], der erstmals die Methode der Neuronumerik zur Schadenserkenkung an Getränkekästen einsetzte, präsentiert diese Arbeit eine konsequent weiterentwickelte Methode, die gleichfalls auf der mechanischen Signalausbreitung in Festkörpern basiert und erstmalig zur Zustandsüberwachung an Lebensmittelverpackungen im industriellen Umfeld zum Einsatz kommt.

Zacharias zeigte, dass es die mechanische Schwingungsanalyse, kombiniert mit einem auf Neuronumerik basierenden Auswertungs- und Selektionsverfahren, ermöglicht, Schäden an Getränkeboxen zu detektieren. Dies beinhaltet auch das Erkennen von Latenzmängeln, wie z.B. versprödetem Kunststoff oder Fremdfabrikate. Unter Laborbedingungen erreichte diese Methode eine Erkennungsrate von 99 %.

Als nachteilig erwiesen sich die relativ lange Dauer eines Prüfzyklus von ca. 10 s und die aufwändige konstruktive Umsetzung, die den praktischen Einsatz in Getränkebetrieben unwirtschaftlich machten. Aus diesem Grund erfolgte in dieser Arbeit eine Modifikation des Schwinganalyseverfahrens, um den Taktzyklen einer industriell nutzbaren Inspektionsmaschine ( $T \leq 1$  s) gerecht zu werden. Ebenso erfolgte eine Modifizierung des Auswertungsverfahrens, um die Erkennungsrate bei gleichzeitiger Erhöhung der Robustheit und Performanz zu verbessern.

### **Finite-Elemente-Methode (FEM)**

Zu Beginn der Untersuchungen erfolgte eine numerische Berechnung des mechanischen Schwingungsverhaltens eines zum Schwingen angeregten Getränkeboxens mit Hilfe der Finite-Elemente-Methode (FEM). Ziel dieser Berechnungen war es, grundlegende Zusammenhänge zwischen dem Schwingverhalten der Getränkeboxen, Art und Position der eingeleiteten Anregungskraft und Auswirkungen verschiedener Befestigungsmethoden zu erkennen.

Die Modellierung der Boxen erfolgte auf CAD-Basis mit Hilfe von herstellerseitig zur Verfügung gestellten Materialparametern. In der anschließenden Simulation wurden die Schwingungen simuliert, die ein auf die Boxenoberfläche eingeleiteter Anregungsimpuls hervorruft. Daraus resultieren zeitdiskrete Verschiebungsvektoren, welche durch Fouriertransformation in die entsprechenden Frequenzspektren umgerechnet wurden. Die Abweichung des Schwingungsspektrums eines beschädigten Boxens zu dem eines unbeschädigten Boxens konnte im Anschluss durch normierte Kenngrößen definiert werden. Eine Quantifizierung der Schwere des Schadens am Boxen wurde somit ermöglicht.

Es zeigte sich, dass keine gemeinsame optimale Sensorposition für alle betrachteten Schadensfälle existiert. Es konnten jedoch Bereiche abgegrenzt werden, die auf Beschädigungen besonders sensibel reagieren. Diese befinden sich im oberen Bereich der Boxen, in der Mitte der Stirnseiten sowie an den Seitengriffen. Weitergehende Untersuchungen wurden deshalb auf diese Bereiche beschränkt.

Die Simulation ergab, dass sich die Antwortsignale eines beschädigten und eines unbeschädigten Kastens je nach Ort des Erregungsimpulses stark unterscheiden. Es zeigte sich, dass die vertikal wirkende, zentral von unten angreifende Kraft durchwegs die größte Differenz in der Frequenzantwort von intaktem und defektem Kasten hervorruft. Die anschließende Planung und Konstruktion des Versuchstandes basiert maßgeblich auf den Ergebnissen der FEM-Simulationen.

### **Experimentelle Versuchsanlagen**

Der Prototyp der Kasteninspektionsmaschine ermöglichte durch weitgehende Automatisierung eine Abarbeitung der einzelnen Schritte des Prüfverfahrens. Dies geschah mit Hilfe moderner Computersteuerung sowie pneumatisch betriebener Mechanismen zur Vereinzelung, Fixierung und Anregung der Kästen unter nahezu realen Umgebungsbedingungen. Eine dynamisch betriebene Klemmbackenfixierung diente dazu, die Getränkekästen vom laufenden Förderstrom zu selektieren, einer Schwingungsprüfung zu unterziehen und sie danach in den Förderstrom zurückzuführen, ohne diesen dabei zu verlangsamen bzw. zu unterbrechen. Darüber hinaus unterbindet die Klemmbackenfixierung eine Ganzkörperbewegung der Prüflinge.

Zur Schwingungserregung der Getränkekästen diente ein ca. 0,2 Sekunden andauernder, vertikal wirkender Schockimpuls. Dieser wurde durch einen pneumatisch betriebenen Shaker zentral von unten in den Kastenboden eingeleitet. Zur Aufnahme der resultierenden Kastenschwingung diente ein nach dem Doppler-Prinzip funktionierendes Laservibrometer. Es erfasst die Schwingung eines Punktes auf der Kastenoberfläche und liefert ein analoges Spannungssignal zur Weiterverarbeitung mit einem PC. Dieses Signal, aufgenommen mit einer Abtastfrequenz von 10 kHz, enthält die Beschleunigungsinformationen des gemessenen Punktes für ein Zeitintervall von ca. 0,2 Sekunden. Eine Fouriertransformation führte das Signal aus dem zeitaufgelösten Bereich in eine frequenz aufgelöste Darstellung über. Diese enthielt Informationen über die Zerlegung des Beschleunigungssignals von 0-5 kHz in Frequenzintervalle von 4,88 Hz und bestand somit aus 1024 diskreten Schwingungsamplituden.

Für die Untersuchung dienten insgesamt 129 Getränkekästen in unterschiedlichen Zustandsformen, von fabrikneu bis gebrochen. Daraus entstanden mit Hilfe des beschriebenen industrietauglichen Funktionsmusters insgesamt 1483 Messdatensätze. Mit Hilfe dieser Informationen konnte durch weitere Auswertung auf den Zustand der Getränkekästen geschlossen und eine automatische Sortierung vorgenommen werden.

**Auswertungsverfahren (DVV, PCA, Neurostatistik, KNN)**

Die Datenverarbeitung erfolgte mit dem Verfahren der Neurostatistik. Hierbei handelt es sich um eine Kombination aus dem statistischen Verfahren der Hauptkomponentenanalyse (HKA) mit kognitiven Algorithmen in Form von Künstlichen Neuronalen Netzen (KNN). Damit vereint dieses Hybrid die jeweiligen Vorteile und ist so leistungsfähiger als die genannten Einzelverfahren.

Bei KNN handelt es sich um „Multilayer Perzeptron“ Netze, dessen Neuronen schichtweise miteinander verbunden sind, und deren Verbindungen und Funktionen in den Neuronen als Informationsspeicher dienen. Durch einen sogenannten Trainingsprozess lernt das KNN Zusammenhänge zwischen Ausgangs- und Zielgrößen mit fortschreitender Anzahl von Lernzyklen immer besser abzubilden. Bei den vorliegenden Untersuchungen kamen sechs verschiedene KNN-Topologien zum Einsatz.

Da die nach der Fouriertransformation vorliegenden 1024 diskreten Schwingungsamplituden für ein KNN einen enormen Rechenaufwand bedeuten, der mit normaler Computerhardware nicht in sinnvollen Zeitintervallen zu bewältigen ist, müssen die Datensätze für die Verarbeitung komprimiert werden. Die Schichten zur Informationsaufnahme der KNN enthalten in den einzelnen Versuchsreihen 16, 32, 64 und 128 Eingänge. Dies bedeutet, dass die ursprünglich aus der Messung resultierenden 1024 Datenpunkte zusammengefasst bzw. beschnitten werden mussten, um sie als Eingangsdaten für die KNN verwenden zu können. Dabei durften jedoch keine wichtigen Informationen verlorengehen.

Durch die Hauptkomponentenanalyse, die bei diesem Verfahren die Rolle der Datenvorverarbeitung übernahm, konnte dies gewährleistet werden. Durch diese Datenvorverarbeitung wurden aus den gemessenen Schwingungssignalen der Getränkekästen Informationen sowohl extrahiert als auch komprimiert und eine effektive Klassifizierung ermöglicht. Dabei entfernte die HKA nicht aussagekräftige Teile der Daten bzw. fasste redundante Informationen zusammen. Die so aufbereiteten Datensätze dienten dem KNN anschließend dazu, einen Zusammenhang zwischen der Schwingungsantwort und dem jeweiligen Zustand eines untersuchten Getränkekastens herzustellen. Aus der Kombination von Hauptkomponentenanalyse und Künstlichen Neuronalen Netzen resultiert ein leistungsfähiges Auswertungssystem, das in der Lage ist, in Bruchteilen einer Sekunde anhand eines Schwingungssignals eine Prognose über den Zustand des Getränkekastens abzugeben.

## Ergebnisse

Eine Betrachtung der Erkennungsrate der Künstlichen Neuronalen Netze zeigte, dass eine zuverlässige Klassifizierung von Getränkekästen anhand ihrer Schwingantwort möglich ist. Diese hängt sehr stark von der Topologie des Netzwerkes, der Vorverarbeitung der Daten und des vorher durchgeführten Netzwerktrainings ab. Der Einsatz der gesamten Schwingspektren von 0 bis 5 kHz und eine Komprimierung der Daten nach Simpson zeigten gute Erfolge. Dabei erreichte das Netzwerk mit 64 Eingangsknoten, 32 verdeckten Knoten und einem Ausgangsknoten mit einer Erkennungsrate von 95 % das beste Ergebnis. Es zeigte sich jedoch deutlich, dass während des Trainings der KNN eine Verbesserung der Erkennungsrate gleichzeitig einen Verlust der Generalisierungsfähigkeit des KNN bedeutete. Dies hat zur Folge, dass zwar bekannte Muster immer besser klassifiziert werden können, unbekannte Muster, die nicht in den Trainingsdatensätzen abgebildet sind, aber zu großen Klassifizierungsschwierigkeiten führen.

Die genauere Untersuchung aller Messdaten zeigte, dass die meisten Informationen über den Zustand des Getränkekastens im Bereich zwischen 0 bis 1,5 kHz enthalten sind. Eine erneute Auswertung dieses Frequenzbereiches mit einer speziell gewählten KNN-Topologie (32-16-1) erbrachte eine Verbesserung der Gesamterkennungsrate auf über 98 %.

In einem weiteren Schritt wurden die Schwingspektren einer Hauptkomponentenanalyse unterzogen. Die Auswertung dieses Datenmaterials mit Hilfe eines KNN mit 64 Eingangsknoten, 32 verdeckten Knoten und einem Ausgangsknoten erreichte dabei eine Gesamterkennungsrate von 98,5 %. So konnten auch nicht erlernte Schadenstypen am Kasten mit großer Sicherheit richtig klassifiziert werden. Dies unterstreicht die Wichtigkeit der Wahl der richtigen Daten sowie deren korrekte Vorverarbeitung.

## **Ausblick**

Diese Arbeit zeigt, dass eine Verbesserung der Aussortierquote von defekten Getränkekästen sowohl in bestehenden als auch in neu geplanten Abfüllanlagen durch die vorgestellte Methode möglich ist. Während Abfüller bisher oftmals eine feste Quote an Kästen pro Zeiteinheit ersetzen mussten, der auch unbeschädigte Kästen zum Opfer fielen, können nun, durch die hochselektive Entfernung beschädigter Kästen, Ersatzkosten bei gleichzeitiger Verbesserung der Qualität des Kastenpools minimiert werden. Einzelhandel und Endverbraucher profitieren dadurch, dass die von ihnen benutzten Getränkekästen sich in einem akzeptablen Zustand befinden, was sowohl dem Schutz der darin enthaltenen Getränkeflaschen als auch die damit verbundene Transportsicherheit und den Gebrauchskomfort erhöht. Eine hieraus generierte Qualitätssteigerung und eine Aufwertung des Ansehens der entsprechenden Marke kommt indirekt auch dem Hersteller der Getränke zu gute.

Weitere Entwicklungen in diesem Bereich sollten neben der Klassifizierung des Zustandes der geprüften Getränkekästen eine Identifikation und Lokalisierung der vorliegenden Schäden sein. In einer differenzierten Betrachtung können die Anlagenbetreibern darüber entscheiden, welche Schäden an ihren Gebinden die Weiterverwendung im Mehrwegpool ausschließen, und welche Schäden toleriert werden.

Dafür müssen bei der Anpassung der KNN neben der einfachen Zustandsklassifizierung weitere Informationen über den Getränkekasten erfasst und in das Auswertungssystem integriert werden. Die Einbindung der Bildinformationen aus den bestehenden Kamerasystemen zur erweiterten Auswertung wäre hierbei denkbar.

Weitere Einsatzgebiete für eine Schwingungsprüfung in der Lebensmittel- und Getränkeindustrie gilt es zu forcieren. Es ist durchaus denkbar, diese Methode auf andere Verpackungen, wie z.B. Getränkeflaschen oder Dosen, anzuwenden. Transportpaletten sind bereits im Fokus der Wissenschaft. Eine weitere interessante Möglichkeit bietet die Schwingungsprüfung auch im Bereich der Lebensmittel, indem so z.B. Veränderungen durch Reifungsprozesse detektiert werden könnten. Die Methoden der manuellen akustischen Reifeprüfung durch Fachleute, z.B. im Käsebereich, aber auch bei Obst, könnte damit standardisiert und automatisiert werden.



## 6 Anhang

### 6.1 Anhang A

Schadensbilder an Kastenmodell 2 zur Simulation (vgl. Abschnitt 4.1.4)

Tabelle 6-1: Modellschäden am Kasten Modell Amstel

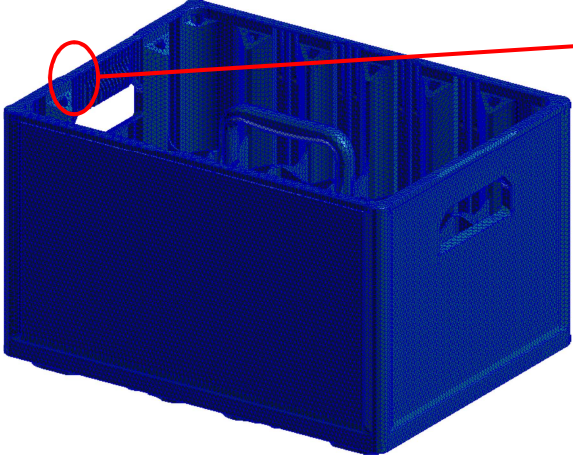
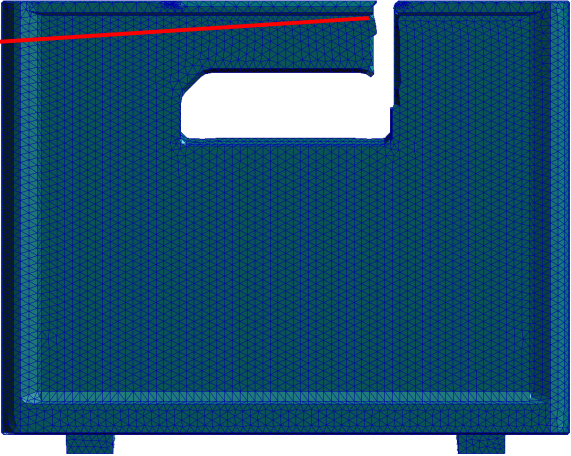
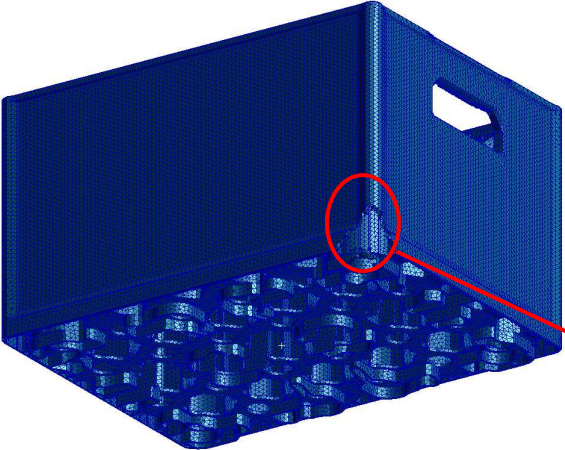
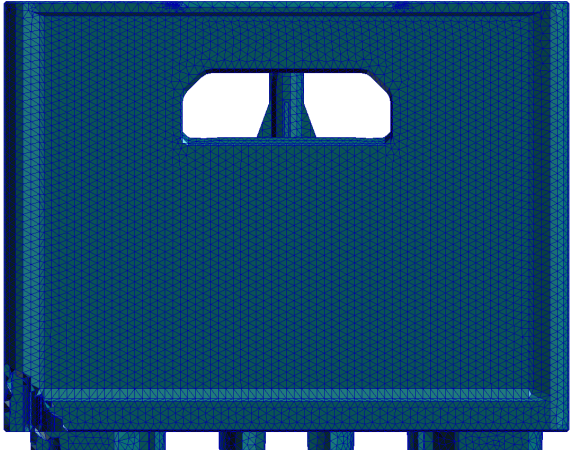
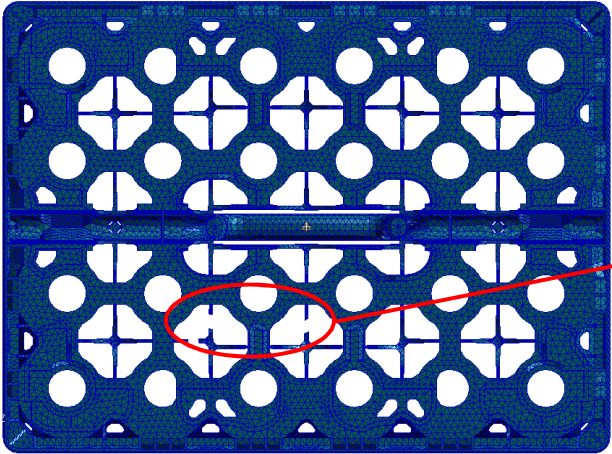
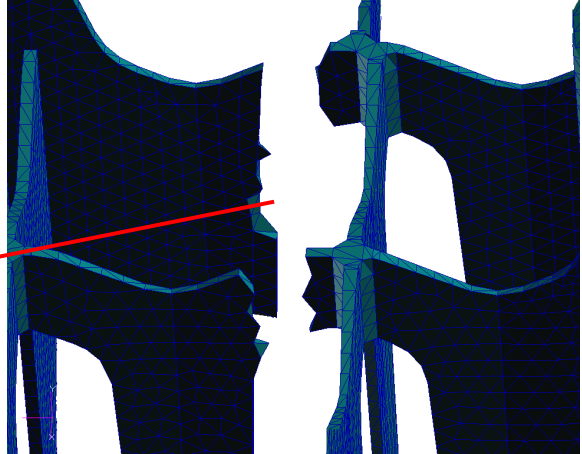
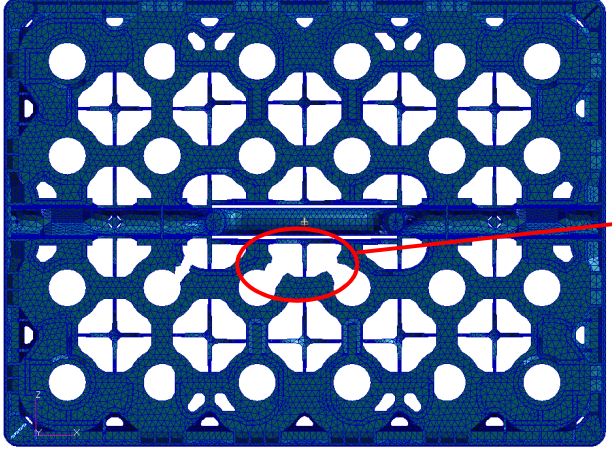

perspektivische Ansicht (vorne rechts)	Seitenansicht
	
Bruch des Griffes - Modellschaden S01	
	
Bruch an der Ecke- Modellschaden S02	

Tabelle 6-2: Modellschäden am Kasten Modell Amstel

Draufsicht	perspektivische Ansicht
	
Brüche im Gefache - Modellschaden S03	
	
Brüche am Kastenboden - Modellschaden S04	

## 6.2 Anhang B

Ergebnisplots zur Untersuchung der besten Sensorposition in Abhängigkeit von Anregungssignal und Fixierung (vgl. 4.1.4).




Abbildung 6-1: Ergebnisplot E03-S01-2




Abbildung 6-2: Ergebnisplot E03-S02-2






Abbildung 6-3: Ergebnisplot E03-S03-2






Abbildung 6-6: Ergebnisplot E01-S02-2




Abbildung 6-7: Ergebnisplot E01-S03-2




Abbildung 6-8: Ergebnisplot E01-S04-2




Abbildung 6-9: Ergebnisplot E02-S01-2




Abbildung 6-10: Ergebnisplot E02-S02-2




Abbildung 6-11: Ergebnisplot E02-S03-2






Abbildung 6-12: Ergebnisplot E02-S04-2




Abbildung 6-13: Ergebnisplot E03-S01-3




Abbildung 6-14: Ergebnisplot E03-S02-3

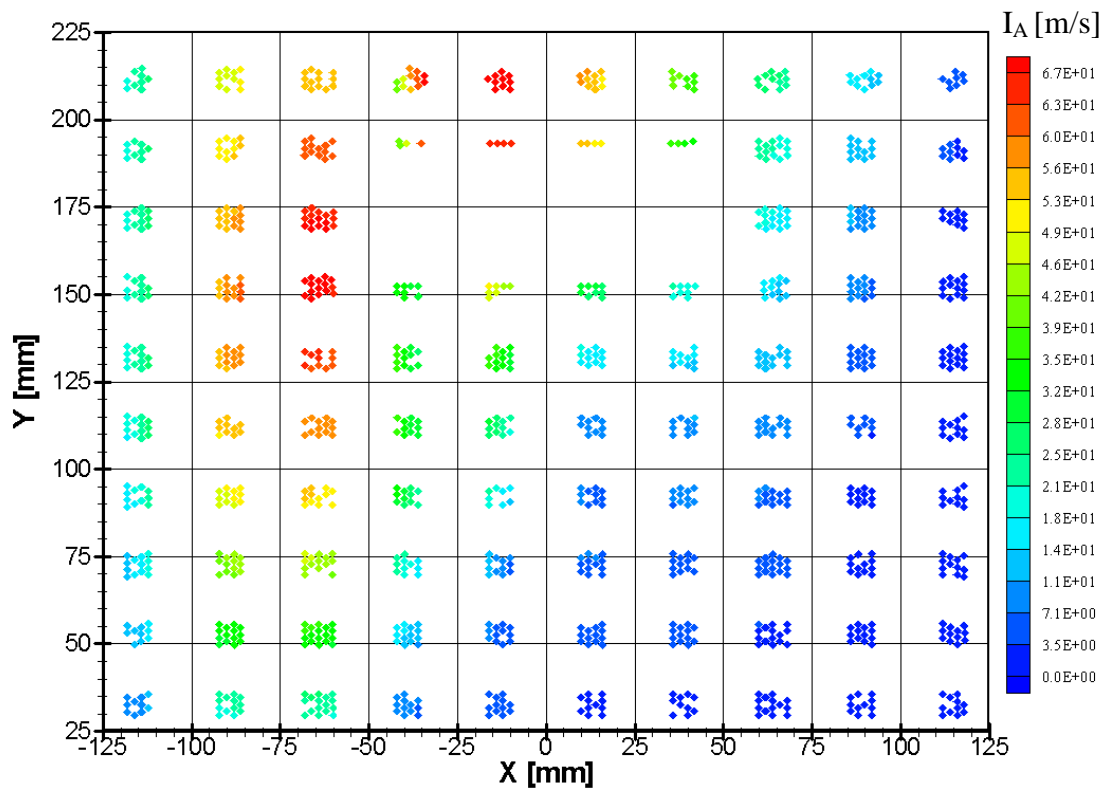


Abbildung 6-15: Ergebnisplot E03-S03-3




Abbildung 6-16: Ergebnisplot E03-S04-3




Abbildung 6-17: Ergebnisplot E01-S01-3




Abbildung 6-18: Ergebnisplot E01-S02-3




Abbildung 6-19: Ergebnisplot E01-S03-3




Abbildung 6-20: Ergebnisplot E01-S04-3




Abbildung 6-21: Ergebnisplot E02-S01-3




Abbildung 6-22: Ergebnisplot E02-S02-3




Abbildung 6-23: Ergebnisplot E02-S03-3

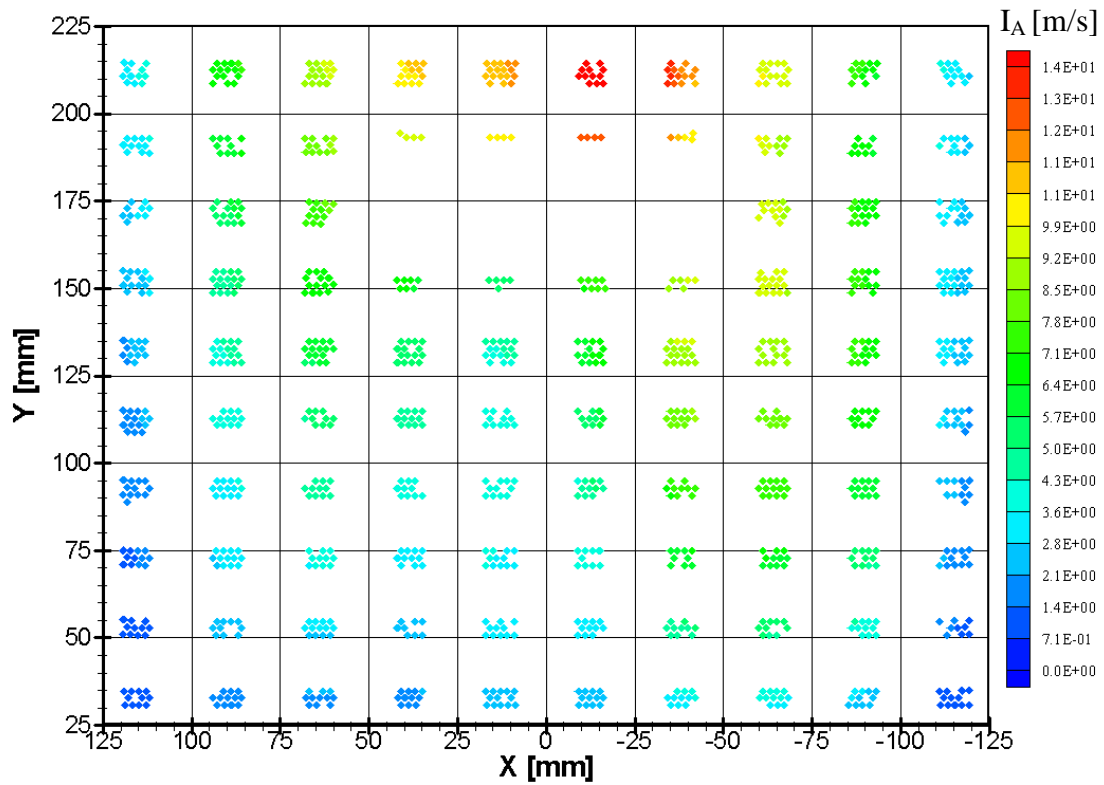


Abbildung 6-24: Ergebnisplot M02-S01-4




Abbildung 6-25: Ergebnisplot M02-S02-4

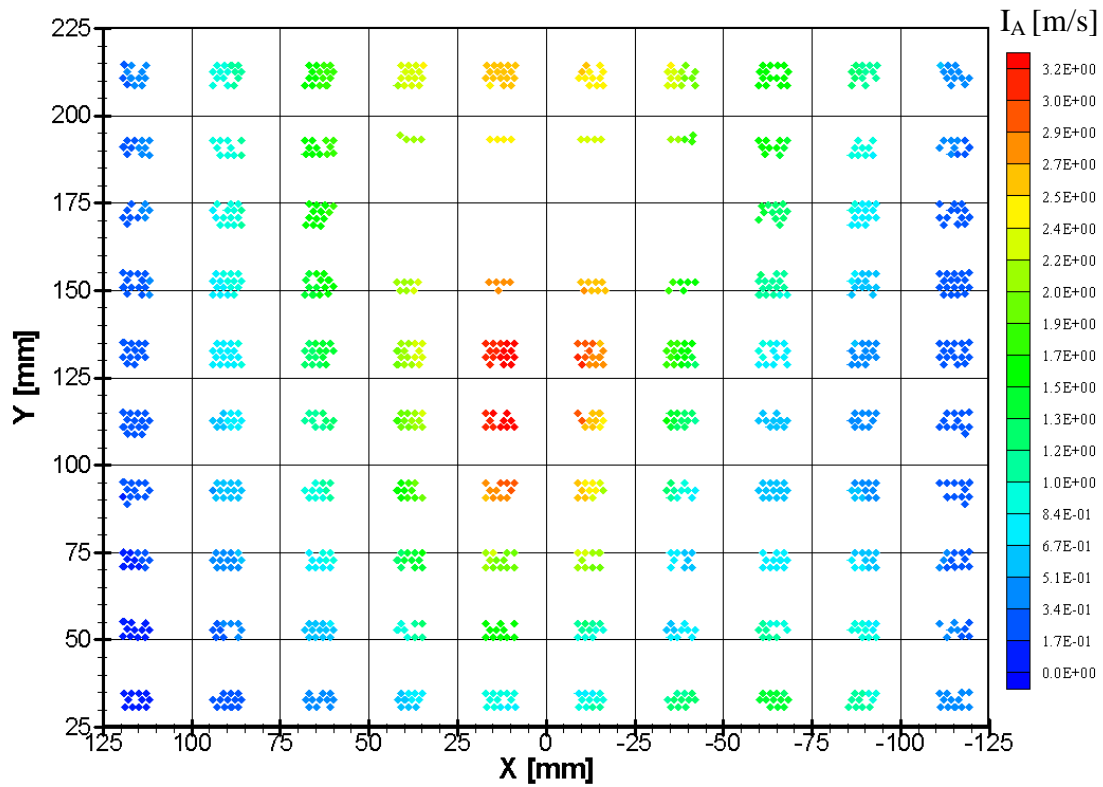


Abbildung 6-26: Ergebnisplot M02-S03-4




Abbildung 6-27: Ergebnisplot M02-S04-4






Abbildung 6-28: Ergebnisplot M03-S02-4




Abbildung 6-29: Ergebnisplot M03-S03-4




Abbildung 6-30: Ergebnisplot M03-S04-




Abbildung 6-31: Ergebnisplot E02-S01-4




Abbildung 6-32: Ergebnisplot E02-S02-4




Abbildung 6-33: Ergebnisplot E02-S03-4




Abbildung 6-34: Ergebnisplot E02-S04-4

### 6.3 Anhang C

Verläufe des mittleren quadratischen Netzwerkfehlers während des Netzwerktrainings bei der Untersuchung der Auswirkungen der Datenkomprimierung auf die Prognosefähigkeit (vgl. 4.2.6.2).




Abbildung 6-35: Mittlerer quadratischer Fehler während des Trainingsprozesses




Abbildung 6-36: Mittlerer quadratischer Fehler während des Trainingsprozesses




Abbildung 6-37: Mittlerer quadratischer Fehler während des Trainingsprozesses




Abbildung 6-38: Mittlerer quadratischer Fehler während des Trainingsprozesses




Abbildung 6-39: Mittlerer quadratischer Fehler während des Trainingsprozesses

## 6.4 Anhang D

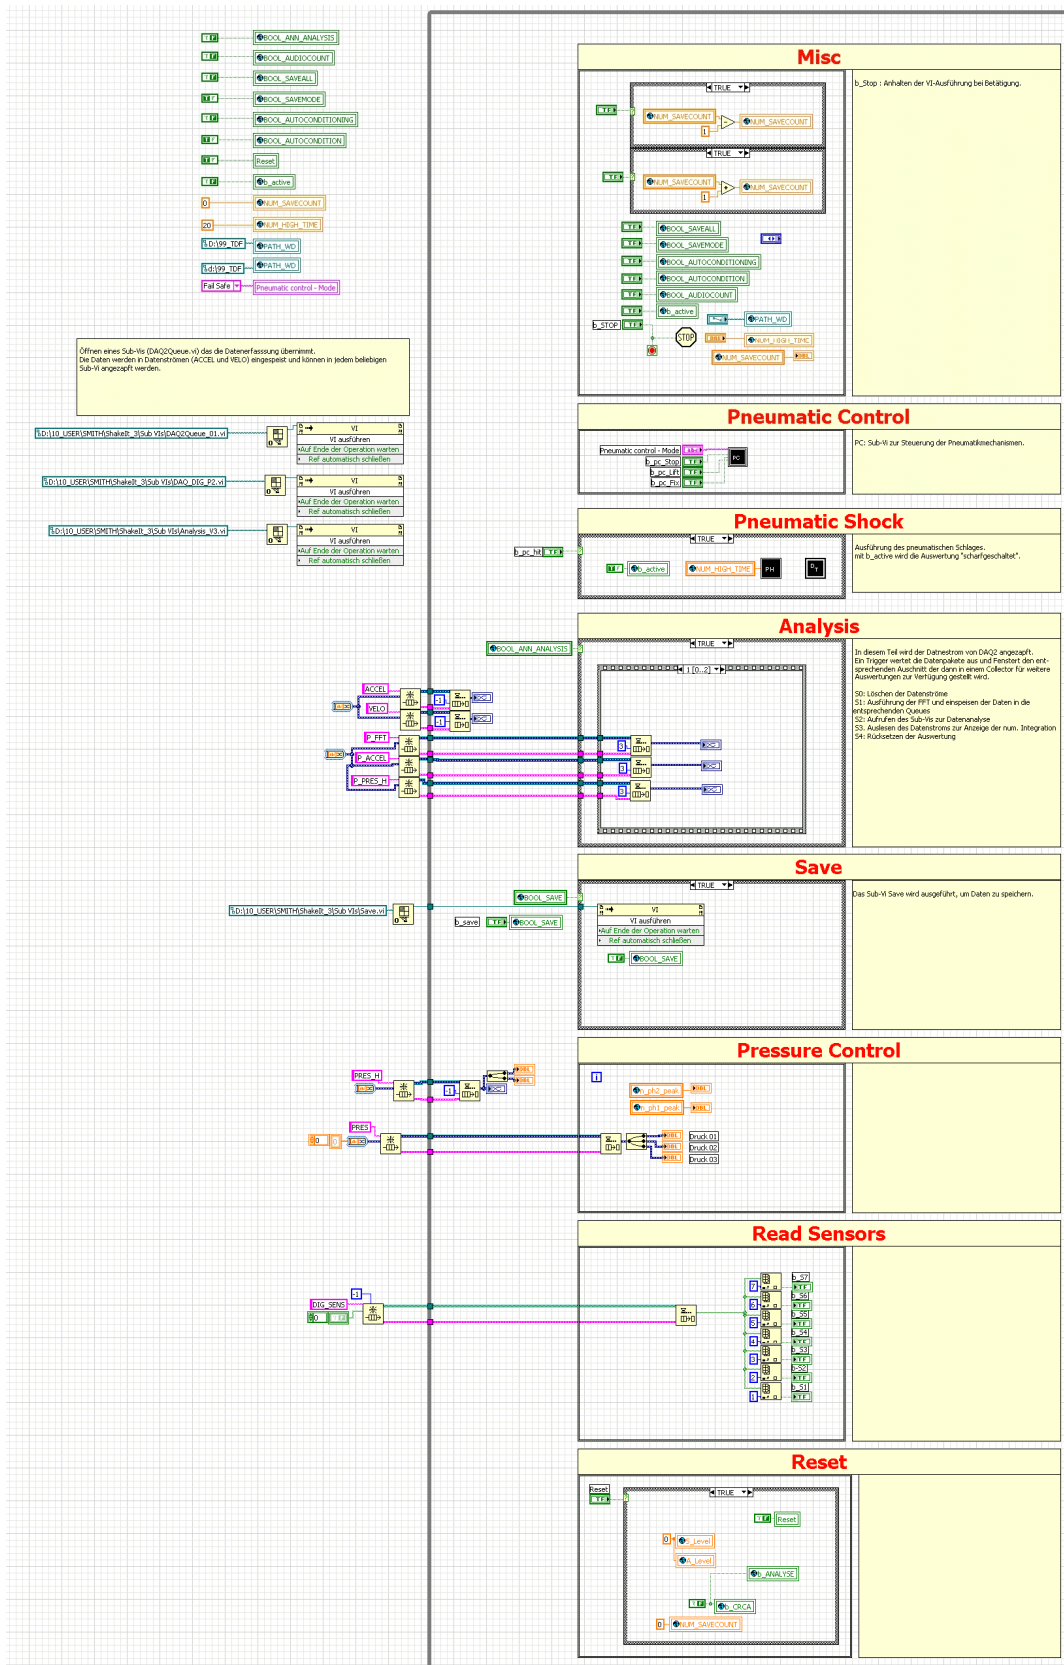


Abbildung 6-40: Screenshot des Lab-View Schaltbild



## 7 Literatur

- [1] "Verband Deutscher Mineralbrunnen (VDM): Branchendaten 2006. URL: [http://www.gdb.de/mehrwegsystem/daten\\_fakten.php](http://www.gdb.de/mehrwegsystem/daten_fakten.php) (letzter Zugriff 28.05.2008)."
- [2] "Hilche, T.: Genossenschaft Deutscher Brunnen e.G., persönliche Mitteilung, 2004."
- [3] "Deutscher Brauer Bund (DBB): Die deutsche Brauwirtschaft in Zahlen. URL: <http://www.brauer-bund.de/index1.html> (letzter Zugriff 27.06.2008)."
- [4] W. Flad and S. Vey, "Planung von Flaschenabfuellanlagen," *BRAUWELT*, vol. 13/14, pp. 552-558, 1994.
- [5] H. Weisser, "Meilensteine in der Abfülltechnik im 20. Jahrhundert," *Brauwelt*, vol. 51/52, pp. 2428-2430, 1999.
- [6] F. Berg, "Technische Flaschenbetriebskontrolle," *Brauwelt*, vol. 45/46, pp. 833-838, 1968.
- [7] B. Foitzik, *Abfüllanlagen für die Getränkeindustrie: Konzepte, Technik, Trends*, vol. 200: Verlag moderne industrie, 86895 Landsberg/Lech, 2000.
- [8] T. Voigt, "Neue Methoden für den Einsatz der Informationstechnologie bei Getränkeabfüllanlagen," Technische Universität München, 2004.
- [9] D. Hoppe, "Ein akustisches Resonanzverfahren zur Klassifikation von Füllständen," *tm – Technisches Messen*, vol. 66, pp. 244, 1999.
- [10] E. Vargas, R. Ceres, J. M. Martín, and L. Calderón, "Ultrasonic sensor for liquid-level inspection in bottles," *Sensors and Actuators A: Physical*, vol. 61, pp. 256-259, 1997.
- [11] A. Niedermeier, R. Ederer, and R. Fiegler, "Vorrichtung zum Inspizieren von gefüllten und verschlossenen Gefäßen," D. P.-u. Markenamt, Ed. Deutschland, 2004.
- [12] Heuft, "Neuerungen in der Inspektionstechnik," *Brauwelt*, vol. 42/43, pp. 1509, 2002.
- [13] G. Arndt, "Produktionssicherheit im Flaschenkeller," *Brauwelt*, vol. 13, pp. 387-388, 2003.
- [14] Firmin, D. Hamad, J. G. Postaire, R. D. Zhang, and G. Cedex, "Fault detection by a Gaussian neural network with reject options in glass bottle production," *SPIE Proceedings*, vol. 2785, pp. 152-162, 1996.
- [15] C. Firmin, D. Hamad, J.-G. Postaire, and R. D. Zhang, "Gaussian Neural Networks for Glass Bottles Inspection: A Learning Procedure," *International Journal of Neural Systems*, vol. 8, pp. 41-46, 1997.
- [16] K. Aas, L. Eikvil, D. Bremnes, and A. Norbryhn, "Automatic classification of bottles in crates," *Proceedings of the SPIE*, vol. 2423, pp. 108-117, 1995.
- [17] T. Rädler, "Cost factors related to integrating sorting systems," *Brauwelt International*, vol. 14, pp. 224-229, 1996.
- [18] R. Mattone, M. Divona, and A. Wolf, "Intelligent Sensing for Automatic Sorting in Industrial Processes," *EUFIT '98*, vol. 2, pp. 1399-1403, 1998.
- [19] H. Schaefer, "Kasten- und Flaschensortierung in Mineralwasserbetrieben - ein Problem ohne Ende?," *Mineralbrunnen*, vol. 45, pp. 212-214; 217, 1995.
- [20] B. Brosch, "Knifflige Flaschensortierung," *Brauwelt*, vol. 33/34, pp. 1341-1344, 2000.
- [21] F. Klein, "Leergutsortierung in der Getränkeindustrie," *Getränketechnik*, vol. 8, pp. 46-52, 1992.
- [22] K. Meyer and S. Hofer, "Neue Kasten- und Flachensortierung," *Brauwelt*, vol. 51/52, pp. 2248-2249, 2000.

- [23] M. Lotz, R. Grabrucker, and H. Vogelpohl, "Projektieren von Sortieranlagen," *Der Weihenstephaner*, vol. 61, pp. 54-58, 1993.
- [24] R. Steindreischer, "Sortieren differenter Kästen," *Die neue Verpackung*, vol. 32, pp. 543-544, 1979.
- [25] Broesele, "Trockenteil in der Getränkeabfüllung," *Brauwelt*, vol. 12, pp. 570-575, 1996.
- [26] Bartels, Garbe, Heuft, Evers, Lohr, and Pschichholz, "Wie kann ein aktueller Flaschenkeller aussehen?," *Brauwelt*, vol. 13/14, pp. 509-510, 2000.
- [27] K. Nakazawa, I. Iwasaki, and I. Yamashita, "Development of damage detection system for container," presented at Industrial Electronics, Control, and Instrumentation, 1995., Proceedings of the 1995 IEEE IECON 21st International Conference on, 1995.
- [28] M. Magee, R. Weniger, D. J. Wenzel, and R. Pirasteh, "Recognition of containers using a multidimensional pattern classifier," presented at Intelligent Robots and Computer Vision XI: Algorithms, Techniques, and Active Vision, 1992.
- [29] J. Johnstone, "Small pack inspection technology," *FERMENT*, vol. 12, pp. 33-40, 1999.
- [30] H. H. Chen, D. H. Kim, J. A. Latchinian, V. A. Brown, A. A. Kostrzewski, G. D. Savant, T. P. Jansson, and C. G. Pergantis, "Real-time holographic nondestructive inspection system with automatic defect classification," presented at Machine Vision Applications in Industrial Inspection V, 1997.
- [31] B. Bull, "Suche nach Schlafmützen und Haarrissen," *Brauwelt*, vol. 42/43, pp. 1525-1526, 2002.
- [32] W. Martin and M. Herbert, "Inspection device for empties crates and the containers in them," vol. EP1747821 KHS AG, 2007.
- [33] R. Jansen and A. Krabs, "Automatic identification in packaging - radio frequency identification in multiway systems," *Packaging Technology and Science*, vol. 12, pp. 229-234, 1999.
- [34] C. Kremkow, "Die Stabilität von Flaschenkästen nach längerer Gebrauchsdauer," *Brauwelt*, vol. 3, pp. 47-53, 1986.
- [35] J. Zacharias, "Automatische Schadenserkennung an Getränkekästen mittels Neuronumerik," Technische Universität München, 2003.
- [36] J. Zacharias, "Damage detection on crates of beverages by artificial neural networks trained with finite element data.," *Computer methods in applied mechanics and engineering*, pp. 561-574, 2004.
- [37] J. Zacharias, "Application of Neuro-Numeric for Damage Recognition on Crates of Beverages," *Neural Network World*, vol. 6, pp. 621-633, 2002.
- [38] H. Boller, "Schwingungsprüfung mit elektrodynamischen Schwingerregern," *Der Versuchs- und Forschungsingenieur* vol. 2, pp. 24-27, 1996.
- [39] R. Baker, *Eine Einführung in die Schwingungsprüfung*. Ismaning: Firmenschrift Ling Dynamik Systems Ltd. , 1992.
- [40] J. F. Hair, *Multivariate data analysis*, 6. ed. Upper Saddle River, NJ: Prentice Hall, 2006.
- [41] R. Henrion and G. Henrion, *Multivariate Datenanalyse : Methodik und Anwendung in der Chemie und verwandten Gebieten*. Berlin: Springer, 1994.
- [42] W. Kessler, *Multivariate Datenanalyse für die Pharma-, Bio- und Prozessanalytik : ein Lehrbuch*. Weinheim: Wiley-VCH, 2007.
- [43] C. Bishop, *Neural Networks for Pattern Recognition*: Oxford University Press, 1995.

- [44] D. Graupe, *Principles of artificial neural networks*, 2nd ed. Singapore ; Hackensack, N.J.: World Scientific, 2007.
- [45] K. L. Priddy and P. E. Keller, *Artificial neural networks : an introduction*, vol. IX. Bellingham, WA: SPIE Press, 2005.
- [46] A. Zell, *Simulation neuronaler Netze*. Bonn [u.a.]: Addison-Wesley, 1994.
- [47] K.-J. Bathe, *Finite-Elemente-Methoden*. Berlin: Springer, 2002.
- [48] P. Fröhlich, *FEM-Leitfaden*. Berlin: Springer-Verlag, 1995.
- [49] B. Klein, *FEM : Grundlagen und Anwendungen der Finite-Element-Methode ; mit 12 Fallstudien und 19 Übungsaufgaben*, 5., verb. und erw. Aufl.. ed. Wiesbaden: Vieweg, 2003.
- [50] F. Shahrivar and J. G. Bouwkamp, "Damage Detection in Offshore Platforms Using Vibration Information," *Journal of Energy Resources Technology-Transactions of the Asme*, vol. 108, pp. 97-106, 1986.
- [51] J. K. Vandiver, "Detection of Structural Failure on Fixed Platforms by Measurement of Dynamic-Response," *Journal of Petroleum Technology*, vol. 29, pp. 305-310, 1977.
- [52] L. Hermans and H. Van der Auweraer, "Modal testing and analysis of structures under operational conditions: Industrial applications," *Mechanical Systems and Signal Processing*, vol. 13, pp. 193-216, 1999.
- [53] G. Dalpiaz and A. Rivola, "Condition monitoring and diagnostics in automatic machines: Comparison of vibration analysis techniques," *Mechanical Systems and Signal Processing*, vol. 11, pp. 53-73, 1997.
- [54] A. S. Nowak, S. Kim, and P. R. Stankiewicz, "Analysis and diagnostic testing of a bridge," *Computers & Structures*, vol. 77, pp. 91-100, 2000.
- [55] U. P. Poudel, G. Fu, and J. Ye, "Structural damage detection using digital video imaging technique and wavelet transformation," *Journal of Sound and Vibration*, vol. 286, pp. 869-895, 2005.
- [56] Y. J. Kim, L. Jofre, F. De Flaviis, and M. Q. Feng, "Microwave subsurface imaging technology for damage detection," *Journal of Engineering Mechanics-Asce*, vol. 130, pp. 858-866, 2004.
- [57] Y. J. Kim, L. Jofre, F. De Flaviis, and M. Q. Feng, "Microwave reflection tomographic array for damage detection of civil structures," *Ieee Transactions on Antennas and Propagation*, vol. 51, pp. 3022-3032, 2003.
- [58] J. E. Michaels, "Detection, localization and characterization of damage in plates with an in situ array of spatially distributed ultrasonic sensors," *Smart Materials & Structures*, vol. 17, pp. -, 2008.
- [59] Z. G. Yang and S. G. Long, "Damage analysis for particle reinforced metal matrix composite by ultrasonic method," *Transactions of Nonferrous Metals Society of China*, vol. 16, pp. S652-S655, 2006.
- [60] N. Parida, B. R. Kumar, and D. M. Bhattacharya, "Fatigue damage assessment and detection of onset of crack initiation by x-ray diffraction," *Transactions of the Indian Institute of Metals*, vol. 51, pp. 175-177, 1998.
- [61] W. Zhishen and A. Masato, "Proceedings of the First International Conference on Structural Health Monitoring and Intelligent Infrastructure," Tokyo, Japan, 2004.
- [62] C. Boller and W. J. Staszewski, "Proceedings of the 2nd European Workshop on Structural Health Monitoring," Munich, Germany, 2004.

- [63] A. Mufti and F. Ansari, "Proceedings of the Second International Workshop on Structural Health Monitoring of Innovative Civil Engineering Structures," Winnipeg, Manitoba, 2004.
- [64] D. L. Balageas, "Proceedings of the 1st European Workshop on Structural Health Monitoring," Cachan, France, 2002.
- [65] F.-K. Chang, "Proceedings of the 4nd International Workshop on Structural Health Monitoring," Standford, California, 2003.
- [66] F.-K. Chang, "Proceedings of the 3nd International Workshop on Structural Health Monitoring," Standford, California, 2001.
- [67] F.-K. Chang, "Proceedings of the 2nd International Workshop on Structural Health Monitoring," Standford, California, 1999.
- [68] S. Doebling, C. Farrar, and M. Prime, "A summary review of vibration-based damage identification methods," *The shock and vibration digest*, vol. 30, 1998.
- [69] S. W. Doebling, C. R. Farrar, M. B. Prime, and D. W. Shevitz, "Damage identification and health monitoring of structural and mechanical systems from changes in their vibration characteristics: A literature review," 1996, pp. Size: 132 p.
- [70] A. D. Dimarogonas, "Vibration of cracked structures: A state of the art review," *Engineering Fracture Mechanics*, vol. 55, pp. 831-857, 1996.
- [71] O. S. Salawu, "Detection of structural damage through changes in frequency: a review," *Engineering Structures*, vol. 19, pp. 718-723, 1997.
- [72] C. R. Farrar, S. W. Doebling, and D. A. Nix, "Vibration-based structural damage identification," *Philosophical Transactions of the Royal Society of London Series a-Mathematical Physical and Engineering Sciences*, vol. 359, pp. 131-149, 2001.
- [73] K. Worden and J. M. Dulieu-Barton, "An overview of intelligent fault detection in systems and structures," *Structural Health Monitoring*, vol. 3, pp. 85-98, 2004.
- [74] C. R. Farrar and K. Worden, "An introduction to structural health monitoring," *Philosophical Transactions of the Royal Society a-Mathematical Physical and Engineering Sciences*, vol. 365, pp. 303-315, 2007.
- [75] H. Van der Auweraer, "International research projects on structural damage detection," *Damage Assessment of Structures*, vol. 204-2, pp. 97-112, 2001.
- [76] D. E. Bently, B. Grissom, and C. T. Hatch, *Fundamentals of rotating machinery diagnostics*. Minden, Nev.: Bently Pressurized Bearing Press, 2002.
- [77] P. J. Shull, *Nondestructive evaluation theory, techniques, and applications*. New York: M. Dekker, 2002.
- [78] C. R. Farrar and N. A. J. Lieven, "Damage prognosis: the future of structural health monitoring," *Philosophical Transactions of the Royal Society a-Mathematical Physical and Engineering Sciences*, vol. 365, pp. 623-632, 2007.
- [79] A. Rytter, "Vibration Based Inspection of Civil Engineering Structures," Aalborg University, Denmark, 1993.
- [80] J. Humar, A. Bagchi, and H. P. Xu, "Performance of vibration-based techniques for the identification of structural damage," *Structural Health Monitoring-an International Journal*, vol. 5, pp. 215-241, 2006.
- [81] C. P. Fritzen, "Vibration-based structural health monitoring - Concepts and applications," *Damage Assessment of Structures Vi*, vol. 293-294, pp. 3-18, 2005.
- [82] J. Benedito, T. Conde, G. Clemente, and A. Mulet, "Use of the acoustic impulse-response technique for the nondestructive assessment of Manchego cheese texture," *Journal of Dairy Science*, vol. 89, pp. 4490-4502, 2006.

- [83] H. Yamamoto, M. Iwamoto, and S. Haginuma, "Acoustic Impulse-Response Method for Measuring Natural Frequency of Intact Fruits and Preliminary Applications to Internal Quality Evaluation of Apples and Watermelons," *Journal of Texture Studies*, vol. 11, pp. 117-136, 1980.
- [84] P. T. Jancsok, L. Clijmans, B. M. Nicolai, and J. De Baerdemaeker, "Investigation of the effect of shape on the acoustic response of 'conference' pears by finite element modelling," *Postharvest Biology and Technology*, vol. 23, pp. 1-12, 2001.
- [85] N. Muramatsu, N. Sakurai, N. Wada, R. Yamamoto, T. Takahara, T. Ogata, K. Tanaka, T. Asakura, Y. Ishikawa-Takano, and D. J. Nevins, "Evaluation of fruit tissue texture and internal disorders by laser Doppler detection," *Postharvest Biology and Technology*, vol. 15, pp. 83-88, 1999.
- [86] T. G. Weigel and M. S. White, "The effect of pallet connection stiffness, deck stiffness and static load level on the resonant response of pallet decks to vibration frequencies occurring in the distribution environment," *Packaging Technology and Science*, vol. 12, pp. 47-55, 1999.
- [87] V. Rouillard and Michael A. Sek, "A frequency domain technique for maintaining resonance condition during sine dwell vibration testing of packages," *Packaging Technology and Science*, vol. 13, pp. 227-232, 2000.
- [88] Pitman, Knight, and Grime, "Identifying fractured containers," *European Patent Office*; [www.esp@cenet.com](http://www.esp@cenet.com), vol. GB2100432, 1982.
- [89] R. Benning, T. Becker, and A. Delgado, "Initial Studies of Predicting Flow Fields with an ANN Hybrid," *Advances in Engineering Software* vol. 32, pp. 895 - 901, 2001.
- [90] R. M. Benning, T. M. Becker, and A. Delgado, "Principal Feasibility Studies Using NeuroNumerics for Prediction of Flow Fields," *Neural Processing Letters*, vol. 16, pp. 1-15, 2002.
- [91] A. Delgado, H. Nirschl, and T. Becker, "First Use of Cognitive Algorithms in Investigations under Compensated Gravity," *Microgravity Science Technology*, vol. 9, pp. 185 - 193, 1997.
- [92] D. J. Inman and C. Minas, "Matching Analytical Models with Experimental Modal Data from Mechanical Systems," *Control and Dynamic Systems: Advances in Industrial Systems*, vol. Vol. 37, pp. pp. 327-363, 1990.
- [93] S. Alamoalli, "Effects of testing analysis, damage and environment on modal parameters," *Mechanical Systems and Signal Processing*, vol. 14, pp. 63-74, 2000.
- [94] C.-P. Fritzen, D. Jennewein, and T. Kiefer, "Damage detection based on model updating methods," *Mechanical Systems and Signal Processing*, vol. 12, pp. 163-186, 1998.
- [95] J. V. Araujo dos Santos, C. M. M. Soares, C. A. Mota Soares, and H. L. G. Pina, "A damage identification numerical model based on the sensitivity of orthogonality conditions and least squares techniques," *Computers & Structures*, vol. 78, pp. 283-291, 2000.
- [96] H. J. Wu, "Finite element modelling and experimental modal testing of a three-dimensional framework," *International Journal of Mechanical Sciences*, vol. 46, pp. 1245-1266, 2004.
- [97] S. Vanlanduit, F. Daerden, and P. Guillaume, "Experimental modal testing using pressurized air excitation," *Journal of Sound and Vibration*, vol. 299, pp. 83-98, 2007.
- [98] C. Zang and M. Imregun, "Structural damage detection using artificial neural networks and measured FRF data reduced via principal component protection," *Journal of Sound and Vibration*, vol. 242, pp. 813-827, 2001.

- [99] C. Zang, M. I. Friswell, and M. Imregun, "Structural damage detection using independent component analysis," *Structural Health Monitoring*, vol. 3, pp. 69-83, 2004.
- [100] Y. Q. Ni, X. T. Zhou, and J. M. Ko, "Experimental investigation of seismic damage identification using PCA-compressed frequency response functions and neural networks," *Journal of Sound and Vibration*, vol. 290, pp. 242-263, 2006.
- [101] L. Zhong, H. Z. Song, and B. Han, "Extracting structural damage features: Comparison between PCA and ICA," *Intelligent Computing in Signal Processing and Pattern Recognition*, vol. 345, pp. 840-845, 2006.
- [102] L. E. Mujica, J. Vehi, M. Ruiz, M. Verleysen, W. Staszewski, and K. Worden, "Multivariate statistics process control for dimensionality reduction in structural assessment," *Mechanical Systems and Signal Processing*, vol. 22, pp. 155-171, 2008.
- [103] A. M. Yan, G. Kerschen, P. De Boe, and J. C. Golinval, "Structural damage diagnosis under varying environmental conditions - part II: local PCA for non-linear cases," *Mechanical Systems and Signal Processing*, vol. 19, pp. 865-880, 2005.
- [104] H. Sohn, J. A. Czarnecki, and C. R. Farrar, "Structural health monitoring using statistical process control," *Journal of Structural Engineering-Asce*, vol. 126, pp. 1356-1363, 2000.
- [105] H. Sohn, C. R. Farrar, N. F. Hunter, and K. Worden, "Structural health monitoring using statistical pattern recognition techniques," *Journal of Dynamic Systems Measurement and Control-Transactions of the Asme*, vol. 123, pp. 706-711, 2001.
- [106] D. P. Patil and S. K. Maiti, "Experimental verification of a method of detection of multiple cracks in beams based on frequency measurements," *Journal of Sound and Vibration*, vol. 281, pp. 439-451, 2005.
- [107] J. Milberg and P. Eibelshausen, "Computer-Aided Experimental-Analysis of Mechanical Structures," *Technisches Messen*, vol. 57, pp. 424-436, 1990.
- [108] S. W. Liu, J. H. Huang, J. C. Sung, and C. C. Lee, "Detection of cracks using neural networks and computational mechanics," *Computer Methods in Applied Mechanics and Engineering*, vol. 191, pp. 2831-2845, 2002.
- [109] J. J. Lee, J. W. Lee, J. H. Yi, C. B. Yun, and H. Y. Jung, "Neural networks-based damage detection for bridges considering errors in baseline finite element models," *Journal of Sound and Vibration*, vol. 280, pp. 555-578, 2005.
- [110] Y. M. Chen and M. L. Lee, "Neural networks-based scheme for system failure detection and diagnosis," *Mathematics and Computers in Simulation*, vol. 58, pp. 101-109, 2002.
- [111] A. J. Oberholster and P. S. Heyns, "On-line fan blade damage detection using neural networks," *Mechanical Systems and Signal Processing*, vol. 20, pp. 78-93, 2006.
- [112] S. G. Pierce, K. Worden, and G. Manson, "Considerations for practical neural network application to a damage detection problem," *Damage Assessment of Structures VI*, vol. 293-294, pp. 151-158, 2005.
- [113] H. P. Zhu, Y. Z. Sima, and J. X. Tang, "Damage detection in structures using modified back-propagation neural networks," *Acta Mechanica Solida Sinica*, vol. 15, pp. 358-370, 2002.
- [114] W. T. Yeung and J. W. Smith, "Damage detection in bridges using neural networks for pattern recognition of vibration signatures," *Engineering Structures*, vol. 27, pp. 685-698, 2005.
- [115] T. Marwala, "Damage identification using committee of neural networks," *Journal of Engineering Mechanics-Asce*, vol. 126, pp. 43-50, 2000.

- [116] C. B. Yun and E. Y. Bahng, "Substructural identification using neural networks," *Computers & Structures*, vol. 77, pp. 41-52, 2000.
- [117] G. Müller and C. Groth, *FEM für Praktiker : die Methode der finiten Elemente mit dem FE-Programm ANSYS*, 4., aktualisierte Aufl.. ed. Renningen-Malmsheim: expert-Verl., 1999.
- [118] P. Fröhlich, *FEM-Anwendungspraxis : Einstieg in die Finite Elemente Analyse ; zweisprachige Ausgabe Deutsch/Englisch*, 1. Aufl.. ed. Wiesbaden: Vieweg, 2005.
- [119] O. C. Zienkiewicz, *The Finite Element Method*. Amsterdam {[u.a.]}: Elsevier, 2005.
- [120] T. J. R. Hughes, *The finite element method : linear static and dynamic finite element analysis*. Englewood Cliffs, N.J.: Prentice-Hall, 1987.
- [121] K. Knothe and H. Wesses, *Finite Elemente - Eine Einführung für Ingenieure*. Berlin Heidelberg New York: Springer Verlag, 1999.
- [122] R. Steinbuch, *Finite Elemente : ein Einstieg*. Berlin {[u.a.]}: Springer, 1998.
- [123] K. Knothe and H. Wessels, *Finite Elemente : eine Einführung für Ingenieure*, 3., überarb. und erw. Aufl.. ed. Berlin {[u.a.]}: Springer, 1999.
- [124] M. Link, *Finite Elemente in der Statik und Dynamik*, 3. Aufl.. ed. Stuttgart {[u.a.]}: Teubner, 2002.
- [125] J. Altenbach and U. Fischer, *Finite-Elemente-Praxis*, 1. Aufl.. ed. Leipzig: Fachbuchverl., 1991.
- [126] G. Sitton, *MSC/NASTRAN Basic Dynamic Analysis User's Guide*. Los Angeles: The McNeal-Schwendler Corporation, 1997.
- [127] J. Bolognese, "A Users Guide to Eigenvalue Extraction Methods in NASTRAN," *FEMCI The Book*, 1995.
- [128] E. O. Brigham, *FFT : schnelle Fourier-Transformation ; mit 8 Tabellen, 27 Beispielen und 123 Aufgaben*, 6., korr. Aufl.. ed. München {[u.a.]}: Oldenbourg, 1995.
- [129] G. Hämmerlin, *Numerische Mathematik*. Berlin [u.a.] : Springer, 1994.
- [130] C. M. Bishop, "Neural Networks and Their Applications," *Review of Scientific Instruments*, vol. 65, pp. 1803-1832, 1994.
- [131] G. Yagawa and H. Okuda, "Neural networks in computational mechanics," *Archives of Computational Methods in Engineering*, vol. 03, pp. 435-512, 1996.
- [132] M. F. Elkordy, K. C. Chang, and G. C. Lee, "Neural Networks Trained by Analytically Simulated Damage States," *Journal of Computing in Civil Engineering*, vol. 7, pp. 130-145, 1993.
- [133] J. Rhim and S. W. Lee, "A Neural-Network Approach for Damage Detection and Identification of Structures," *Computational Mechanics*, vol. 16, pp. 437-443, 1995.
- [134] D. Barschdorff and D. Becker, "Neuronale Netze als Signal- und Musterklassifikatoren - Neuronal networks as signal and pattern classifiers," *Technisches Messen tm*, vol. 57, 1990.
- [135] M. Fellner, A. Delgado, and T. Becker, "Functional nodes in dynamic neural networks for bioprocess modelling," *Bioprocess and Biosystems Engineering* vol. 25, pp. 263-270, 2003.
- [136] B. A. Paya, I. I. Esat, and M. N. M. Badi, "Artificial neural networks based fault diagnostics of rotating machinery using wavelet transforms as a preprocessor," *Mechanical Systems and Signal Processing*, vol. 11, pp. 751-765, 1997.
- [137] Z. Hongping, S. Yuzhou, and T. Jiexiang, "Damage detection in structures using modified back-propagation neural networks," *Acta Mechanica Solida Sinica*, vol. 15, pp. 358-370, 2002.

- 
- [138] H. F. Kaiser and K. W. Dickmann, "Analytic determination of common factors," *American Psychologist*, vol. 14, pp. 425, 1959.
- [139] R. B. Catell, "The scree test for number of factors," *Multivariate Behavioral Research*, vol. 1, pp. 245, 1966.