

# Entwicklung von Methoden zur Echtzeitanalyse von EKG-Signalen mit Neuro-Fuzzy-Systemen für Anwendungsszenarien der Telemedizin

Zur Erlangung des akademischen Grades eines  
DOKTOR-INGENIEURS

von der Fakultät für  
Elektrotechnik und Informationstechnik  
der Universität Fridericiana Karlsruhe

genehmigte

DISSERTATION

von

Dipl.-Ing. Gero von Wagner  
aus Maulbronn-Zaisersweiher

Hauptreferent: Prof. Dr.-Ing. K. D. Müller-Glaser  
Korreferent: Prof. Dr.-Ing. B. Meffert  
Tag der mündlichen Prüfung: 27. April 2006



Für meinen Vater  
Klaus von Wagner  
\*22.12.1930  
+03.04.2006



# Inhaltsverzeichnis

<b>1</b>	<b>Einleitung</b>	<b>1</b>
1.1	Motivation . . . . .	1
1.2	Zielsetzung dieser Arbeit . . . . .	3
1.3	Gliederung der Arbeit . . . . .	5
<b>2</b>	<b>Medizinische Grundlagen</b>	<b>7</b>
2.1	Physiologie des Herzens . . . . .	7
2.1.1	Anatomie . . . . .	7
2.1.2	Erregungsbildung und Reizleitung . . . . .	8
2.2	Pathophysiologie . . . . .	13
2.2.1	Erregungsbildungsstörungen . . . . .	13
2.2.2	Erregungsleitungsstörungen . . . . .	15
2.2.3	Reentry-Phänomene . . . . .	16
2.3	Regelungsmechanismen der Herzaktivität . . . . .	17
2.3.1	Herzratenvariabilität . . . . .	19
2.3.2	Herzratenturbulenz . . . . .	19
<b>3</b>	<b>Das Elektrokardiogramm und seine Ableitungssysteme</b>	<b>23</b>
3.1	Dipolnäherung und Herzvektor . . . . .	23
3.2	Gängige Ableitungssysteme . . . . .	25
3.3	Physiologisches EKG-Signal . . . . .	29
3.4	Pathologische Veränderungen im EKG-Signal . . . . .	31
3.4.1	Supraventrikuläre Rhythmusstörungen . . . . .	31
3.4.2	Ventrikuläre Extrasystolen . . . . .	33
3.4.3	Tachykarde Rhythmusstörungen . . . . .	34
3.5	Störgrößen des EKG-Signals . . . . .	35
<b>4</b>	<b>Mobiles EKG-Monitoring</b>	<b>37</b>
4.1	Kriterien zur Klassifikation von EKG-Überwachungssystemen . . . . .	37
4.2	Systeme für den stationären Einsatz . . . . .	39
4.3	Systeme für den mobilen Einsatz . . . . .	41
4.4	Mobiles Telemonitoring mit Online-EKG-Klassifikation . . . . .	43
<b>5</b>	<b>Systemkonzept für ein mobiles Online-Monitoring</b>	<b>45</b>
5.1	Aktuelle Situation in der Behandlung kardiovaskulärer Erkrankungen . . . . .	45
5.2	Entwurf eines Systemkonzepts für mobiles Langzeit-Monitoring . . . . .	47
5.2.1	Chancen und Vorteile des mobilen Online-Monitorings . . . . .	49
5.2.2	Grenzen und Risiken des mobilen Online-Monitorings . . . . .	50
5.3	Diagnostische Parameter für die mobile EKG-Überwachung . . . . .	51

5.4	Konsequenzen für die Online-Klassifikation . . . . .	53
<b>6</b>	<b>Signalklassifikation mit Neuro-Fuzzy-Systemen</b>	<b>57</b>
6.1	Grundlagen neuronaler Netze . . . . .	57
6.1.1	Grundbegriffe . . . . .	57
6.1.2	Training Neuronaler Netze . . . . .	58
6.2	Grundlagen der Fuzzy-Logik . . . . .	59
6.2.1	Grundbegriffe . . . . .	59
6.2.2	Nutzung von Expertenwissen . . . . .	61
6.2.3	Operationen auf Fuzzy-Mengen . . . . .	62
6.2.4	Aufbau eines Fuzzy-Systems . . . . .	63
6.3	Neuro-Fuzzy-Systeme . . . . .	64
6.4	Kombination verschiedener Fuzzy-Inferenzsysteme . . . . .	65
6.5	Verwendete Klassifikationssysteme . . . . .	67
6.5.1	NEFCLASS . . . . .	67
6.5.2	Wissensoptimierter Lernalgorithmus für Neuro-Fuzzy-Systeme . . . . .	69
6.5.3	Neue Strategie für die Optimierung von Zugehörigkeitsfunktionen . . . . .	73
6.5.4	Matlab ANFIS . . . . .	78
<b>7</b>	<b>Verfahren zur Detektion von QRS-Komplexen im EKG</b>	<b>81</b>
7.1	Übersicht über QRS-Detektionsverfahren . . . . .	81
7.2	Auswahl von Verfahren für das mobile Online-Monitoring . . . . .	83
7.3	Verwendete Entwicklungs- und Testumgebungen . . . . .	85
7.3.1	Entwicklung mit Matlab und Simulink . . . . .	85
7.3.2	Entwicklung mit dem TeDiaNet-Framework . . . . .	86
7.4	Das Detektionsverfahren nach Pan/Tompkins . . . . .	88
7.4.1	Funktionsprinzip des Verfahrens . . . . .	88
7.4.2	Simulink-Implementierung des Pan/Tompkins-Algorithmus . . . . .	90
7.4.3	Erweiterung für Mehrkanal-Detektion . . . . .	91
7.5	Das MOBD-Verfahren . . . . .	94
7.5.1	Grundlagen und Einkanal-detektion . . . . .	94
7.5.2	Das MOBD-Verfahren als Mehrkanal-detektor . . . . .	98
7.6	QRS-Detektion mit Wavelets . . . . .	99
7.6.1	Grundlagen von Wavelets . . . . .	99
7.6.2	EKG-Signalverarbeitung mit Wavelets . . . . .	101
7.6.3	Implementierung der waveletbasierten QRS-Detektion . . . . .	107
7.7	Ergebnisse der QRS-Detektion . . . . .	114
7.7.1	Ergebnisse der Implementierungen im Simulink-Framework . . . . .	114
7.7.2	Ergebnisse der Mehrkanal-detektoren . . . . .	115
7.8	Beurteilung der Verfahren . . . . .	116
7.8.1	Detektionsgüte . . . . .	116
7.8.2	Rechenaufwand, mobile Einsatzfähigkeit und Portierung auf ein Mobilsystem . . . . .	120
<b>8</b>	<b>Klassifikation von QRS-Komplexen</b>	<b>123</b>
8.1	Quantitative Analyse der Datenbasis . . . . .	123

8.2	Übersicht über QRS-Klassifikationsverfahren . . . . .	124
8.3	Vorgehen bei der Entwicklung der Schlagklassifikation . . . . .	128
8.4	Randbedingungen für die Parameterextraktion und Schlagklassifikation	130
8.5	Parameter für die Schlagklassifikation . . . . .	132
8.5.1	Waveletbasierte Parameter . . . . .	132
8.5.2	Rhythmusbasierte Parameter . . . . .	133
8.5.3	Morphologische Parameter . . . . .	135
8.6	Regeldefinitionen als Grundlage für die Fuzzy-Klassifikation . . . . .	137
8.7	Differenzierung von supraventrikulären und ventrikulären Schlägen . . .	139
<b>9</b>	<b>Erkennung von ventrikulären tachykarden Arrhythmien</b>	<b>143</b>
9.1	Signaleigenschaften des EKGs bei Auftreten von VT/VF . . . . .	143
9.1.1	Morphologie des EKGs bei VT und VF . . . . .	143
9.1.2	Eigenschaften des EKGs im Frequenzbereich . . . . .	144
9.2	Ansätze zur Klassifikation von VT-/VF-Episoden . . . . .	145
9.2.1	Stand der Technik und Forschung . . . . .	145
9.3	Waveletbasierter Ansatz für die VT-/VF-Detektion . . . . .	148
9.3.1	Matlab-GUI für die Entwicklung der waveletbasierten VT-/VF-Detektion . . . . .	148
9.3.2	Parameter für die VT-/VF-Detektion . . . . .	149
9.4	Vorgehen bei der VT-/VF-Klassifikation . . . . .	156
9.4.1	Evaluationsmethode auf der Datenbasis . . . . .	156
9.4.2	Klassifikation mit ANFIS . . . . .	157
9.4.3	Klassifikation mit NEFCLASS-J, NFS und NFC . . . . .	157
9.5	Ergebnisse der VT-/VF-Rhythmusklassifikation . . . . .	161
9.5.1	Klassifikation mit ANFIS . . . . .	161
9.5.2	Klassifikation mit NFC . . . . .	162
<b>10</b>	<b>Zusammenfassung und Ausblick</b>	<b>171</b>
<b>A</b>	<b>Medizinische Statistik und Standards</b>	<b>177</b>
A.1	Statistik in der Medizin . . . . .	177
A.2	Aktuelle Standards für EKG-Geräte mit Auswertungsfunktion . . . . .	179
A.3	Medizinische Guidelines . . . . .	181
<b>B</b>	<b>EKG-Datenbanken und Software</b>	<b>183</b>
B.1	Die Online-Ressource PhysioNet . . . . .	183
B.2	Das WFDB-Datenformat . . . . .	183
B.2.1	Aufbau eines WFDB-Datensatzes . . . . .	183
B.2.2	WFDB-Softwarebibliothek . . . . .	184
B.2.3	Annotationen nach WFDB-Konvention . . . . .	185
B.3	EKG-Datenbanken . . . . .	186
B.3.1	MIT/BIH Arrhythmia Database . . . . .	186
B.3.2	AHA Database for Evaluation of Ventricular Arrhythmia Detectors	187
B.3.3	European ST-T Database . . . . .	188
B.3.4	Creighton University Ventricular Tachyarrhythmia Database . . .	189

---

B.3.5	MIT Noise Stress Database . . . . .	189
B.4	Verteilung der Schlagklassen in der MITDB . . . . .	190
<b>C</b>	<b>Details der Wavelet-Transformation</b>	<b>193</b>
C.1	Skalenfilter bei einer Abtastfrequenz von 200 Hz . . . . .	193
<b>D</b>	<b>Übersicht über VT-/VF-Detektionsalgorithmen</b>	<b>195</b>
<b>E</b>	<b>Detaillierte Ergebnisse</b>	<b>199</b>
E.1	Ergebnisse der QRS-Detektion . . . . .	199
E.1.1	MIT/BIH Arrhythmia Database . . . . .	199
E.1.2	AHA Database . . . . .	205
E.1.3	European ST-T Database . . . . .	214
E.1.4	MIT Noise Stress Database . . . . .	224
E.2	Ergebnisse der VT-/VF-Klassifikation . . . . .	226
	<b>Literaturverzeichnis</b>	<b>229</b>
	<b>Danksagungen</b>	<b>245</b>
	<b>Lebenslauf</b>	<b>247</b>

# Tabellenverzeichnis

2.1	Übersicht über die Geschwindigkeiten der Erregungsweiterleitung . . . . .	13
3.1	Berechnung der Ableitungen . . . . .	27
3.2	Berechnung der Frank-Ableitungen . . . . .	27
3.3	Koeffizientenmatrix für berechnetes 12-Kanal-EKG . . . . .	28
3.4	Parameter des EKG-Signals . . . . .	31
3.5	Überblick über verschiedene Störgrößen des EKGs . . . . .	36
4.1	Detektionsgüten des Philips ST/AR Algorithmus . . . . .	41
5.1	Lown-Klassen . . . . .	53
6.1	Fuzzy-Operationen . . . . .	62
6.2	Rechengesetze für unscharfe Mengen . . . . .	62
7.1	Literaturübersicht: Güte von QRS-Detektoren . . . . .	84
7.2	Gültigkeit der MOBD-Peak-Kombinationen . . . . .	95
7.3	3-dB-Bandbreiten der Frequenzbänder . . . . .	104
7.4	Übersicht über die Parametersets für die QRS-Detektion . . . . .	110
7.5	Ergebnisse des Trainings für die verschiedenen Parametersets . . . . .	111
7.6	Regelbasis zur QRS-Detektion mit zwei Regeln . . . . .	112
7.7	Regelbasis mit sechs Regeln zur QRS-Detektion . . . . .	113
7.8	Ergebnisse der Simulink-Implementierung auf der MITDB . . . . .	115
7.9	Ergebnisse der Mehrkanaldetektoren . . . . .	116
7.10	Sensitivität für PVC . . . . .	117
7.11	Ergebnisse auf der NSTDB . . . . .	117
7.12	Durchschnittliche Analysedauern in CARDIOLIGHT . . . . .	120
8.1	Auftreten der Schlagklassen in den Standard-Datenbanken . . . . .	124
8.2	Prozentualer Anteil der Schlagklassen in den Datenbanken . . . . .	124
8.3	Evaluationsergebnisse für ID3- und NN-Klassifikation . . . . .	129
8.4	Trainingsergebnisse Stufe 1 . . . . .	140
8.5	Trainingsergebnisse für PVC-Klassifikation . . . . .	141
8.6	Validierungsergebnisse für PVC-Klassifikation . . . . .	141
9.1	Auswertung SAV und WAL auf den Skalen 3 und 4 . . . . .	162
9.2	Ergebnisse der FIS-Tests für eine Segmentlänge von vier Sekunden . . . . .	164
9.3	Ergebnisse der VT-/VF-Tests mit epic für CropSize=4 . . . . .	164
9.4	Ergebnisse der FIS-Tests für eine Segmentlänge von acht Sekunden . . . . .	164
9.5	Ergebnisse der VT-/VF-Tests mit epic für CropSize=8 . . . . .	164

A.1	Ergebnismatrix für eine Klassifikation mit drei Ergebnisklassen. . . . .	178
B.1	Übersicht über WFDB-Schlagannotationen . . . . .	185
B.2	Weitere WFDB-Annotationscodes . . . . .	185
B.2	Weitere WFDB-Annotationscodes . . . . .	186
B.3	Übersicht über die einzelnen Gruppen der AHA-Datenbank . . . . .	188
B.4	Übersicht über die Datensätze der NSTDB . . . . .	190
B.5	Übersicht der Schlagklassen in der MITDB . . . . .	190
B.5	Übersicht der Schlagklassen in der MITDB . . . . .	191
D.1	Leistungsfähigkeit verschiedener VF-Detektionsalgorithmen . . . . .	195
D.1	Leistungsfähigkeit verschiedener VF-Detektionsalgorithmen . . . . .	196
D.1	Leistungsfähigkeit verschiedener VF-Detektionsalgorithmen . . . . .	197
D.1	Leistungsfähigkeit verschiedener VF-Detektionsalgorithmen . . . . .	198
E.1	Ergebnisse des MOBD-Verfahrens auf der MITDB . . . . .	199
E.1	Ergebnisse des MOBD-Verfahrens auf der MITDB . . . . .	200
E.2	Ergebnisse des Pan/Tompkins-Verfahrens auf der MITDB . . . . .	201
E.2	Ergebnisse des Pan/Tompkins-Verfahrens auf der MITDB . . . . .	202
E.3	Ergebnisse des WT-basierten Verfahrens auf der MITDB bei 200 Hz . .	202
E.3	Ergebnisse des WT-basierten Verfahrens auf der MITDB bei 200 Hz . .	203
E.4	Ergebnisse des WT-basierten Verfahrens auf der MITDB bei 250 Hz . .	203
E.4	Ergebnisse des WT-basierten Verfahrens auf der MITDB bei 250 Hz . .	204
E.5	Ergebnisse des MOBD-Verfahrens auf der AHADB . . . . .	205
E.5	Ergebnisse des MOBD-Verfahrens auf der AHADB . . . . .	206
E.5	Ergebnisse des MOBD-Verfahrens auf der AHADB . . . . .	207
E.6	Ergebnisse des Pan/Tompkins-Verfahrens auf der AHADB . . . . .	207
E.6	Ergebnisse des Pan/Tompkins-Verfahrens auf der AHADB . . . . .	208
E.6	Ergebnisse des Pan/Tompkins-Verfahrens auf der AHADB . . . . .	209
E.7	Ergebnisse des WT-basierten Verfahrens auf der AHADB bei 200 Hz .	209
E.7	Ergebnisse des WT-basierten Verfahrens auf der AHADB bei 200 Hz .	210
E.7	Ergebnisse des WT-basierten Verfahrens auf der AHADB bei 200 Hz .	211
E.8	Ergebnisse des WT-basierten Verfahrens auf der AHADB bei 250 Hz .	211
E.8	Ergebnisse des WT-basierten Verfahrens auf der AHADB bei 250 Hz .	212
E.8	Ergebnisse des WT-basierten Verfahrens auf der AHADB bei 250 Hz .	213
E.9	Ergebnisse des MOBD-Verfahrens auf der EDB . . . . .	214
E.9	Ergebnisse des MOBD-Verfahrens auf der EDB . . . . .	215
E.9	Ergebnisse des MOBD-Verfahrens auf der EDB . . . . .	216
E.10	Ergebnisse des Pan/Tompkins-Verfahrens auf der EDB . . . . .	216
E.10	Ergebnisse des Pan/Tompkins-Verfahrens auf der EDB . . . . .	217
E.10	Ergebnisse des Pan/Tompkins-Verfahrens auf der EDB . . . . .	218
E.11	Ergebnisse des WT-basierten Verfahrens auf der EDB bei 200 Hz . . .	219
E.11	Ergebnisse des WT-basierten Verfahrens auf der EDB bei 200 Hz . . .	220
E.11	Ergebnisse des WT-basierten Verfahrens auf der EDB bei 200 Hz . . .	221
E.12	Ergebnisse des WT-basierten Verfahrens auf der EDB bei 250 Hz . . .	221
E.12	Ergebnisse des WT-basierten Verfahrens auf der EDB bei 250 Hz . . .	222

---

E.12 Ergebnisse des WT-basierten Verfahrens auf der EDB bei 250 Hz . . .	223
E.13 Ergebnisse des MOBD-Verfahrens auf der NSTDB . . . . .	224
E.14 Ergebnisse des Pan/Tompkins-Verfahrens auf der NSTDB . . . . .	224
E.15 Ergebnisse des WT-basierten Verfahrens auf der NSTDB bei 200 Hz . .	225
E.16 Ergebnisse des WT-basierten Verfahrens auf der NSTDB bei 250 Hz . .	225
E.17 Auswertung der Parameter „SAV“ und „WAL“ mit ANFIS . . . . .	226
E.18 Ergebnisse für Test 3 sekundenbasiert . . . . .	227
E.19 Ergebnisse für Test 3 mit <code>epic</code> . . . . .	228



# Abbildungsverzeichnis

1.1	Arztpraxis der Zukunft . . . . .	1
1.2	Todesursachen in Deutschland 2004 . . . . .	2
2.1	Anatomie des Herzens . . . . .	8
2.2	Aktionspotenzial einer Herzmuskelzelle . . . . .	9
2.3	Verlauf der Aktionspotenziale . . . . .	11
2.4	Komponenten des Erregungsbildungs- und Reizleitungssystems . . . . .	12
2.5	Resultierende Herzrhythmen bei ventrikulären Extrasystolen . . . . .	15
2.6	Wiedereintrittsmechanismus mit unidirektionalem Block . . . . .	17
2.7	Tachogramm mit Turbulence Onset (TO) und Turbulence Slope (TS) . . . . .	20
2.8	Turbulence Onset und Turbulence Slope im pathologischen Fall . . . . .	20
3.1	Einthoven-Dreieck mit Projektionslinien des Herzvektors . . . . .	25
3.2	Ableitungsvektoren der Extremitätenableitungen . . . . .	25
3.3	Wilson-Brustwandableitungen . . . . .	26
3.4	Frank-Ableitungssystem . . . . .	28
3.5	EASI-Ableitungssystem . . . . .	29
3.6	EKG-Signal . . . . .	30
3.7	Isolierte kompensierte supraventrikuläre Extrasystole . . . . .	32
3.8	Vorhofflimmern . . . . .	32
3.9	Isolierte kompensierte ventrikuläre Extrasystole . . . . .	33
3.10	Polymorphe Extrasystolen . . . . .	33
3.11	Bigeminus mit eingestreuten Couplets . . . . .	34
3.12	Tachykarde Salve . . . . .	34
3.13	Ventrikuläre Tachykardie . . . . .	35
4.1	Mobile Patienteneinheiten für stationäre EKG-Telemetriesysteme . . . . .	40
4.2	Vitaphone loop 3300 BT . . . . .	43
5.1	Gesundheitsverlauf bei herkömmlicher Therapie . . . . .	46
5.2	Gesundheitsverlauf bei Therapie mit Dauermonitoring . . . . .	47
5.3	Blockbild des BMBF-Projekts TeDiaNet . . . . .	48
5.4	EKG, extrahierte Parameter und deren Anwendungsbereichen . . . . .	52
6.1	Darstellung eines allgemeinen Neurons . . . . .	58
6.2	Zugehörigkeitsfunktionen scharfer und unscharfer Mengen . . . . .	60
6.3	Aufbau eines Fuzzy-Systems . . . . .	63
6.4	Klassifikationsstrategien . . . . .	66
6.5	Struktur des NEFCLASS-Systems . . . . .	67

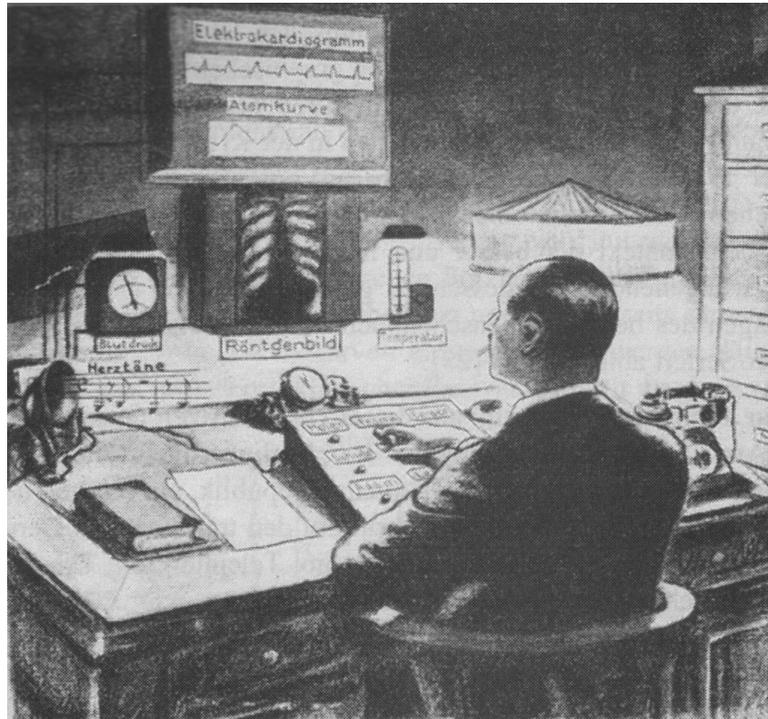
6.6	Ermittlung einer Zugehörigkeitsfunktion . . . . .	70
6.7	Bestimmung der Fußpunkte . . . . .	74
6.8	Normalisierung einer Dreiecksfunktion . . . . .	77
6.9	Java-Anwendung für die Trennpunktbestimmung . . . . .	78
7.1	Simulink-Modell zur Evaluation von QRS-Detektionsverfahren . . . . .	85
7.2	Klassendiagramm des TeDiaNet-Frameworks . . . . .	87
7.3	Stufen des QRS-Detektors. . . . .	88
7.4	Ausgangssignal des Pan/Tompkins-Mittelwertfilters. . . . .	89
7.5	Signalkonditionierung Pan/Tompkins in Simulink . . . . .	90
7.6	QRS-Detektion Pan/Tompkins in Simulink . . . . .	91
7.7	Credibility-Funktionen . . . . .	93
7.8	Peak-Kombinationen des MOBD-Algorithmus . . . . .	95
7.9	Überblick über den MOBD-Algorithmus . . . . .	96
7.10	Anpassung an Artefakte . . . . .	98
7.11	QRS-Detektion . . . . .	99
7.12	Waveletfunktion $\Psi(t)$ und Glättungsfunktion $\Theta(t)$ . . . . .	101
7.13	Impulsantworten der Li-Wavelet-Filter für $f_s = 250$ Hz . . . . .	103
7.14	Frequenzgänge der Li-WT in den Skalen 1 bis 5 . . . . .	105
7.15	Maximum-Minimum-Paare in den Skalen der WT . . . . .	106
7.16	MOBD-Featuresignale bei 200 Hz und 250 Hz Abtastrate . . . . .	119
8.1	Vorgehen bei der Schlagklassifikation . . . . .	128
8.2	Ausschnitt aus dem Datensatz 200 der MITDB . . . . .	131
8.3	Illustration der skalenbasierten Parameter für die QRS-Klassifikation. . . . .	133
8.4	Histogramme für $Max2ThresMax_3$ und $LogMax2ThresMax_3$ . . . . .	134
8.5	Scatterplot für $QRMaxSlope$ und $RSMaxSlope$ . . . . .	136
8.6	Matlab-GUI zur Visualisierung der Parameterverteilungen . . . . .	138
8.7	3D-Visualisierung der Parameterverteilung . . . . .	139
8.8	FIS-Netztopologie für die Klassifikation Normal-PVC . . . . .	140
9.1	Spektren für NSR und VF . . . . .	144
9.2	Herzrate bei Datensatz cu01 . . . . .	149
9.3	Summe der Absolutwerte pro Sekunde bei Datensatz cu01 . . . . .	150
9.4	Anzahl der Grenzwertüberschreitungen pro Sekunde . . . . .	152
9.5	Cross-Scale-Ratio . . . . .	153
9.6	Filter-Leakage-Parameter auf cu01 . . . . .	154
9.7	Statistische Verteilung des Komplexitätsparameters . . . . .	154
9.8	TCI-Parameter auf cu01 . . . . .	155
9.9	Vergleich von Parameterverteilungen cu01 und CUDB . . . . .	157
9.10	Netzdarstellung WAL 4 und VF-Leakage 5 . . . . .	159
9.11	Netzdarstellung WAL 4, Komplexität 3 und VF-Leakage 5 . . . . .	159
9.12	Netzdarstellung Herzrate, WAL 4, Komplexität 3 und VF-Leakage 5 . . . . .	160
9.13	Netzdarstellung Herzrate, Ratio, WAL 4 und VF-Leakage 5 . . . . .	160
9.14	Verhalten von SE und PP bei der Klassifikation mit ANFIS . . . . .	162
9.15	Verhalten von SP und AC bei der Klassifikation mit ANFIS . . . . .	163

---

9.16	Auswirkung der Segmentlänge auf sekundenbasierte Kennwerte . . . . .	165
9.17	Auswirkung der Segmentlänge auf <code>epic</code> -Kennwerte . . . . .	166
9.18	Auswirkungen der Mindestlänge von VT-/VF-Segmenten . . . . .	166
9.19	Sensitivität und positive Prädiktivität für die CUDB . . . . .	167
9.20	Spezifität und Genauigkeit auf den Datensätzen der CUDB . . . . .	167
9.21	Einzelergebnisse für ESE und EPP auf der CUDB . . . . .	168
9.22	Einzelergebnisse für DSE und DPP auf der CUDB . . . . .	169
9.23	VT-Episode im Datensatz <code>cu27</code> . . . . .	170
C.1	Impulsantworten der Li-Wavelet-Filter für $f_s = 200$ Hz . . . . .	194



# 1 Einleitung



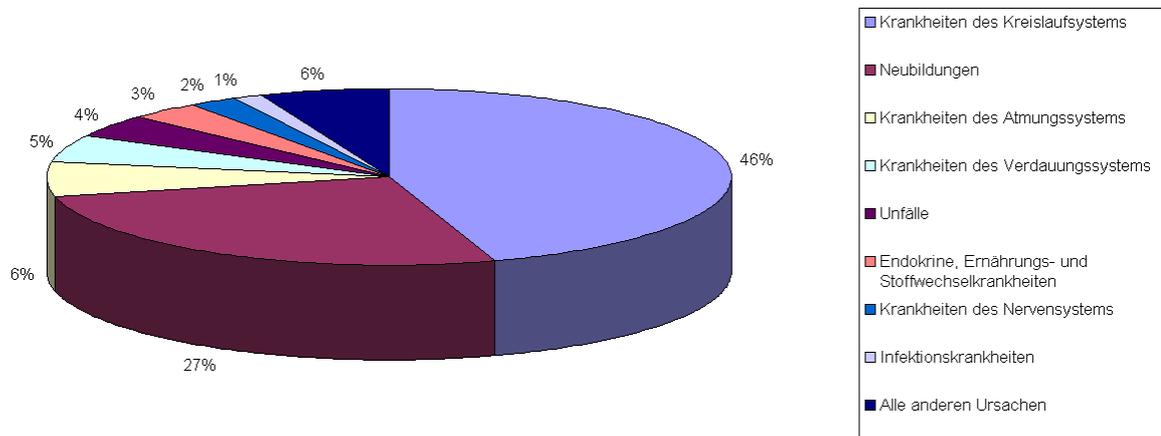
**Abbildung 1.1:** „Die Arztpraxis der Zukunft als diagnostisches Kontrollzentrum“. Abbildung aus der Berliner Illustrierten Zeitung vom 7.6.1925 (entnommen aus [KRW03]).

„[Die Elektrokardiographie gelangte] erst in Verbindung mit der Telefontechnik in die Klinik: Eigens für die Übertragung der elektrischen Herzsignale wurden Telefonkabel zwischen Krankenhaus und [Einthovens] Physiologischem Institut verlegt, so dass zur Untersuchung von Patienten deren Herzsignale ins Kilometer entfernt stehende Saitengalvanometer eingespeist werden konnten. Am Beginn der klinischen Elektrokardiographie stand die Transformation der lokalen Anordnung des physiologischen Labors in eine Telekardiogramm-Station, in der mit avancierter Kommunikationstechnik die ersten klinischen EKGs [...] aufgezeichnet wurden“. [KRW03]

## 1.1 Motivation

Erkrankungen des Herz-Kreislaufsystems sind die mit Abstand häufigste Todesursache in Deutschland und mit ca. 16% der Ausgaben der größte Kostenfaktor im Gesundheitswesen. Maßnahmen, die zu geringeren Kosten bei der Behandlung dieser Erkrankungen

führen, erscheinen daher besonders attraktiv, um die weitere Kostenentwicklung nachhaltig zu dämpfen. Es muss fast als Ironie bezeichnet werden, dass erst zum Ausgang des 20. Jahrhunderts die Potenziale der Telemedizin in dieser Hinsicht vorrangig aus Kostengründen wieder entdeckt wurden, obwohl sie in den Anfängen der Elektrokardiografie ein integraler Systembestandteil bei der klinischen Diagnostik war und danach Anlass für aus heutiger Sicht gar nicht so realitätsferne Visionen über das zukünftige Arbeitsumfeld des Arztes gab (siehe Abbildung 1.1).



**Abbildung 1.2:** Todesursachen in Deutschland 2004 [Sta06].

Dem Einsatz telemedizinischer Systeme im Bereich der kardiovaskulären Erkrankungen werden für die Zukunft aus folgenden Gründen große Chancen eingeräumt:

- Krankenhausaufenthalte können verkürzt werden, da der Patient auch in seinem alltäglichen Umfeld überwacht werden kann. Je nach Alter und Krankheitsgrad ist damit auch ein weiteres Teilhaben am Berufsleben möglich.
- Relevante Daten können dem Arzt schneller zur Kenntnis gebracht werden. Dadurch kann die Therapie schneller und besser an den aktuellen Zustand des Patienten angepasst werden.
- Entsprechende Intelligenz im mobilen System beim Patienten vorausgesetzt, kann in lebensbedrohlichen Situationen unabhängig vom Bewusstseinszustand oder aktuellem Umfeld eine Notfallmeldung abgesetzt werden und so dem Patienten schneller geholfen werden.

Insgesamt können dadurch bei gleicher oder sogar verbesserter Behandlungsqualität effektiv Kosten gesenkt werden. Kann schon die routinemäßige Datenübertragung die Therapieführung nachhaltig verbessern, so ist ein weiterer Behandlungsvorteil durch eine Datenübertragung „On-Demand“, beispielsweise beim Auftreten eines kritischen Patientenzustands, zu erwarten. In vielen solchen Fällen wird der Patient aber nicht (mehr) in der Lage sein, die Datenübertragung selbst zu initiieren, so dass das Ereignis unbeobachtet bleibt und Hilfe für den Patienten eventuell erst verspätet eintrifft. Dies kann massive negative Folgen für den weiteren Behandlungserfolg haben und geht insgesamt mit steigenden Therapiekosten einher. Anders als in Abbildung 1.1 dargestellt

wird auch kein Arzt permanent in Bereitschaft sein können, um die dauernd übertragenen Daten von einer Vielzahl von Patienten zu überwachen. Dies trifft besonders bei physiologischen Messsignalen wie dem Elektrokardiogramm (EKG) zu, die normalerweise mit einer hohen Abtastrate in mehreren Kanälen parallel erhoben werden. Von den dann unerfüllbaren Randbedingungen wie Systemlaufzeit und -größe des mobilen Patientensystems und den Kosten für die Datenübertragung ganz zu schweigen.

Daher kommt der Entwicklung von patientenautarken mobilen Systemen, die selbständig kritische Änderungen des Patientenzustandes erkennen können, eine große Rolle bei der Umsetzung telemedizinischer Szenarien zu, die ein akzeptables Nutzen-Aufwand-Verhältnis (sowohl in organisatorischer als auch in finanzieller Hinsicht) haben. Das EKG spielt bei der Beurteilung des Patientenstatus, besonders im oben angesprochenen Bereich der Herz-Kreislauf-Erkrankungen, eine zentrale Rolle.

Heute bereits vorhandene telemedizinische Lösungen im EKG-Bereich sind jedoch vor allem für den Einsatz in einem sehr begrenzten Umfeld wie einem Krankenhaus konzipiert und operieren im Normalfall mit einer permanenten Datenübertragung und einer zentralen Auswerteeinheit. Bei diesen Systemen kann in den mobilen Patientengeräten daher keine zuverlässige Interpretation des EKGs erfolgen. Andere Lösungen, die die Integration in den Alltag des Patienten ermöglichen, erfordern für die Datenübertragung die Interaktion mit dem Patienten. Auch hier geschieht keine eigentliche Signalauswertung vor Ort, sondern erst nach der Übertragung der Daten in die Arztpraxis oder ein Service-Center.

## 1.2 Zielsetzung dieser Arbeit

Es müssen also Verfahren entwickelt werden, die eine zuverlässige Online-Analyse mit kurzen Reaktionszeiten bei Eintreten eines kritischen Patientenzustandes ermöglichen und auf einer mobilen Plattform mit einer für den Patienten akzeptablen Systemlaufzeit (größer als 24 Stunden) lauffähig sind. Die Analyseverfahren sollen daher möglichst einfach und robust aufgebaut sein. Die Verfahren müssen auch bei einer erhöhten körperlichen Aktivität und dabei auftretenden (Bewegungs-)Artefakten das EKG mit hoher Güte analysieren können. Besonderer Bedeutung kommt der zuverlässigen Detektion von ventrikulären Erregungsstörungen zu, insbesondere von lebensbedrohlichen ventrikulären tachykarden Rhythmusstörungen. Für die Systempflege, Erweiterungen und Verbesserungen der Analyseverfahren ist es außerdem wünschenswert, vorhandenes medizinisches Expertenwissen möglichst einfach zu integrieren. Damit ist es möglich, die Funktionsweise des Systems für den (medizinischen) Anwender transparent zu machen.

Die vorliegende Arbeit beschäftigt sich mit der Entwicklung von Methoden, die den vorgenannten Ansprüchen genügen. Dabei steht die Identifikation geeigneter Verfahren, deren Weiterentwicklung, Verbesserung und Test auf öffentlich zugänglichem Datenmaterial im Mittelpunkt. Der Anwendungsfall des mobilen Monitorings wird bei der Auswahl der Methoden und Entwicklungsschritte stets im Auge behalten, eine vollständige Implementierung eines EKG-Klassifikationssystems auf einem realen System wird im Rahmen dieser Arbeit jedoch nicht angestrebt. Allerdings werden Möglichkeiten aufgezeigt, wie eine Portierung von Offline-Analyseverfahren auf eine mobile Plattform, die für die Online-Analyse geeignet ist, einfach und sicher realisiert werden kann. Im

Einzelnen fokussiert sich die vorliegende Arbeit auf folgende zentrale Bereiche der EKG-Analyse:

- Identifikation, Implementierung und ausführliche Erprobung von für den mobilen Einsatz geeigneten Verfahren zur QRS-Detektion
- Entwicklung eines Klassifikationssystems für die Differenzierung von Normalschlägen und ventrikulären ektopten QRS-Komplexen
- Identifikation geeigneter Parameter zur Erkennung lebensbedrohlicher ventrikulärer tachykarder Rhythmusstörungen und ihre Verknüpfung zu einem für den mobilen Einsatz tauglichen Klassifikationssystem

Ausgehend von den oben genannten Anforderungen werden in dieser Arbeit mehrere Verfahren für die QRS-Klassifikation evaluiert, einige ausgewählte Verfahren implementiert und systematisch auf öffentlich zugänglichen Datenbanken getestet. Die Testverfahren werden konform zu etablierten medizinischen Standards durchgeführt, um eine größtmögliche Transparenz zu gewährleisten. In dem vorliegenden Umfang sind diese Tests für eine größere Anzahl von QRS-Detektionsverfahren erstmalig in einer solchen Weise durchgeführt worden, dass die erzielten Ergebnisse detailliert nachvollzogen werden können.

Die Anwendung unscharfer Systeme für die Klassifikation von biomedizinischen Signalen liegt aus folgenden Gründen nahe:

1. Die große intra- und interindividuelle Varianz biologischer Signale, insbesondere auch des EKGs mit seinen vielfältigen Morphologien, lässt sich mit unscharfen Methoden deutlich besser beherrschen als mit einer auf scharfen Grenz- und Schwellwerten basierenden Logik
2. Durch die Regelbasis, die in linguistischen Termen für den menschlichen Anwender verständlich formuliert werden kann, ist das Systemverhalten transparent und jederzeit nachvollziehbar. Expertenwissen kann deutlich leichter in das bestehende Regelwerk eingebracht werden, da seine umständliche Umformulierung in formale Beziehungen und Grenzwerte entfällt.
3. Sind die Zugehörigkeitsfunktionen und die Regelbasis eines unscharfen Klassifikationssystems optimiert, weist es bei einem intelligenten Systemdesign nur einen geringfügig höheren Implementierungs- und Rechenaufwand auf als herkömmliche, meist auf heuristischen Regeln oder Entscheidungsbäumen beruhende Klassifikationssysteme.

Etablierte Methoden zur Optimierung der Zugehörigkeitsfunktionen solcher Fuzzy-Inferenz-Systeme (FIS) weisen jedoch Nachteile bei der Behandlung stark ungleichmäßig verteilter Trainingskollektive auf. Da im Normalfall versucht wird, den Gesamtfehler der Klassifikation zu minimieren, werden häufig auftretende Ergebnisklassen beim Training bevorzugt. Gerade im medizinischen Umfeld sind jedoch die deutlich seltener auftretenden pathologischen Ereignisse relevant und daher bei der Klassifikation wichtiger als die häufig auftretenden normalen Ereignisse. Die Auswahl bestimmter Trainingsmuster aus

einem größeren Kollektiv birgt die Gefahr, dass eine zu spezielle Anpassung des FIS an die vorgegebenen Daten stattfindet und das System nicht mehr in der Lage ist, adäquat auf die möglichen Parametervariationen zu reagieren. Um dieses Problem so weit wie möglich zu umgehen, wurde die Systemoptimierung anders als bei bisher beschriebenen Verfahren üblich auf möglichst „natürlichen“ Kollektiven vorgenommen.

Dieses Vorgehen wird bereits bei der Schlagdetektion angewandt, in den Bereichen der Schlag- und Rhythmusklassifikation jedoch noch intensiviert. Für die Schlagklassifikation werden eine Vielzahl von möglichen Parametern untersucht und erste Systeme für die Unterscheidung von normalen und ventrikulären Schlägen aufgezeigt. Ebenso werden für die Detektion lebensbedrohlicher Rhythmusstörungen verschiedene Algorithmen zur Parameterextraktion, darunter auch einige etablierte Verfahren, erstmalig auf speziell vorverarbeitete EKG-Signale angewendet. Dabei wird der sequentielle Einsatz von für verschiedene Einsatzzwecke optimierten FIS für die Verbesserung der Klassifikationsgüte exemplarisch demonstriert.

## 1.3 Gliederung der Arbeit

Grundlagen zum Verständnis der komplexen Physiologie des Herzens und einige der möglicherweise auftretenden Pathophysiologien werden in Kapitel 2 dargestellt. Die dem Elektrokardiogramm zu Grunde liegenden Modelle und verbreitete Ableitungskonfigurationen werden in Kapitel 3 vorgestellt, ebenso wie das Standard-EKG und Signalbeispiele für verschiedene Herzrhythmen und pathologische Störungen des EKGs. Eine Übersicht über Störgrößen des EKGs schließt dieses Kapitel ab.

Kapitel 4 führt wichtige Begriffe im Zusammenhang mit dem mobilen Langzeit-EKG-Monitoring ein und gibt einen Überblick über den Stand der Technik und derzeit auf dem Markt befindlicher Systeme.

Das neue Systemkonzept, in dem die in dieser Arbeit entwickelten Algorithmen eingesetzt werden sollen, wird in Kapitel 5 vorgestellt. Darin wird auch ein Überblick über den geplanten Einsatz, die zu überwachenden Kenngrößen und die sich daraus ergebenden Konsequenzen für das Systemkonzept gegeben.

Die im Rahmen dieser Arbeit für die Klassifikation verwendeten bzw. entwickelten (Neuro-)Fuzzy-Systeme werden mit den dazugehörigen theoretischen Grundlagen in Kapitel 6 behandelt. Neben zwei bekannten Standardverfahren werden zwei im Rahmen dieser Arbeit erweiterte bzw. neu entwickelte Verfahren präsentiert, die eine bessere Klassifikation von selten auftretenden Ereignissen in großen Trainingskollektiven ermöglichen. Die dabei implementierten Strategien für die Optimierung von Fuzzy-Zugehörigkeitsfunktionen werden ausführlich erläutert. Diese neu entwickelten Verfahren können als flexible Grundlage für eine neue Generation von wissensbasierten Klassifikationssystemen für spezielle medizinische Aufgaben dienen.

Die QRS-Detektion als wesentliche Grundlage für die weitere EKG-Klassifikation wird ausführlich in Kapitel 7 behandelt. Nach einem Überblick über einige wesentliche in der Literatur beschriebenen Verfahren werden die drei im Rahmen dieser Arbeit näher untersuchten QRS-Detektoren vorgestellt. Diese wurden im Zuge der Entwicklung in ihrer Detektionsleistung deutlich verbessert und zu Mehrkanaldetektoren erweitert. Darunter ist auch ein neuer waveletbasierter Detektor, der mit einer fuzzy-basierten Schlagdetek-

tion arbeitet. Alle Verfahren wurden systematisch und standardkonform auf öffentlich zugänglichen Datenbanken getestet. Die dabei erzielten Ergebnisse werden ausführlich dokumentiert und kommentiert. Alle Verfahren werden hinsichtlich ihrer Einsatzfähigkeit auf einer mobilen Plattform beurteilt. Die Vorstellung einer möglichen Portierungsstrategie vom stationären System auf das Mobilsystem für die Verfahren mit Hilfe eines automatischen Transformationstools rundet dieses Kapitel ab.

Die Unterscheidung von normalen und ventrikulären ektopten Schlägen bildet das zentrale Thema von Kapitel 8. Nach einer Analyse des zur Verfügung stehenden Datenmaterials und einer Übersicht über die in der Literatur beschriebenen Verfahren wird das eingeschlagene Vorgehen für die Entwicklung der Schlagklassifikation erläutert. Die für die Schlagklassifikation extrahierten Parameter werden detailliert beschrieben. Die Verwendung der stabilsten Parameter in einem neuen sequentiellen Fuzzy-Klassifikationssystem und die damit auf dem vorhandenen Datenmaterial erzielten Ergebnisse werden ausführlich diskutiert.

Derselbe Ansatz wird in Kapitel 9 zur Detektion von lebensbedrohlichen tachykarden Rhythmusstörungen verwendet. Die dabei angewendeten Testanforderungen sind deutlich höher anzusiedeln als bei den meisten in der Literatur beschriebenen Verfahren, die ebenfalls erläutert werden. Durch die neuartige Anwendung von etablierten Parametern auf wavelettransformierte EKG-Signale nach dem „Algorithme á trous“ Verfahren erbringt eine deutliche Verbesserung im Vergleich zu den ursprünglichen EKG-basierten Verfahren. Bei Tests auf dem von medizinischen Standards vorgeschriebenem Datenmaterial werden Ergebnisse erzielt, die einen baldigen Einsatz in einem realen System möglich erscheinen lassen. Die Verwendung der neu entwickelten Strategien für die Optimierung von Fuzzy-Zugehörigkeitsfunktionen zeigen sich den etablierten Methoden ebenbürtig und teilweise überlegen.

Kapitel 10 fasst die Ergebnisse der Arbeit noch einmal zusammen und zeigt mögliche weitere Entwicklungsschritte auf.

An dieser Stelle sei auf Anhang A verwiesen, der die wesentlichen in dieser Arbeit verwendeten statistischen Kenngrößen vorstellt und einen Überblick über die medizinischen Standards gibt, die wesentlichen Einfluss auf die Gestaltung dieser Arbeit genommen haben. In weiteren ausführlichen Anhängen werden die verwendeten Datenbanken detailliert beschrieben (Anhang B) und Zusatzinformationen zu den im Rahmen dieser Arbeit implementierten Verfahren bzw. zum Stand der Technik (Anhänge C und D) gegeben. Großen Raum nimmt die ausführliche Dokumentation der erzielten Ergebnisse in Anhang E ein.

## 2 Medizinische Grundlagen

In diesem Kapitel werden die medizinischen Grundlagen, die zum Verständnis der vorliegenden Arbeit wichtig sind, erläutert. Ausgangspunkt bildet die Physiologie des Herzens zusammen mit den Regelmechanismen der Herzaktivität. Danach werden mögliche pathophysiologische Änderungen der Herzaktivität vorgestellt.

### 2.1 Physiologie des Herzens

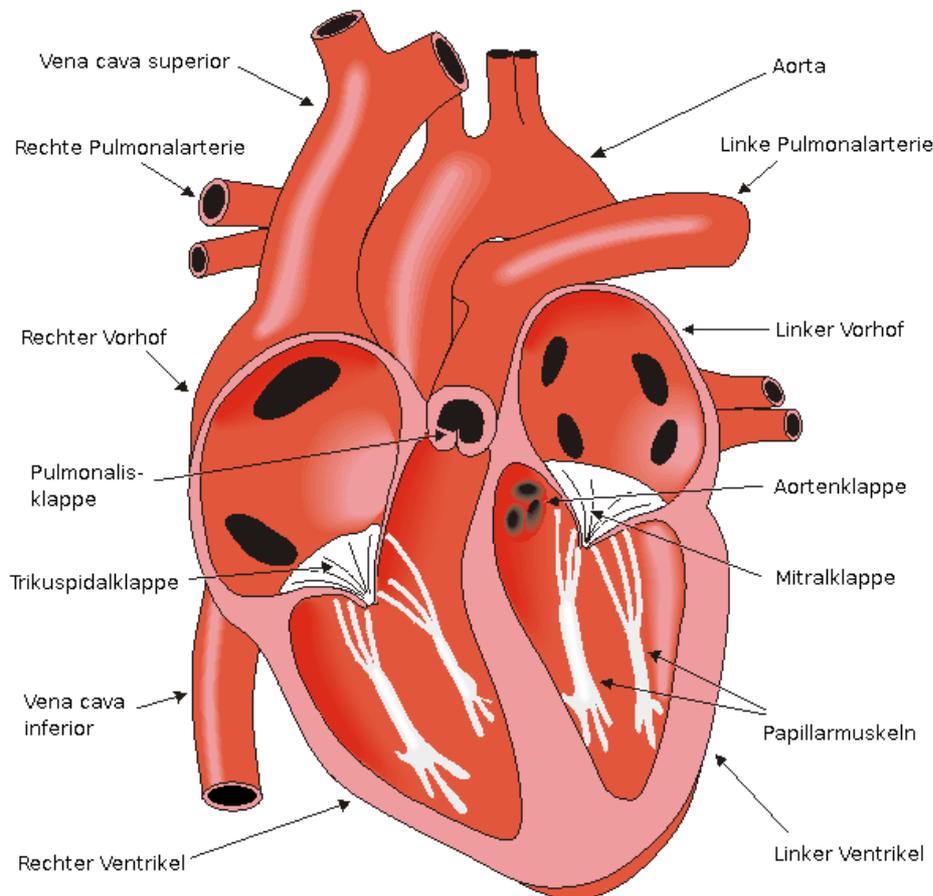
#### 2.1.1 Anatomie

##### Lage und Aufbau

Das Herz ist ein etwa faustgroßer, bei Erwachsenen ca. 300 g schwerer Hohlmuskel, der durch einen stabilen, bindegewebigen Beutel (Perikard) geschützt wird und im Mediastinum, in der Brusthöhle zwischen den beiden Lungenflügeln oberhalb des Zwerchfells, liegt. Es ist in vier Kompartimente unterteilt. Neben der vertikalen Teilung durch das Herzseptum in linkes und rechtes Herz existiert noch eine horizontale Teilung in die Herzvorhöfe (Atrien) und -kammern (Ventrikel). Der Blutstrom im Herzen wird durch die Segelklappen zwischen den Vorhöfen und den Kammern, sowie die Taschenklappen zwischen den Ventrikeln und den abgehenden Arterien geregelt (siehe Abbildung 2.1). Die Papillarmuskeln verhindern dabei das Öffnen der Trikuspidal- bzw. der Mitralklappe zu den Vorhöfen während der Kontraktionsphase der Kammern. Die Vorhöfe sind muskulär deutlich schwächer ausgebildet als die Kammern. Das rechte Herz, das den Lungenkreislauf versorgt, weist eine dünnere Herzmuskulatur (Myokard) auf als das linke, das den großen Körperkreislauf versorgt. Dies hat seine Ursache im unterschiedlichen Druck in den Gefäßen, die zur Aufrechterhaltung des Blutflusses notwendig sind: Sie schwanken im Normalfall zwischen 5 mmHg diastolisch und 25 mmHg systolisch im Lungenkreislauf und zwischen 80 mmHg und 120 mmHg im Körperkreislauf. Das Arbeitsmyokard der Ventrikel besteht aus vier verschiedenen Muskelzügen, die sich von außen nach innen wie folgt anordnen: zwei spiralförmig angeordnete Schrägschichten, die beide Kammern umschließen, einer Mittelschicht, die ringförmig um jedes Ventrikel verläuft und eine weitere Längsschicht, die nur das linke Ventrikel umschließt. Das Myokard der Atrien und der Ventrikel wird durch das bindegewebige Herzskelett getrennt.

##### Der Weg des Blutes durch das Herz

Der Blutrückstrom aus dem Körper zum Herz erfolgt über die Vena cava inferior und superior, die in den rechten Vorhof münden. Von der rechten Kammer aus gelangt das Blut dann über den Lungenarterienstamm (Truncus pulmonalis) in die Lunge und nach



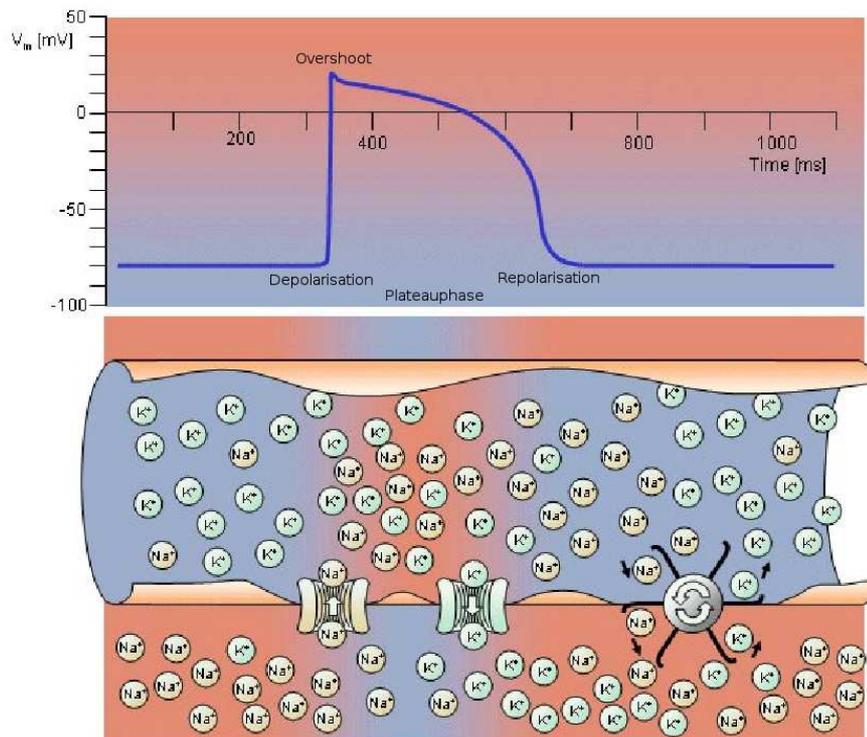
**Abbildung 2.1:** Anatomie des Herzens (modifiziert aus [MP05])

der Aufsättigung mit Sauerstoff durch die Venae pulmonalis in den linken Vorhof. Das Auspumpen des Blutes in den Körperkreislauf geschieht über die Aorta. Die Versorgung des Herzgewebes wird durch die Herzkranzgefäße (Koronarien) übernommen, die kurz hinterhalb der Aortenklappe abzweigen. Der Anteil der Eigenversorgung des Herzens am Herzzeitvolumen (HZV) liegt relativ belastungsunabhängig bei ca. 5%. Durch die Kontraktion des Herzmuskels ist eine Durchblutung der Herzkranzgefäße nur in der Erschlaffungsphase (Diastole) des Herzens möglich. Die Versorgung des Myokards geschieht dabei durch Diffusion der Nährstoffe und Stoffwechselprodukte von außen über die Koronarien.

## 2.1.2 Erregungsbildung und Reizleitung

### Erregungsverlauf und mechanische Kontraktion einer Herzmuskelzelle

Die Kontraktion einer einzelnen Myokardfaser wird durch eine Veränderung des Zellmembranpotenzials ausgelöst. Der Verlauf der Transmembranpotenzial über der Zeit wird Aktionspotenzial genannt und kann in folgende Phasen eingeteilt werden, die in Abbildung 2.2 dargestellt sind:



**Abbildung 2.2:** Verlauf des Aktionspotenzials einer Herzmuskelzelle (oben) und Illustration der Ionenverteilungen und -ströme während seiner einzelnen Phasen [MP05]. Im Bild rechts unten ist der aktive Rücktransport der Kalium-Ionen in den Intra- und der Natrium-Ionen in den Extrazellulärraum durch eine Na-K-Pumpe zu sehen.

**Ruhepotenzial:** In unerregtem Zustand besteht zwischen Extra- und Intrazellulärraum einer Muskelzelle eine Potenzialdifferenz von ca. -80 bis -90 mV, die v.a. durch die unterschiedlichen Konzentrationen von Natrium- und Kaliumionen bestimmt wird. Die Konzentrationsgradienten und damit das Ruhepotenzial werden durch aktiven Ionenaustausch mit Hilfe von Natrium-Kalium-Pumpen in der Zellmembran aufrecht erhalten und sind ohne externe Einflüsse stabil.

**Depolarisation:** Eine elektrische Erregung hat eine Veränderung der Ionenkonzentrationen an der Membran der Muskelzelle zur Folge, wodurch die Transmembranspannung steigt. Dadurch wird die Leitfähigkeit natriumspezifischer Ionenkanäle in der Zellmembran und damit deren Permeabilität für Natriumionen erhöht. Ab Erreichen eines Schwellenpotenzials von ca. -60 mV kommt es durch positive Rückkopplung zu einem massenhaften Einstrom von Natriumionen in den Intrazellulärraum, in dessen Folge das Membranpotenzial zusammenbricht und es sogar zu einer Umpolarisierung bis auf ungefähr +30 mV kommt („Overshoot“).

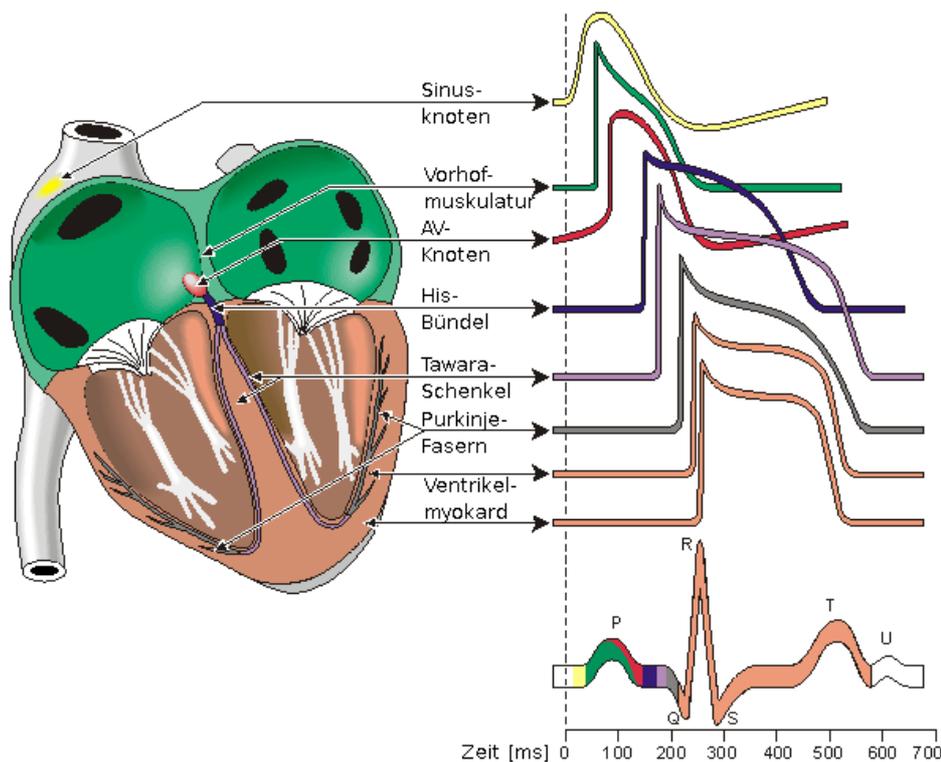
**Repolarisation:** Die anschließende Erregungsrückbildung lässt sich in drei Phasen einteilen. In der ersten Phase geht das Membranpotenzial durch einen verstärkten Kaliumausstrom wieder zurück auf ca. 0 mV. Die darauffolgende zweite Phase wird Pla-

teauphase genannt, da sich in ihr das Membranpotenzial nur sehr wenig ändert. Dieses Plateau ist ein Charakteristikum des einfachen Arbeitsmyokards und wird u.a. durch den Einstrom von Calciumionen verursacht, die zum einen über sog. „langsame Kanäle“ aus dem Extrazellulärraum in das Zellinnere strömen, zum anderen aus zellinternen Strukturen stammen und wesentlich für die Kopplung zwischen elektrischer Erregung und mechanischer Kontraktion des Myokards verantwortlich sind. In der dritten Phase wird das Ruhepotenzial durch schnelle Repolarisation in Folge weiterhin starken  $Ka^+$ -Ausstroms wieder erreicht [ST95] und dann durch aktive Arbeit mit Hilfe von in die Zellmembran integrierten Natrium-Kalium-Pumpen (Na-K-Pumpen) das ursprüngliche Ionenkonzentrationsverhältnis wieder hergestellt.

Nach Wiederherstellung des Ruhepotenzials ist der Muskel wieder vollständig erregbar. In der Zeit vom Beginn der Depolarisation bis zur Repolarisation des Membranpotenzials auf -40 bis -50 mV reagiert der Muskel nicht auf neue Reize, er befindet sich in der absoluten Refraktärphase. In der anschließenden relativen Refraktärphase ist der Muskel bedingt erregbar, jedoch sind auch mit großen Reizstärken nur kleine Reizantworten zu erreichen. Diese fallen umso geringer aus, je früher in der relativen Refraktärzeit die neue Erregung eintrifft. Eine leicht inhomogene Repolarisierung des Myokards kann daher im Normalfall nicht zu einer gegenseitigen Wiedererregung führen, u.a. auch deswegen, weil die für eine Depolarisation notwendigen Ionengradienten noch nicht wiederhergestellt sind. Erst mit Erreichen des Ruhepotenzials kann wieder eine normale Reaktion des Myokards ausgelöst werden. Die effektive Refraktärzeit kennzeichnet die Phase, in der ein Reiz keine Gesamterregung des Herzen auslösen kann, weil er noch auf refraktäres Gewebe in seiner Umgebung trifft und sich damit nicht weiter ausbreiten kann [GH99].

## Erregungsbildung

Im Gegensatz zur normalen Muskulatur, bei der die Muskelerregung von außen durch Innervation induziert wird, entsteht die Erregung des Herzens im Organ selbst. Diese Fähigkeit zur rhythmischen Eigenerregung nennt man Herzautomatismus [psc98]. Verursacht wird diese autonome Erregung durch sogenannte Schrittmacherzellen. Im Gegensatz zum Arbeitsmyokard, das ein konstantes Ruhepotenzial besitzt, beginnt bei diesen Zellen sofort nach der Repolarisation eine langsame Depolarisation. Das Minimum des Transmembranpotenzials wird daher nicht Ruhepotenzial, sondern maximales diastolisches Potenzial (MDP) genannt. Bei Erreichen eines Schwellenpotenzials, das zwischen -50 und -60 mV liegt, beschleunigt sich die Depolarisation und die Zelle wird erregt. Die Zellen, die die Fähigkeit zur spontanen Depolarisation besitzen, gehören zum Erregungsbildungssystem, das aus mehreren Schrittmachern besteht. Der primäre Schrittmacher ist der Sinusknoten, der in Körperruhe eine Eigenfrequenz von 60 - 80 Erregungen pro Minute hat. Daraus ergibt sich die Herzfrequenz, die in *Schlägen pro Minute* (S/min) oder *beats per minute* (bpm) angegeben wird. Die spontane Depolarisation im AV-Knoten, dem sekundären Schrittmacher, verläuft langsamer als im Sinusknoten, daher ist auch die autonome Herzfrequenz in diesem Falle niedriger (40 - 60 bpm). Im physiologischen Fall kommt er nicht zum Einsatz, da die Erregung vom Sinusknoten bereits beim AV-Knoten eingetroffen ist, bevor dessen spontane Depolarisation das Schwellenpotenzial erreicht hat. Das gilt auch für den tertiären Schrittmacher.

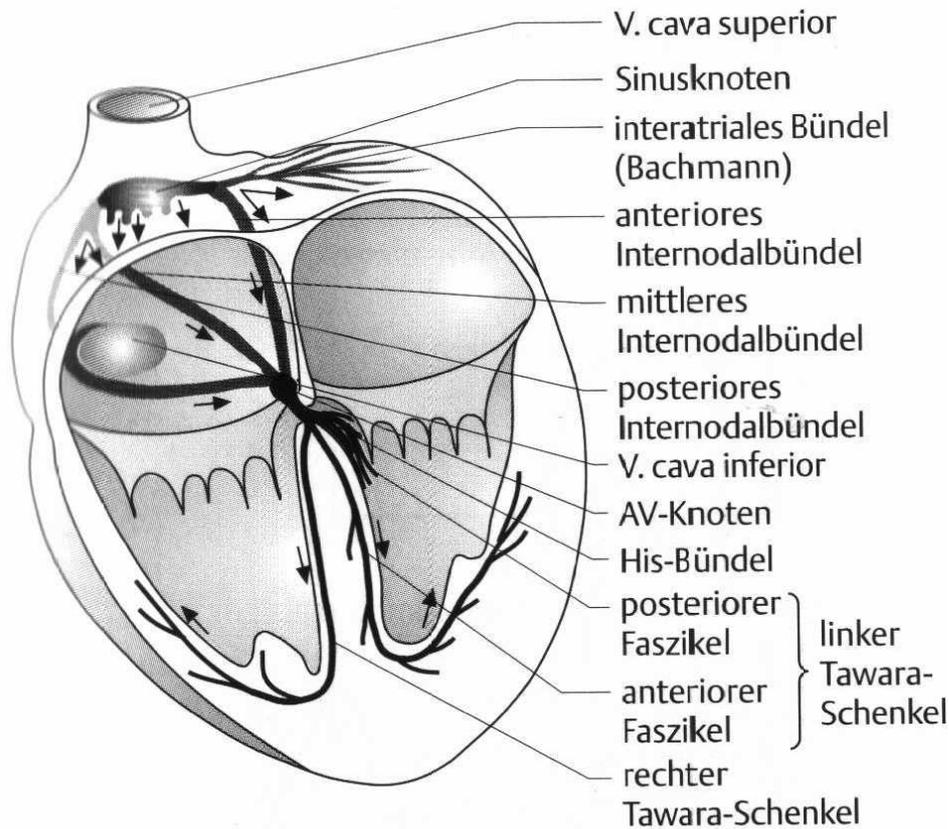


**Abbildung 2.3:** Verlauf der Aktionspotenziale in den Schrittmacherzentren, im Reizleitungssystem und im Myokard und ihre Beiträge zum Standard-EKG. Abbildung modifiziert aus [MP05].

cher, das His-Tawara-Purkinje-System, das eine Erregungsfrequenz von 20 - 40 bpm hat. Durch die unterschiedlichen Refraktärzeiten der einzelnen Schrittmacher wird eine Mehrfacherregung im Herzen verhindert. Sekundärer und tertiärer Schrittmacher werden auch als potenzielle oder latente Schrittmacher bezeichnet. Sie übernehmen die Schrittmacherfunktion nur, wenn es eine Störung im Erregungsleitungssystem gibt oder es zu keiner anderen Erregungsbildung gekommen ist [GH99], siehe dazu auch Kapitel 2.2. Abbildung 2.3 zeigt die Verläufe der Aktionspotenziale für verschiedene Teile des Reizbildungs- und Reizleitungssystems. Auffällig ist dabei, dass die Schrittmacherzentren keine ausgeprägte Plateauphase besitzen.

### Erregungsleitung

Um die elektrische Trennung von Vorhöfen und Kammern zu überwinden und die koordinierte Kontraktion des Herzmuskels zu gewährleisten, wird die elektrische Erregung durch das sog. Erregungsleitungssystem oder Reizleitungssystem (RLS) innerhalb des Herzens fortgeleitet. Die Zellen des RLS sind besonders glykogenreich und können auch anatomisch vom einfachen Arbeitsmyokard unterschieden werden. Die Erregung beginnt im physiologischen Fall im Sinusknoten, der sich in der Vorderwandverdickung des rechten Herzhohls in der Nähe der Einmündung der V. cava superior in den rechten Vorhof befindet. Von dort breitet sie sich über das Vorhofmyokard aus. Die schnelleren Leitungs-



**Abbildung 2.4:** Komponenten des Erregungsbildungs- und Reizleitungssystems [Hor98]

bahnen in den drei Internodalbündeln dienen der gezielten Erregung des AV-Knotens, während das interatriale (Bachmann-)Bündel der zeitlich koordinierten Erregung des weiter entfernt liegenden linken Vorhofs dient. Durch eine Verzögerung der Erregungsweiterleitung im AV-Knoten von etwa 90 ms kann das Blut von den Vorhöfen in die Kammern fließen. Vom AV-Knoten aus läuft die Erregung in der Kammerscheidewand über das His-Bündel mit den anschließenden Tawara-Schenkeln zu den Purkinje-Fasern, die sich im Ventrikelmyokard verzweigen. Siehe hierzu auch Abbildung 2.4. Die dort ankommende Erregung löst eine vollständige Kontraktion beider Ventrikel aus [GH99]. Die Geschwindigkeit der Erregungsweiterleitung schwankt in den einzelnen Teilen des RLS, wie Tabelle 2.1 zeigt.

### Erregungsausbreitung im Myokard

Die Zellen der Herzmuskulatur sind durch Brücken, die so genannten *gap junctions*, miteinander verbunden. Diese Koppelung ermöglicht die schnelle Erregungsausbreitung von einer Zelle zur nächsten. Alle Zellen, die durch *gap junctions* miteinander verbunden sind, werden erregt, wenn eine Erregung innerhalb des Verbandes entsteht (Alles-oder-nichts-Gesetz). Dieser Verband wird als funktionelles Synzytium bezeichnet. Auch diese Eigenschaft der Herzmuskulatur ist einmalig im Organismus, da sonst jede Kontraktion

**Tabelle 2.1:** Übersicht über die Geschwindigkeiten der Erregungsweiterleitung in den einzelnen Teilen des Reizleitungssystems (nach [BU02])

Komponente des RLS	Geschwindigkeit der Erregungsleitung [m/s]
Vorhof	0,6
AV-Knoten	0,04-0,1
His-Bündel	1,0
Tawara-Schenkel	2,0
Purkinje-Fasern	1,5-4,0
Arbeitsmyokard	0,5

von Muskelfasern durch den innervierenden Nerv hervorgerufen wird. Atrien und Ventrikel bilden getrennte funktionelle Synzytien [SD91], die Rolle des „Isolators“ übernimmt dabei das Herzskelett in der Klappenebene. Je nach ihrer Lokalisierung besitzen die Myokardzellen unterschiedlich lange Plateauphasen, die im Wesentlichen von der Größe des umgebenden funktionellen Synzytiums und der sich daraus ergebenden möglichen Weglänge für kreisende Erregungen (siehe hierzu Kapitel 2.2.3) abhängt.

## 2.2 Pathophysiologie

Es gibt eine Vielzahl von pathologischen Fällen in der Herzerregung. Allen Pathologien ist gemein, dass sie die normale Herzerregung be- oder eventuell sogar verhindern und damit negative Auswirkungen auf die Pumparbeit des Herzens haben. Dadurch besteht die Gefahr einer Minderdurchblutung des Organismus. In der Folge werden nur die für die vorliegende Arbeit wichtigsten Pathologien kurz dargestellt.

### 2.2.1 Erregungsbildungsstörungen

Bei den Erregungsbildungsstörungen gibt es drei wesentliche Erscheinungsbilder:

1. Eine Veränderung der Erregung des Sinusknotens.
2. Der Ausfall eines Erregungszentrums, d.h. das Ausbleiben der normalen Erregung.
3. Ein zusätzlich zum normalen Schrittmacher arbeitendes Erregungszentrum.

Der erste Fall beschreibt sog. nomotope Erregungsbildungsstörungen. Dazu gehören die Sinustachykardie (Herzfrequenz (HF) in Körperruhe  $>100$  bpm), die Sinusbradykardie (HF  $<60$  bpm), die Sinusarrhythmie und das Sinusknotensyndrom.

Im zweiten Fall wird die Erregung des Herzens durch ein untergeordnetes Schrittmacherzentrum übernommen. Dieser Vorgang wird als passive Heterotopie oder Ersatzsystole bezeichnet. Ursachen für passive Heterotopie sind Änderungen in der Depolarisation des Sinusknotens, die so lang dauert, dass der AV-Knoten als sekundäres Schrittmacherzentrum sein Schwellenpotenzial erreicht. In schwereren Fällen können aber auch erst die tertiären Schrittmacherzentren für eine Herzerregung sorgen.

Das im letzten Punkt beschriebene Phänomen ist eine sog. aktive Heterotopie, die sich meist als eine vorzeitige Kammererregung (Extrasystole) zeigt. Diese Erregungsbildungsstörungen können innerhalb oder außerhalb des normalen Erregungsbildungssystems auftreten [psc98]. Je nach Ort ihrer Entstehung unterteilt man sie in supraventrikuläre und ventrikuläre Erregungsbildungsstörungen. Bei supraventrikulären Erregungen werden die Kammern auf physiologischem Weg erregt, d.h. das Erregungszentrum liegt oberhalb des His-Bündels. Im ventrikulären Fall nimmt die Erregungsfront einen anderen Verlauf durch die Kammern.

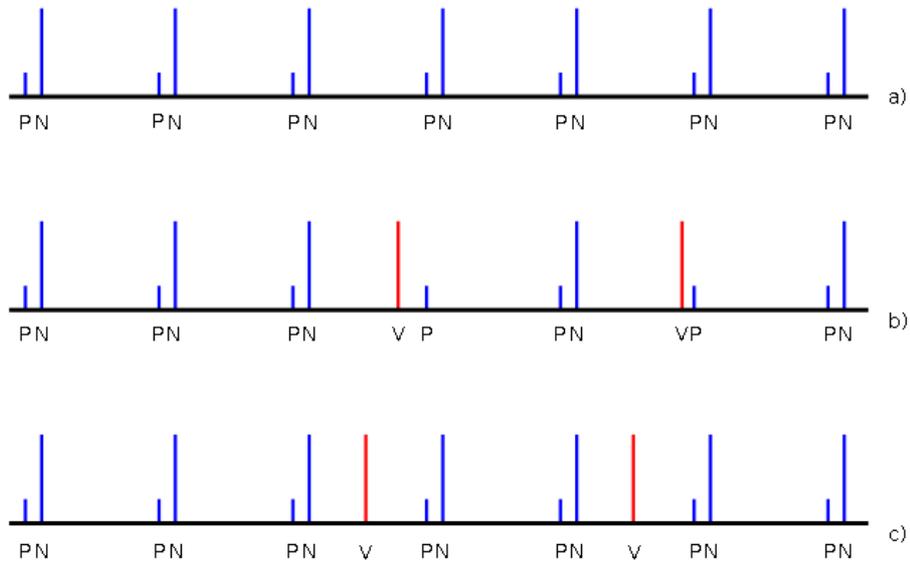
Aktive Heterotopie entsteht entweder durch pathologische Veränderungen der Depolarisation von Zellen des Erregungsbildungssystems oder durch Umwandlung von Myokardzellen in Zellen mit spontaner diastolischer Depolarisation. Sie führen wie bereits erwähnt meist zu Extrasystolen, wobei diese vereinzelt auftreten können oder eine feste Kopplung eingehen können. Folgen einem Normalschlag eine oder mehrere Extrasystolen, so gelten im deutschen Sprachraum folgende Bezeichnungen [GH99]:

- 1 Extrasystole  $\Rightarrow$  vereinzelte Extrasystole
- 2 konsekutive (aufeinanderfolgende) Extrasystolen  $\Rightarrow$  Couplet
- 3 konsekutive Extrasystolen  $\Rightarrow$  Triplet
- 3-5 konsekutive Extrasystolen  $\Rightarrow$  Salve
- 6 und mehr konsekutive Extrasystolen  $\Rightarrow$  Tachykardie

Bildet sich eine feste Abfolge von Normalschlägen mit darauffolgenden Extrasystolen aus, so verwendet man folgende Termini (Anzahl Normalschlag:Anzahl Extrasystolen):

- 1:1-Extrasystolie  $\Rightarrow$  Bigeminus
- 1:2-Extrasystolie  $\Rightarrow$  Trigeminus
- 1:3-Extrasystolie  $\Rightarrow$  Quadrigeminus

Die zwei verschiedenen Arten, auf die vereinzelte ventrikuläre Extrasystolen (VES, engl. Premature Ventricular Contraction PVC) in den normalen Herzrhythmus einfallen können, zeigt Abbildung 2.5. In der obersten Zeile a) ist ein normaler Sinusrhythmus zu sehen: Jeder Vorhoferregung (P) folgt eine Kammererregung (N). In Zeile b) treten zwei ventrikuläre Extrasystolen (V) mit kompensatorischer Pause auf. Diese vorzeitigen Erregungen haben ihren Ausgangspunkt im Bereich der Kammern, es erfolgt keine Erregung über den Vorhof (fehlendes P). Die nächste Erregung des Sinusknotens trifft dann auf refraktäres Gewebe, d.h. es erfolgt keine Kammererregung, sondern erst wieder nach der nächsten Normalerregung. Charakteristischerweise ist bei dieser Art von VES das Kopplungsintervall zum vorhergehenden Normalschlag deutlich verkürzt, danach folgt die kompensatorische Pause, also ein durch die „fehlende“ Normalerregung deutlich verlängertes Intervall bis zum nächsten Normalschlag. Zeile c) schließlich zeigt intermittierende VES: Hier führt auch die nächste Vorhoferregung zu einer Kammeraktion, d.h. der Grundrhythmus der Normalerregungen bleibt ungestört, die VES fallen



**Abbildung 2.5:** Veranschaulichung der resultierenden Herzrhythmen bei ventrikulären Extrasystolen (V) mit kompensatorischer Pause (b) und intermittierend einfallend (c). Die oberste Zeile (a) zeigt einen normalen Sinusrhythmus: Jeder Vorhoferregung (P) folgt eine Kammererregung (N).

dazwischen („intermittierend“) ein. Ähnliche Erregungsbilder können auch durch supraventrikulär gelegene Erregungszentren ausgelöst werden. In diesem Fall spricht man von supraventrikulären Extrasystolen (SVES). Diese können ebenso mit kompensatorischer Pause oder intermittierend auftreten.

Aktive ventrikuläre Heterotopien haben ein erhöhtes Risiko, Wiedereintrittsphänomene und in der Folge kreisende Erregungen auszulösen (siehe Kapitel 2.2.3). Sie sind daher kritischer zu beurteilen als Nomotopien oder passive Heterotopien.

## 2.2.2 Erregungsleitungsstörungen

Erregungsleitungsstörungen beschreiben ganz allgemein Behinderungen der normalen Erregungsförderung innerhalb des RLS oder des Myokards v.a. durch pathologische Änderungen der Leitungsgeschwindigkeit. Im Extremfall kann es zu einem vollständigen Block der Erregungsleitung kommen. Sind diese Störungen im Bereich des Vorhofs lokalisiert, besteht die Möglichkeit für einen sinuatrialen Block. Dies ist einer der beiden Gründe (neben Erregungsbildungsstörungen im Sinusknoten), bei denen es zu einer passiven Heterotopie des AV-Knotens kommen kann. Ist die Erregungsleitung im Bereich des AV-Knoten behindert, spricht man von einem AV-Block. Hierbei sind verschiedene Grade zu unterscheiden: Bei einem AV-Block 1. Grades erfolgt die Überleitung der Erregung verzögert. Als AV-Block 2. Grades wird eine vollständige Blockierung der Überleitung bezeichnet, die nur zeitweise auftritt. Im Falle eines totalen AV-Blocks (3. Grad) findet keine Überleitung der Erregung zwischen Vorhöfen und Kammern statt. Der sekundäre oder tertiäre Schrittmacher übernimmt dann die Erregung der Ventrikel.

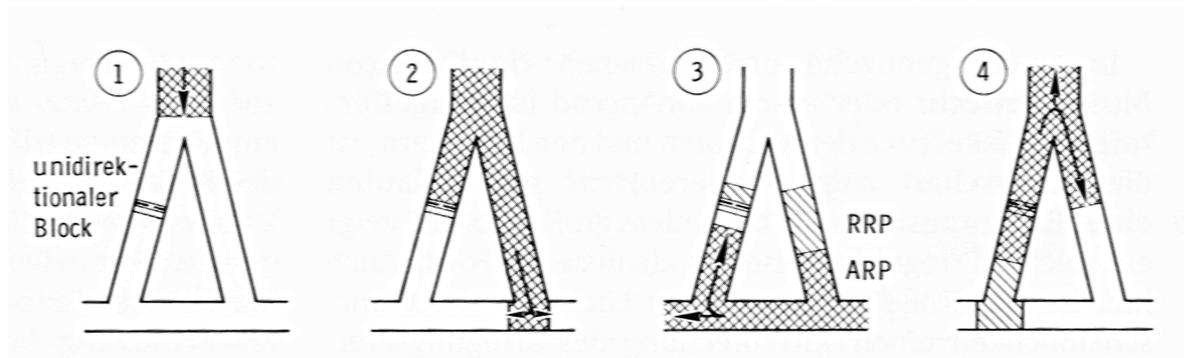
Entscheidend dafür ist die Lage des Blocks. AV-Knoten oder His-Bündel ermöglichen noch eine physiologische Erregung der Kammern. Die Frequenz der Ventrikelerrregung entspricht der Eigenfrequenz des jeweiligen Schrittmachers.

### 2.2.3 Reentry-Phänomene

Im physiologischen Fall ist sichergestellt, dass die Herzerregung von selbst terminiert, da die letzten Areale, die noch erregt werden, vollständig von refraktärem Gewebe umgeben sind. Dies hat seine Ursache in der absoluten Refraktärphase des Myokards, in der dieses unempfindlich für äußere Erregungen ist. Im Normalfall ist diese Refraktärphase mehr als  $2\frac{1}{2}$  mal so lang wie die Dauer der Erregungsausbreitung im gesamten Herzen. Ohne sie würde sich die Erregung auf Grund der in Kapitel 2.1.2 beschriebenen Mechanismen der Erregungsleitung immer wieder im Gewebe ausbreiten, die Erregung würde nie gestoppt. Genau zu diesem Phänomen kann es in pathologischen Fällen kommen: Die Erregung im Myokard erlischt nicht, sondern bleibt weiter bestehen und tritt wieder in erregbares Gewebe ein. Durch dieses Reentry-Phänomen kann sich eine kreisende Erregung auf dem Herzmuskel ausbilden, die bei längerem Bestehen lebensgefährlich wird. Ein Reentry-Phänomen kann durch Blockierungen oder Verzögerungen der Erregungsleitung im Herzmuskel infolge einer mangelnden Sauerstoffversorgung durch verringerte Durchblutung des Herzmuskels (Ischämie) oder durch Vernarbungen im Myokard entstehen. Eine weitere mögliche Ursache ist das Auftreten eines konkurrierenden Erregungszentrums, das durch die Umwandlung von Myokardgewebe in solches mit instabilem Ruhepotenzial entsteht, wie dies in Kapitel 2.2.1 bereits angesprochen wurde.

In beiden Fällen besteht das Risiko der Ausbildung einer kreisenden Erregung, deren Mechanismus exemplarisch in Abbildung 2.6 gezeigt wird. In diesem Beispiel existiert eine Blockade der Erregungsleitung, die allerdings nur in einer Richtung wirkt (unidirektionaler Block). Die eintreffende Erregungsfront (1) breitet sich daher nur über die rechte Faser aus (2), trifft nach Durchtritt durch den Block in der linken Faser (3) jedoch auf bereits wieder erregbares Gewebe und setzt eine kreisende Erregung in Gang (4). Hier handelt es sich um einen antegraden, also um einen nur in der physiologischen Ausbreitungsrichtung bestehenden Block. Dieser ist retrograd durchlässig für die Erregung, wenn auch mit verzögerter Leitfähigkeit. Besteht nun die Möglichkeit einer antegraden Leitung über eine alternative Bahn, kann es sein, dass die Erregung über die blockierte Bahn über die Blockadestelle zurückläuft und dort bereits wieder auf erregbares Gewebe trifft. Ist die „Kreisbahn“ so groß, dass bei der gegebenen Erregungsleitungsgeschwindigkeit die Umlaufzeit der Erregung größer als die Refraktärzeit ist, kommt es zum Kreisen der Erregung.

Ähnlich funktioniert der Mechanismus bei einer aktiven Heterotopie: Die neue Erregungsfront des zusätzlichen Schrittmacherzentrums braucht durch die unphysiologische Erregung der Herzmuskulatur so lange zur Erregung des gesamten Myokards, dass andere Bereiche bereits wieder erregbar sind und sich auf diese Weise eine kreisende Erregung ausbilden kann. Besonders gefährlich ist, wenn diese Erregung die sogenannte vulnerable Phase des Herzens trifft. Diese vulnerable Phase weisen auch herzgesunde Menschen auf und hat ihre Ursache darin, dass die Repolarisation unterschiedlich weit fortgeschritten ist. Trifft eine Extrasystole oder ein äußerer Stromstoß auf Bereiche, die die absolute Refraktärzeit bereits verlassen haben, kann sich eine Erregung einstellen,



**Abbildung 2.6:** Wiedereintrittsmechanismus mit unidirektionalem Block in der linken Faser (aus [GH99]). RRP steht für relative Refraktärphase, ARP bedeutet absolute Refraktärphase.

die später auf die momentan noch unerregbaren Bereiche übergeht und daraufhin ein Kreisen verursacht.

Eine kreisende Erregung kann sowohl die Vorhöfe als auch die Kammern betreffen. Nach der Frequenz geordnet, kann man laut [GH99] folgende Formen der kreisenden Erregung unterscheiden:

- ab 140 bpm: Vorhof- oder Kammertachykardie
- 200 - 350 bpm: Vorhofflattern
- 180 - 250 bpm: Kammerflattern

Die Frequenz der kreisenden Erregung ist dabei wesentlich von der Geschwindigkeit der Erregungfortpflanzung und der Größe des betroffenen Areals abhängig. Da die Vorhöfe deutlich kleiner sind als die Kammern, werden dort weitaus höhere Frequenzen erreicht. Von Flimmern ist die Rede, wenn die Erregung immer wieder auf andere Muskelbereiche trifft bzw. sich eine Vielzahl kreisender Erregungen in verschiedenen Muskelarealen ausbilden. Dadurch ist keine koordinierte Kontraktion mehr möglich und die Pumpleistung faktisch aufgehoben. Sind die Kammern davon betroffen, tritt ein Kreislaufstillstand ein, der nach ca. fünf Minuten zu irreversiblen Hirnschädigungen und nach 10–12 Minuten zum Tod führt.

Kreisende Erregungen können durch Depolarisation aller nichtrefraktären Bereiche des Myokards unterbrochen werden. Dies lässt sich mit Hilfe eines Defibrillators bewerkstelligen, der [BU02] zufolge über zwei Elektroden einen Impuls mit einer Stromstärke von mindestens zwei Ampere über einen Zeitraum von 10–20ms durch das Herz fließen lassen sollte.

## 2.3 Regelungsmechanismen der Herzaktivität

Es gibt mehrere Regelungsmöglichkeiten, mit denen die Herzaktivität und in der Folge das Herzminutenvolumen und der Blutdruck beeinflusst und so an den wechselnden

Bedarf des Organismus, z.B. bei körperlicher Belastung, angepasst werden können. Diese Regelung geschieht durch das vegetative oder autonome Nervensystem (ANS), das über seine afferenten (sensorischen) Fasern Informationen wie Blutdruck, Temperatur etc. aus dem Körper aufnimmt. Über die efferenten (aktorischen) Fasern seiner beiden Antagonisten, dem Sympathikus und dem Parasympathikus, wirkt das vegetative Nervensystem schließlich auf das Herz. Grundsätzlich kann man vier verschiedene Parameter der Herztätigkeit unterscheiden, die durch äußere Einflüsse manipuliert werden können [SD91]:

1. Herzfrequenz durch Änderung der Frequenz der Impulsbildung im Schrittmacherzentrum (Chronotropie)
2. Veränderung der Leitungsgeschwindigkeiten, v.a. im AV-Knoten (Dromotropie)
3. Kontraktilität der Herzmuskulatur (Inotropie)
4. Erregbarkeit durch Veränderung der Reizschwelle (Bathmotropie)

Für die Chronotropie gibt es drei wesentliche Hebel: Erstens das Niveau des Schwellenpotenzials, zweitens die Steigung der spontanen Depolarisationskurve und drittens das Niveau des maximalen diastolischen Potenzials (MDP). Negativ-chronotrop, d.h. die Herzfrequenz senkend, wirken sich eine Erhöhung des Schwellenpotenzials, eine Erniedrigung des Depolarisationsgradienten und ein betragsmäßig größeres MDP aus. Die Herzfrequenz wird dagegen erhöht, wenn das Schwellenpotenzial absinkt, die Depolarisationskurve steiler wird und das MDP kleinere Betragswerte annimmt. Diese Modifikationen greifen beim Sinusknoten, wobei der Sympathikus positiv-chronotrop und der Parasympathikus negativ-chronotrop wirkt. Neben dem vegetativen Nervensystem können jedoch auch andere Faktoren v.a. auf den Depolarisationsgradienten einwirken: Eine Erniedrigung der extrazellulären Kaliumionen (Hypokaliämie) wirkt genauso wie Fieber positiv-chronotrop, eine starke Hyperkaliämie oder eine erniedrigte Körpertemperatur dagegen negativ-chronotrop. Die Wirkung des vegetativen Nervensystems nimmt zu den untergeordneten Schrittmacherzentren hin stark ab, allerdings ist auf der Ebene der tertiären Zentren eine stark positiv-bathmotrope Wirkung des Sympathikus erkennbar. Diese dient dazu, bei Ausfall der übergeordneten Erregungszentren eine genügend hohe Herzfrequenz realisieren zu können.

Dromotrope Wirkungen lassen sich v.a. im Bereich des AV-Knotens nachweisen. Der Sympathikus wirkt positiv-dromotrop, d.h. die Leitungsgeschwindigkeit im Gewebe wird erhöht, der Parasympathikus negativ-dromotrop. Dabei werden das Niveau des MDP und die Anstiegssteilheit des Aktionpotenzials beeinflusst [SD91]. Wie bei der Chronotropie sind auch hier die Änderungen der Eigenschaften der Ionenkanäle für  $\text{Ca}^{2+}$  und  $\text{K}^+$  hauptverantwortlich.

Die Inotropie wird im physiologischen Fall wesentlich über das vegetative Nervensystem geregelt, wobei der Sympathikus durch einen adrenerg über die  $\beta_1$ -Rezeptoren verursachten  $\text{Ca}^{2+}$ -Einstrom eine positiv-inotrope Wirkung direkt auf das Arbeitsmyokard entfalten kann. Auch bei der Inotropie können Änderungen der Körpertemperatur und der Kaliumionenkonzentration eine Rolle spielen.

### 2.3.1 Herzratenvariabilität

Unter der Herzratenvariabilität versteht man die Schwankungen der Herzfrequenz über einen Messzeitraum bei der Analyse von Herzschlag zu Herzschlag. Die HRV ist ein Parameter der autonomen Funktion des Herzens und wird durch zahlreiche Einflussgrößen wie Alter, Geschlecht, Atmung und Trainingszustand bestimmt [Löl99]. Die HRV stellt eine Messgröße der neurovegetativen Aktivität und der autonomen Funktion des Herzens dar. Die einzelnen Herzschläge erfolgen nicht in regelmäßigen Abständen, sondern sind durch - bereits in Ruhe vorhandene - Unregelmäßigkeiten gekennzeichnet, welche aufgrund der wechselseitigen Beeinflussung der an der Herzfrequenz beteiligten Vorgänge entstehen. Dies verleiht der Herzfrequenz eine Zeitstruktur, die als Herzfrequenzvariabilität messbar ist.

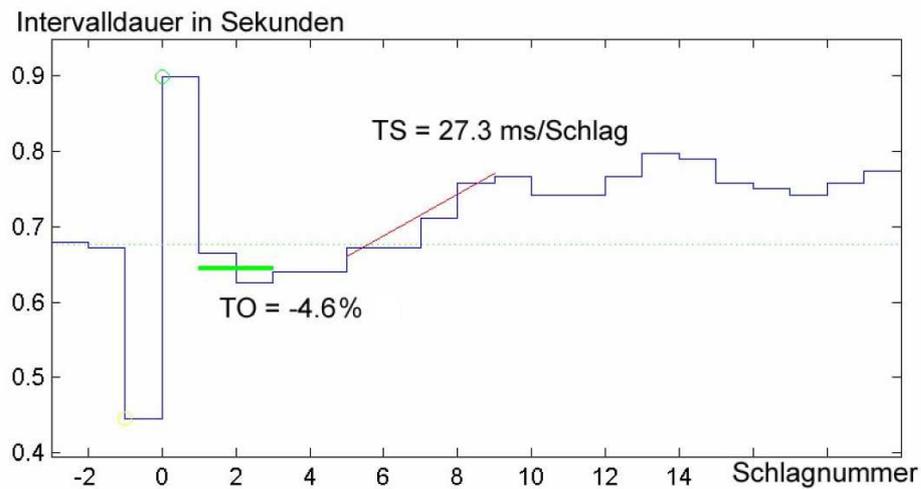
Die klinische Relevanz der Herzratenvariabilität wurde erstmals 1965 von Hon und Lee [HL65] in Zusammenhang mit der Geburtshilfe erkannt. Den Zusammenhang zwischen einem erhöhten Risiko des plötzlichen Herztodes nach überlebtem Herzinfarkt und einer eingeschränkten Herzratenvariabilität wurde erstmals von Wolf et al. 1978 gezeigt [WVHS78]. In den späten 1980er Jahren wurde die klinische Bedeutung der HRV deutlich, als sich bestätigte, dass eine verminderte HRV einen stabilen Parameter für das Risiko eines plötzlichen Herztods darstellt [Löl99].

### 2.3.2 Herzraturbulenz

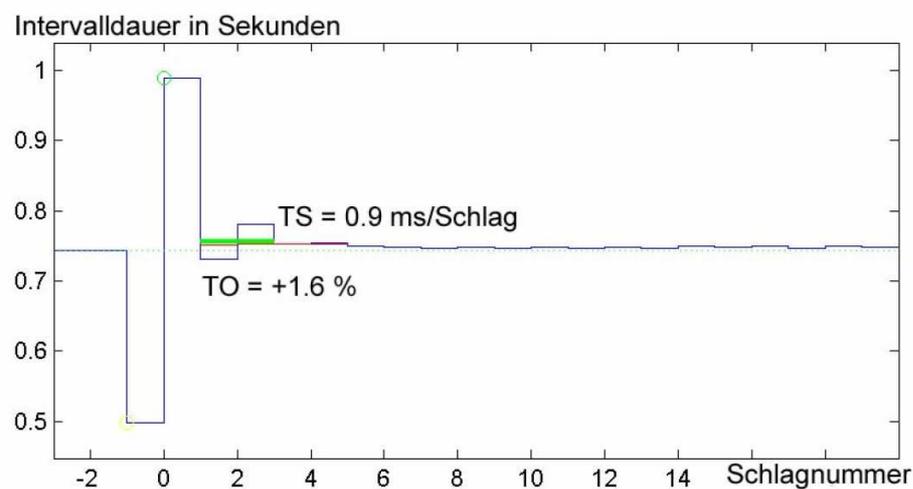
Die Herzraturbulenz (HRT) ist die physiologische Reaktion auf die Störung des normalen Sinusrhythmus durch eine kompensierte ventrikuläre Extrasystole (VES) (siehe Abschnitt 2.2.1). Nach der kompensatorischen Pause bestimmt wieder der Sinusknoten die Herzrate, wobei sich eine Phase des „Einregelns“ anschließt, die aus einer kurzen initialen Erhöhung und einer anschließenden Erniedrigung der Herzrate besteht. Ihre Ausprägung lässt Rückschlüsse auf die sympathiko-vagale Regelgüte zu. Für die HRT werden ausschließlich isolierte kompensierte VES betrachtet. Ihr müssen mindestens zwei Normalschläge vorangehen, danach müssen mindestens zwanzig Normalschläge folgen.

Vereinfacht lässt sich der Mechanismus der HRT folgendermaßen darstellen: Nach dem verfrühten Herzschlag der VES ist der arterielle Blutdruck aufgrund mehrerer Faktoren sehr niedrig. Der Ventrikel ist durch die asynchrone Kontraktion nicht vollständig gefüllt und das Auswurfvolumen somit erniedrigt. Der Ruhezustand verschiedener Ionenkanäle ist noch nicht wieder hergestellt, was zu einem verkürzten Aktionspotenzial führt. Durch den Franck-Starling-Mechanismus, der eine Anpassung der Herzkontraktion an den Füllungsgrad der Kammern bewirkt, ist die Kontraktilität reduziert. Der Blutdruck nach der kompensatorischen Pause ist dagegen sehr hoch verglichen mit einer normalen Sinuserregung, was wiederum an einem größeren Auswurfvolumen und einem längerem Aktionspotenzial liegt. Der veränderte arterielle Blutdruck löst über Barorezeptoren die kurze Beschleunigung und die darauf folgende Verlangsamung der Herzschläge aus [SMB<sup>+</sup>99].

Schmidt et al. fassten in [SMB<sup>+</sup>99] die HRT in zwei numerische Parameter - Turbulence Onset (TO) und Turbulence Slope (TS) - und prüften diese an den Populationen zweier großer Postinfarktstudien, dem Multicenter Post-Infarction Program



**Abbildung 2.7:** Tachogramm mit berechneten Werten für Turbulence Onset (TO) und Turbulence Slope (TS) im physiologischen Fall. Das Auftreten der VES ist durch den kleinen Kreis zu Beginn der kompensatorischen Pause gekennzeichnet. Der Referenzwert für den TO wird aus den beiden der VES vorangehenden Normalintervallen bestimmt.



**Abbildung 2.8:** Turbulence Onset und Turbulence Slope im pathologischen Fall. Im Vergleich zu Abbildung 2.7 ist die geringere Regelaktivität nach der VES deutlich sichtbar.

(MPIP) [Mul82] und dem European Myocardial Infarction Amiodarone Trial (EMI-AT) [JCF97]. In beiden Studien erwies sich die HRT als stärkster multivariater Parameter zur Risikoeinschätzung der Mortalität nach akutem Myokardinfarkt. Der TO entspricht der prozentualen Änderung der Herzrate unmittelbar nach der VES im Vergleich zur Herzrate unmittelbar vor der VES. Beide Herzraten werden aus der Mittelung zweier aufeinanderfolgender Intervalle von Normalschlägen (NN-Intervalle) bestimmt. Positive Werte von TO bedeuten eine Verlangsamung, negative Werte eine Beschleunigung des Sinusrhythmus im Verhältnis zum Grundrhythmus. Da der TO ein Relativwert ist, besitzt er keine Einheit.

Der TS entspricht der Steigung der steilsten Regressionsgeraden für eine Sequenz von fünf aufeinanderfolgenden Normalintervallen innerhalb von zwanzig Schlägen nach der VES. Die Regressionsgerade ist eine lineare Annäherung an die tatsächlichen Messwerte nach der Methode der kleinsten Fehlerquadrate. TS ist ein Absolutwert und wird in ms/Schlag ausgedrückt. Für die HRT gelten als Normwert  $TO < 0$  und  $TS > 2,5$  ms/Schlag.

Die Abbildungen 2.7 und 2.8 zeigen exemplarisch, wie sich TO und TS zwischen physiologischem und pathologischem Fall verändern. Im ersten Fall sind Anstieg und Senkung der Herzfrequenz sehr gut zu erkennen, was für eine intakte Regulierung durch das vegetative Nervensystem spricht. Im zweiten Fall ist diese praktisch überhaupt nicht zu erkennen, was auf einen eingeschränkten sympathiko-vagalen Tonus hindeutet.



# 3 Das Elektrokardiogramm und seine Ableitungssysteme

In diesem Kapitel wird die Herleitung des Dipolmodells und des Herzvektors beschrieben und daraus folgend das Prinzip der EKG-Ableitung dargestellt. Danach werden verschiedene, in der Praxis gebräuchliche EKG-Ableitungskonfigurationen vorgestellt.

## 3.1 Dipolnäherung und Herzvektor

Es existiert eine Vielzahl von Ansätzen für die Modellierung der elektrischen Herzaktivität. Eine Übersicht bietet [MP05]. Die folgende Darstellung für die Gewinnung des Herzvektors ist verkürzt daraus entnommen. In ihr wird der menschliche Körper als unendlich ausgedehnter, homogener und isotroper Leiter mit der Leitfähigkeit  $\sigma$  angenommen. Die Depolarisation der Zellmembran einer Herzmuskelzelle prägt einen raum- und zeitabhängigen Strom mit der Dichte  $\vec{J}^i(x, y, z, t)$ , der ein Potenzial im umgebenden leitfähigen Volumen erzeugt. Die Gesamtheit der gleichzeitig depolarisierenden Myokardzellen bildet eine dreidimensionale Fläche, die sog. isochrone Aktivierungsfläche. Für jede ihrer Zellen  $j$  kann eine Dipolbeziehung formuliert werden, die wesentlich durch die unterschiedlichen Potenziale innerhalb und außerhalb der Zellmembran bestimmt wird. Nach [MP05] gilt für den Dipol der Zelle  $j$ :

$$d\vec{p}_j = \int (\sigma_o \Phi_o - \sigma_i \Phi_i) d\vec{S}_j \quad (3.1)$$

mit  $\vec{p}_j$  als Dipol,  $\sigma_o$  und  $\sigma_i$  den Leitfähigkeiten außerhalb bzw. innerhalb der Membran,  $\Phi_o$  und  $\Phi_i$  den Potentialen gerade außerhalb bzw. innerhalb der Membran und  $d\vec{S}_j$  der Oberfläche des Volumenelements  $dv_j$  der Zelle  $j$ . Auf Grund der hohen Anzahl von Dipolquellen - ca. 5% der Herzzellen, also ca.  $2,5 \cdot 10^9$  Zellen sind gleichzeitig aktiv - kann eine Funktion für die eingeprägte Stromdichte  $\vec{J}$  definiert werden. Dazu werden  $N$  Zellen zu einem größeren Volumenelement so zusammengefasst, dass sich für die Stromdichte ein hinreichend glatter Verlauf ergibt. Die Stromdichte des Volumenelements kann dann mit folgender Beziehung angegeben werden:

$$\vec{J}^i = \frac{\sum_{j=1}^N d\vec{p}_j}{\sum_{j=1}^N dv_j} \quad (3.2)$$

Dieser durch die zellulären Ionenverschiebungen eingeprägte Strom erzeugt ein Feld, das durch die Integration der einzelne Dipole über das gesamte Volumen berechnet

werden kann:

$$\Phi_o = \frac{1}{4\pi\sigma_o} \int \nabla \left( \frac{1}{r} \right) \vec{J}^i dv \quad (3.3)$$

Dabei ist  $r$  der (hinreichend große) Abstand des Ableitorts vom betrachteten Volumen.

Für den  $\nabla$ -Operator gilt folgende Beziehung:

$$\nabla \cdot \left( \frac{\vec{J}^i}{r} \right) = \nabla \left( \frac{1}{r} \right) \cdot \vec{J}^i + \frac{1}{r} \nabla \cdot \vec{J}^i \quad (3.4)$$

Setzt man 3.4 in 3.3 ein, so erhält man:

$$\Phi_o = \frac{1}{4\pi\sigma_o} \left( \int \nabla \left( \frac{\vec{J}^i}{r} \right) dv - \int \frac{\nabla \cdot \vec{J}^i}{r} dv \right) \quad (3.5)$$

Auf das erste Integral von 3.5 kann der Gaußsche Integralsatz angewendet werden:

$$\int \nabla \left( \frac{\vec{J}^i}{r} \right) dv = \int \left( \frac{\vec{J}^i}{r} \right) dS_o \quad (3.6)$$

$S_o$  ist dabei eine geschlossene Oberfläche, die alle Quellen komplett einschließt. Damit gilt direkt  $\vec{J}^i = 0$  auf  $S_o$  und damit auch

$$\int \left( \frac{\vec{J}^i}{r} \right) dS_o = 0 \quad (3.7)$$

Für Gleichung 3.5 folgt dann:

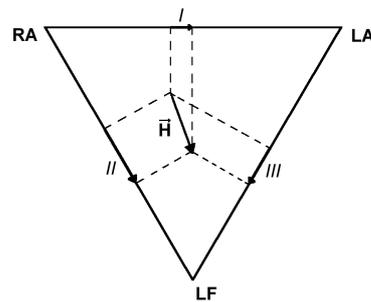
$$\Phi_o = -\frac{1}{4\pi\sigma_o} \int \frac{1}{r} \nabla \cdot \vec{J}^i dv \quad (3.8)$$

Durch die Integration über die einschließende Oberfläche (beispielsweise die Herzoberfläche) erhält man aus den Einzelvektoren  $\vec{J}^i$  einen Gesamtvektor  $\vec{H}$ , den sog. Herzvektor. Dessen Existenz wurde bereits von Einthoven postuliert, ohne dass er seine Entstehung als räumliche Summation vieler Einzelquellen angesehen hätte. Eine zwar unzulässige, aber als Näherung erstaunlich gut funktionierende Annahme ist Einthovens Postulierung dieses Herzvektors als ortsfest und in einer Ebene in Abhängigkeit von der Zeit betrags- und richtungsmäßig variierend (siehe dazu Kapitel 3.2). Eine ausreichend gute makroskopische Näherung ist die Auffassung des Herzvektors als ortsfester, aber sonst frei im Raum kreisender zeitabhängiger Summenvektor. Dieses Modell hat seinen Niederschlag in der Vektorkardiographie gefunden. Das vom Herzdipol an einem bestimmten Punkt der Körperoberfläche erzeugte Potenzial ist als Skalarprodukt eines mit diesem Punkt assoziierten Ableitungsvektor (engl. *lead vector*) mit dem Herzvektor anzusehen. Dieser lead vector ist durch die verwendete Elektrodenkonfiguration bestimmt, wie im folgenden Kapitel zu sehen sein wird.

## 3.2 Gängige Ableitungssysteme

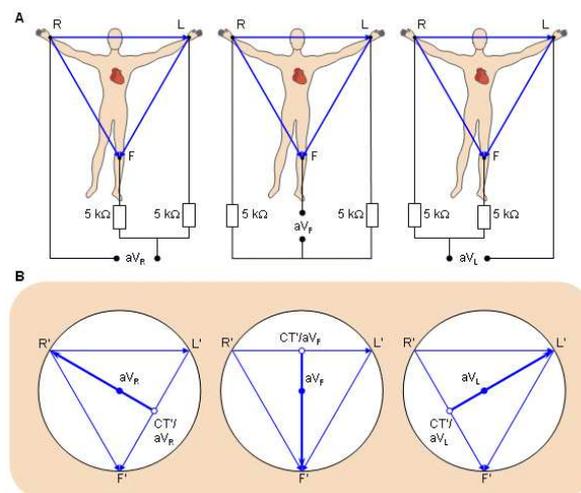
Die historisch ältesten Ableitungen sind die Extremitätenableitungen nach Einthoven. Dabei bilden die drei Ableitungsorte rechter Arm, linker Arm und linker Fuß ( $RA$ ,  $LA$ ,  $LF$ ) idealisiert ein gleichseitiges Dreieck, das sog. Einthoven-Dreieck. Einthoven postuliert die elektrische Herzaktivität als einen im Mittelpunkt dieses Dreiecks verankerten Vektor, der zeitabhängig in der durch die Ableitorte gebildeten Ebene kreist. Die Potenzialunterschiede zwischen den einzelnen Elektroden bilden die einzelnen Ableitungen  $I$ ,  $II$  und  $III$ , die nach dem Kirchhoffschen Gesetz in folgender Beziehung zueinander stehen:

$$II = I + III \quad (3.9)$$



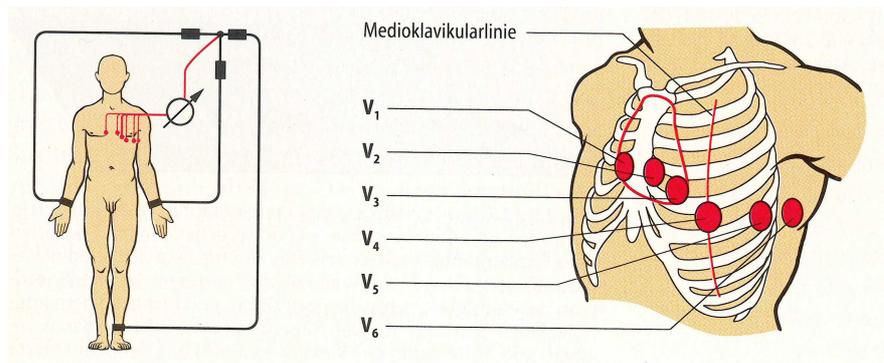
**Abbildung 3.1:** Einthoven-Dreieck. In der Mitte der Herzvektor  $\vec{H}$ , die Seiten des Dreiecks entsprechen den Ableitungsvektoren  $I$ ,  $II$  und  $III$ . Die Länge der eingezeichneten Vektoren auf den lead vectors ist die Aussteuerung der einzelnen Ableitungen für  $\vec{H}$ .

Als Ableitungslinien der einzelnen Elektroden fungieren demzufolge die Seiten des Einthoven-Dreiecks, so dass die einzelnen Ableitungen die Projektion des zweidimensionalen Herzvektors auf diese Seiten darstellen (siehe Abbildung 3.1).



**Abbildung 3.2:** Ableitungsvektoren der Goldberger-Ableitungen ( $aVR$ ,  $aVL$ ,  $aVF$ ) in Relation zum Einthoven-Dreieck [MP05].

Eine weitere Ableitungskonfiguration, die sich dasselbe Herzvektormodell zu Nutze macht, wurde von Goldberger vorgestellt. Dabei werden je zwei der drei Extremitätenelektroden zu einem virtuellen Bezugspunkt zusammengeschaltet, der dann in der Mitte der Ableitungslinie zwischen diesen Elektroden liegt. Die lead vectors ergeben sich als Richtungsvektoren der jeweils freien Elektrode von diesem Punkt aus. Die Bezeichnungen der einzelnen Ableitungen lauten  $aVR$ ,  $aVL$  und  $aVF$ , wobei mit den Endbuchstaben die freien Elektroden rechter Arm, linker Arm und linker Fuß bezeichnet sind. Eine geometrische Repräsentation dieser lead vectors zeigt Abbildung 3.2.



**Abbildung 3.3:** Wilson-Brustwandableitungen. Abbildung entnommen aus [SD91]

Bei den Wilson-Ableitungen wird ein weiterer virtueller Sternpunkt (*central terminal*) eingeführt, indem alle drei Extremitätenelektroden über gleichgroße Widerstände zusammengeschaltet werden. Damit ist dieser Sternpunkt im Mittelpunkt des oben genannten Einthoven-Dreiecks lokalisiert. Als neue Ableitungen werden die Potenzialdifferenz von Brustwandelektroden zu dieser Referenz betrachtet. Durchgesetzt haben sich insgesamt sechs Positionen auf der linken Brustseite, die mit  $V_1$  bis  $V_6$  bezeichnet werden (Abbildung 3.3). Besonders die Elektrodenpositionen  $V_5$  und  $V_6$  sind für Beobachtungen von Vorgängen auf der Herzurückseite wichtig.

Diese drei bisher vorgestellten Ableitungskonfigurationen haben sich als klinischer Standard etabliert und bilden zusammen das sog. „12-Kanal-Standard-EKG“. Ihre Berechnung aus den einzelnen Elektrodensignalen  $RA$ ,  $LA$  und  $LF$  ist in Tabelle 3.1 aufgeführt.

In der Vergangenheit hat es auch immer wieder Versuche gegeben, den Herzvektor durch drei linear unabhängige Richtungskomponenten darzustellen. Dies hat zu dem von der Elektrokardiografie unterschiedenen Zweig der Vektorkardiografie geführt, da hier der dreidimensionale Herzvektor betrachtet wird. Dabei wurde stets versucht, so genannte „korrigierte“ Elektrodensysteme zu entwerfen, bei denen die Einzelvektoren ein orthogonales Achsensystem bilden, die parallel zu den Hauptachsen des menschlichen Körpers liegen.

Dazu müssen die einzelnen Elektrodensignale anhand einer Koeffizientenmatrix gewichtet werden, deren Elemente Gegenstand umfassender empirischer Untersuchungen waren, da sie von der Körpergeometrie und den Gewebeeigenschaften abhängen und daher nur statistisch ermittelt werden können. Die Anzahl der Spalten dieser  $(3, n)$ -Matrizen hängt von der Anzahl der verwendeten Elektroden ab, wobei der Approxi-

**Tabelle 3.1:** Berechnung der einzelnen Ableitungen aus den Elektrodensignalen.  $C_1$  bis  $C_6$  entsprechen dabei den Elektroden  $V_1$  bis  $V_6$  aus Abbildung 3.3.

Name	Bezeichnung	Berechnung aus Elektrodensignalen
Einthoven- Ableitungen	$I$	$I = LA - RA$
	$II$	$II = LF - RA$
	$III$	$III = LF - LA$
Goldberger- Ableitungen	$aVR$	$aVR = RA - \frac{LA+LF}{2}$
	$aVL$	$aVL = LA - \frac{RA+LF}{2}$
	$aVF$	$aVF = LF - \frac{LA+RA}{2}$
Wilson- Ableitungen	$V_1$	$V_1 = C_1 - \frac{LA+RA+LF}{3}$
	$V_2$	$V_2 = C_2 - \frac{LA+RA+LF}{3}$
	$V_3$	$V_3 = C_3 - \frac{LA+RA+LF}{3}$
	$V_4$	$V_4 = C_4 - \frac{LA+RA+LF}{3}$
	$V_5$	$V_5 = C_5 - \frac{LA+RA+LF}{3}$
	$V_6$	$V_6 = C_6 - \frac{LA+RA+LF}{3}$

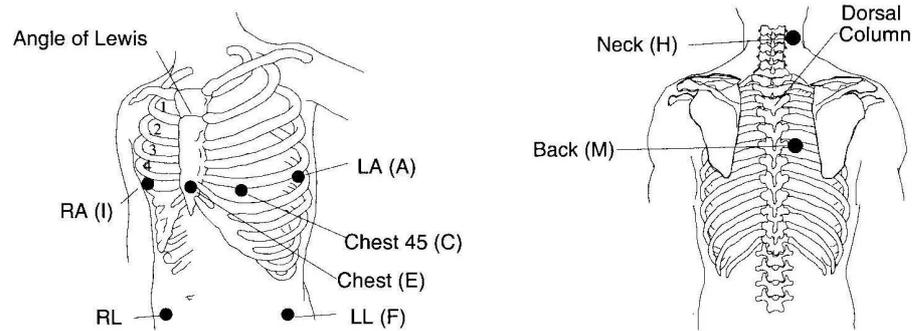
mationsgrad mit zunehmender Elektrodenanzahl tendenziell steigt, die Praktikabilität jedoch naturgemäß sinkt.

Die im Frank-System verwendeten Ableitungsorte zeigt Abbildung 3.4, aus Tabelle 3.2 können die Elemente der verwendeten Koeffizientenmatrix zur Berechnung der Einzelsignale  $V_x$ ,  $V_y$  und  $V_z$  entnommen werden. Im Anschluss an die Arbeit von Frank wurden Untersuchungen durchgeführt, wie eine Abbildung der drei Richtungskomponenten auf die im 12-Kanal-Standard-EKG verwendeten Ableitungslinien stattfinden kann. So ist eine Umrechnung von vektorkardiografisch gewonnenen Potenzialdifferenzen in eine für den Arzt gewohnte Darstellungsweise möglich. Eine abschließend in [DMO80] gewonnene Koeffizientenmatrix zeigt Tabelle 3.3.

**Tabelle 3.2:** Berechnung der Frank-Ableitungen aus den einzelnen Elektrodensignalen.

Name	Bez.	Berechnung aus Elektrodensignalen
Frank- Ableitungen	$V_x$	$V_x = 0,610 \cdot A + 0,171 \cdot C - 0,781 \cdot I$
	$V_y$	$V_y = 0,655 \cdot F + 0,345 \cdot M - 1,000 \cdot H$
	$V_z$	$V_z = 0,133 \cdot A + 0,736 \cdot M - 0,246 \cdot I - 0,374 \cdot E - 0,231 \cdot C$

In den 1980er Jahren gab es weitere Untersuchungen zu einem alternativen vektorkardiografischen Verfahren. Ziel dieser Entwicklung von Dower et al. war es, bei den Frank-Ableitungen v.a. die für den Patienten unbequemen Elektroden auf dem Rücken



**Abbildung 3.4:** Ableitungssystem nach Frank. Die einzelnen Elektrodensignale werden in Referenz zum Signal der Elektrode  $RL$  gemessen. Aus [Hew98a].

**Tabelle 3.3:** Koeffizientenmatrix für die Berechnung des 12-Kanal-EKGs aus den Frank-Ableitungen  $V_x$ ,  $V_y$  und  $V_z$ .

	$I$	$II$	$III$	$aVR$	$aVL$	$aVF$
$V_x$	0,632	0,235	-0,397	-0,434	0,515	-0,081
$V_y$	-0,235	1,066	1,301	-0,415	-0,768	1,184
$V_z$	-0,059	-0,132	-0,191	0,037	0,125	-0,162
	$V_1$	$V_2$	$V_3$	$V_4$	$V_5$	$V_6$
$V_x$	-0,515	0,044	0,882	1,213	1,125	0,831
$V_y$	0,157	0,164	0,098	0,127	0,127	0,076
$V_z$	-0,917	-1,387	-1,277	-0,601	-0,086	0,230

einzusparen und nur noch Elektroden auf der Vorderseite des Brustkorbs zu verwenden. Ergebnis waren die so genannten EASI-Leads [DYN<sup>+</sup>88], die in den USA patentrechtlich geschützt wurden [Dow87], in Europa aber frei verwendet werden dürfen.

Die Platzierung der Ableitelektroden zeigt Abbildung 3.5. Auch hier existiert eine Koeffizientenmatrix zur Umrechnung der drei Ableitungskanäle in ein 12-Kanal-EKG, so dass Medizinern mit dieser vereinfachten Ableitung ein Standard-EKG präsentiert werden kann. Durch die ausschließliche Verwendung von Brustelektroden eignet sich dieses Ableitungsverfahren vor allem für den Einsatz in Langzeitmonitoringsystemen (siehe Kapitel 4.3). Die drei Kanäle der EASI-Leads werden über folgende Beziehung berechnet:

$$\begin{aligned}
 EI &= E - I \\
 AI &= A - I \\
 SI &= S - I
 \end{aligned}
 \tag{3.10}$$

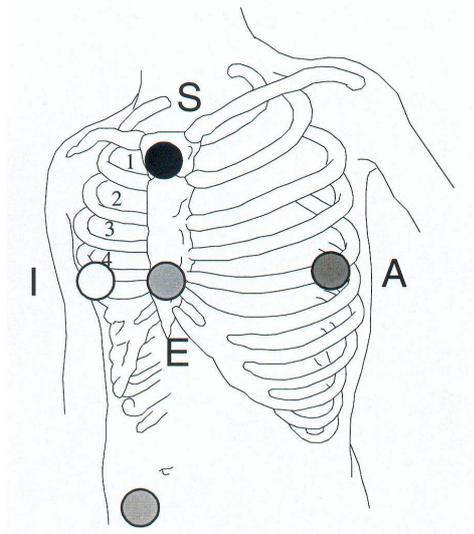


Abbildung 3.5: EASI-Leads nach Dower. Aus [Hew98b].

### 3.3 Physiologisches EKG-Signal

Ein Beispiel für ein physiologisches EKG-Signal ist in Abbildung 3.6 dargestellt. Wie in Kapitel 3 ausgeführt entstehen die positiven und negativen Ausschläge durch die „Abbildung“ des Herzvektors auf die jeweilige elektrische Ableitungslinie und können daher in Form und Polarität variieren. Die charakteristischen Punkte bzw. Wellen P, Q, R, S und T sind jedoch immer vorhanden. Typische Zeiten und Amplituden der Einzelkomplexe sind Abbildung 3.6 und Tabelle 3.4 zu entnehmen. Die folgenden Beschreibungen, insbesondere die Polarität der Einzelkomplexe, beziehen sich auf dieses Standard-EKG. In realen Elektrokardiogrammen kann es zu deutlich anderen Signalformen kommen.

Die P-Welle entsteht durch die Erregungsausbreitung in den beiden Vorhöfen. Diese ist in den meisten Fällen unipolar, in seltenen Fällen bipolar. Der Abstand zwischen Erregungsbeginn in den Vorhöfen und den Ventrikeln wird durch das PQ-Intervall beschrieben. Bei einem erwachsenen, gesunden Menschen liegt seine Dauer zwischen 120 ms und 200 ms bei einer Frequenz von 60 -70 bpm. Ändert sich die Frequenz, so ändert sich auch die PQ-Strecke. Das Ende dieser Strecke wird auch zur Bestimmung der Nulllinie genutzt und dient damit als Referenz für den Beginn der ST-Strecke [GH99].

Die Erregungsausbreitung in beiden Ventrikeln beginnt mit dem O-Punkt und endet mit dem J-Punkt. Dazwischen befindet sich der QRS-Komplex. Die erste negative Zacke wird als Q, die darauf folgende positive Zacke als R bezeichnet. Den Abschluss dieser Gruppe bildet eine weitere negative Zacke, die sogenannte S-Zacke. Die Gesamtdauer des QRS-Komplexes soll nicht länger 100 ms sein. Am Ende dieses Komplexes sind beide Ventrikel vollständig erregt. Zur Bestimmung der Amplitude wird der Abstand zwischen der R-Zacke und der Q- bzw. S-Zacke gemessen. Die Amplitude soll nicht kleiner als 0,6 mV sein und wird selten größer als 1,6 mV [GH99].

Im Anschluss folgt die ST-Strecke, die mit dem J-Punkt beginnt und in der T-Welle endet. Das Ende ist nicht genau festzulegen, da diese Strecke leicht ansteigt oder abfällt, und daher in den Beginn der T-Welle übergeht. Um Veränderungen in der ST-Strecke

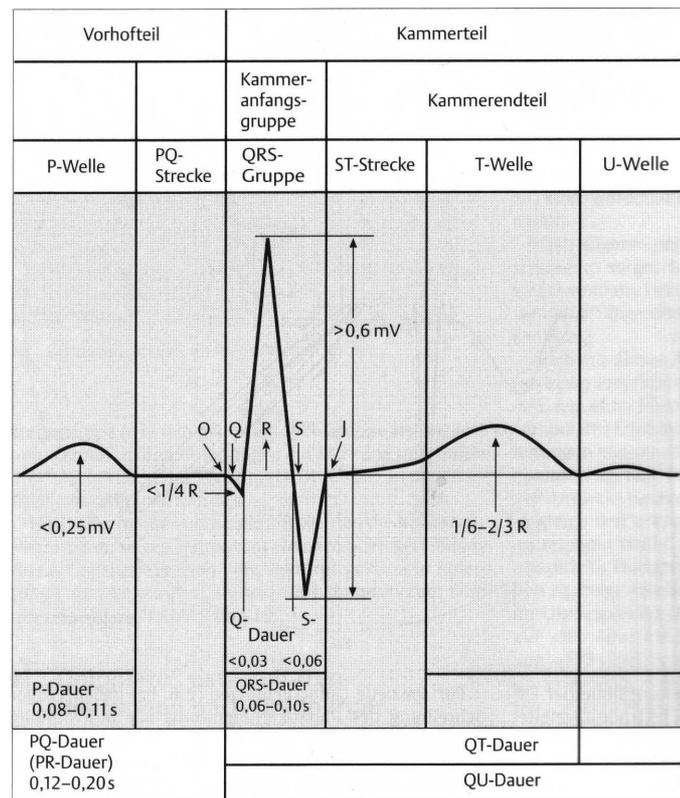


Abbildung 3.6: Darstellung eines EKGs [GH99]

zu verfolgen, wird die Abweichung von der Nulllinie 80 ms nach dem J-Punkt betrachtet (J80). Bei höheren Herzfrequenzen verkürzt sich dieser Abstand auf 60 ms (J60). In der Dauer dieser Strecke sind die Ventrikel depolarisiert und die Repolarisation, die in der T-Welle abgebildet wird, hat noch nicht begonnen. Die T-Welle hat die gleiche Ausschlagsrichtung wie die R-Zacke, da die epikardialen (äußeren) Schichten des Myokards schneller repolarisieren als die endokardialen (inneren). Dadurch zeigt der Herzvektor in die gleiche Richtung wie bei der Depolarisation. Die Höhe der T-Welle beträgt zwischen  $1/6$  und  $2/3$  der Ausschlagshöhe der R-Zacke [GH99]. Die Dauer der Ventrikelerrregung kann an der QT-Dauer abgelesen werden, die von der Herzfrequenz abhängig ist und bei einer Frequenz von 70 bpm zwischen 320-390 ms liegt [ST95]. Um die QT-Dauer verschiedener Frequenzen miteinander vergleichen zu können, wird eine frequenzkorrigierte QT-Dauer  $QT_c$  verwendet, die mit der Bazett-Gleichung berechnet werden kann (Gleichung 3.11).

$$QT_c = \frac{QT}{\sqrt{RR - \text{Intervall}}} \quad (3.11)$$

Im Anschluss an die T-Welle erscheint gelegentlich noch eine weitere Welle, die sogenannte U-Welle. Man geht davon aus, dass sie durch die Erregungsrückbildung in den Endverzweigungen der Purkinje-Fasern entsteht [ST95].

Mit der anschließenden P-Welle beginnt der Herzzyklus wieder von Neuem. Über

den Abstand zwischen zwei gleichen Zacken in aufeinanderfolgenden Herzzyklen - normalerweise werden dazu die R-Zacken als prominenteste Bestandteile eines Herzzyklus benutzt - kann die Herzfrequenz (HF) nach Gleichung 3.12 berechnet werden.

$$HF = \frac{60 \frac{s}{min}}{RR - Intervall (in s)} \quad (3.12)$$

Mit der Dauer eines normalen Zyklus von ca. 800 ms ergibt sich eine Frequenz von 75 bpm.

**Tabelle 3.4:** Parameter des EKG-Signals

	Amplitude	Dauer in [ms]
P-Welle	0,15mV	80 - 110
PQ-Intervall		120 - 200
QRS-Komplex	0,6 - 1,6mV	100
T-Welle	1/6 R - 2/3 R	

## 3.4 Pathologische Veränderungen im EKG-Signal

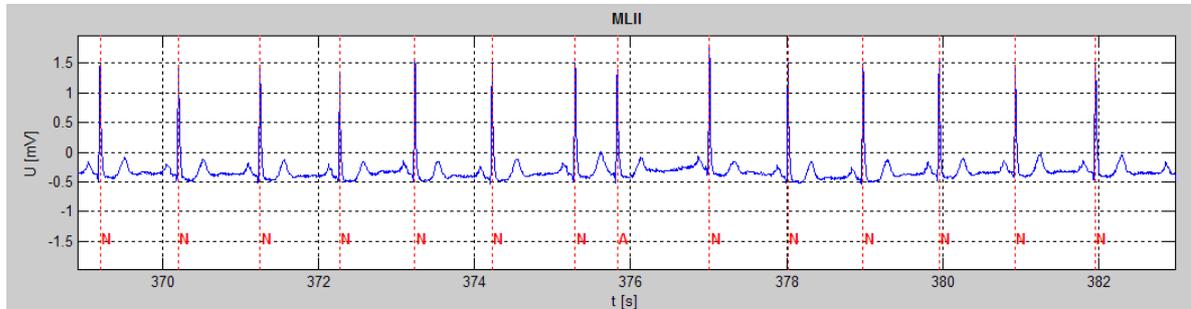
Mit Hilfe des EKGs lassen sich die im Kapitel 2.2 angesprochenen Pathologien diagnostizieren. Auf Grund der Vielzahl der möglichen Pathologien und der Formen ihrer Ausprägung bilden die im Folgenden vorgestellten EKG-Beispiele nur einen sehr schmalen, exemplarischen Ausschnitt. Wegen ihrer größeren medizinischen Relevanz treten dabei ventrikuläre Rhythmusstörungen und Reentry-Phänomene in den Vordergrund, während auf einfache Beispiele wie Sinustachykardien verzichtet wird.

Viele der beschriebenen Erkrankungen sind in den in Kapitel 3 beschriebenen EKG-Ableitungen unterschiedlich stark ausgeprägt. Dies hängt davon ab, wie sehr sich das betrachtete Phänomen auf die Projektion des Herzvektors auf den jeweiligen lead vector auswirkt. Für den ambulanten Bereich und die Langzeit-Überwachung haben sich Systeme mit zwei bis drei Ableitungskanälen durchgesetzt (siehe auch Kapitel 4.3). Dabei werden oft eine modifizierte Einthovenableitung (meist *II*) und eine Brustwandableitung (bspw.  $V_5$ ) verwendet. In seltenen Fällen wird auch eine vektorkardiografische Ableitungskonfiguration (Frank-Ableitungen oder EASI-Leads) angewendet, die später in eine 12-Kanal-Darstellung umgerechnet wird. Daher können die nachfolgenden Beispiele nur als exemplarisch gelten und differieren je nach der in der Realität verwendeten Ableitung.

### 3.4.1 Supraventrikuläre Rhythmusstörungen

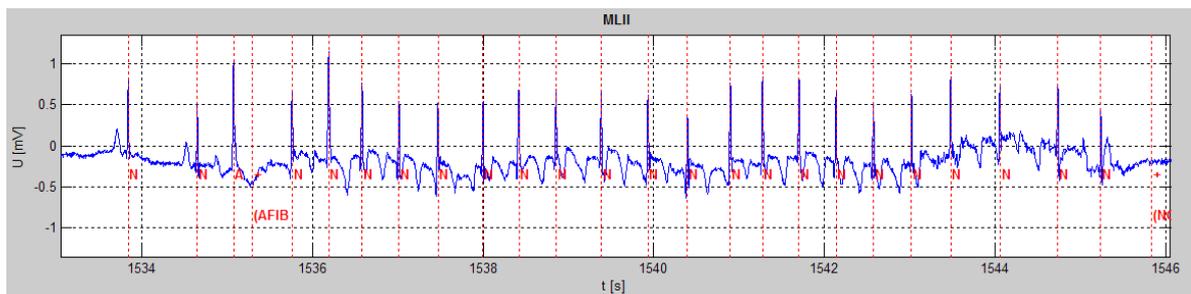
Wie in Kapitel 2.2.1 beschrieben werden bei einer aktiven Heterotopie im Bereich der Vorhöfe die Kammern normal erregt. Abbildung 3.7 zeigt ein Beispiel einer kompensierten supraventrikulären Extrasystole (SVES). Durch die Kürze des Kopplungsintervalls

ist die Erregung des Vorhofs durch das konkurrierende Erregungszentrum nicht erkennbar, während die P-Welle der normalen Erregungen in diesem Fall deutlich zu sehen ist. Der Kammerkomplex entspricht morphologisch den anderen QRS-Komplexen, so dass eine Diagnose dieser Erregungsbildungsstörung vorrangig auf rhythmologischer Basis erfolgen muss. SVES können natürlich auch intermittierend auftreten.

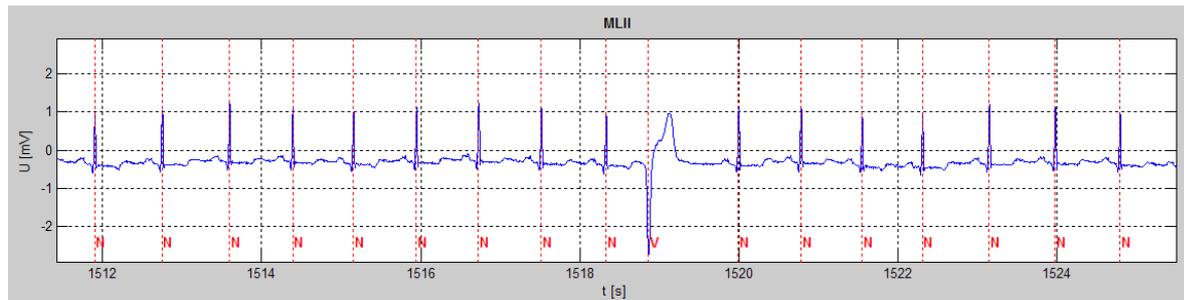


**Abbildung 3.7:** Isolierte kompensierte supraventrikuläre Extrasystole (A) aus Datensatz 101 der MIT/BIH Arrhythmia Database (MITDB) [Phy05a]. Deutlich erkennbar sind das verkürzte Kopplungsintervall und die verlängerte kompensatorische Pause. Der Kammerkomplex entspricht den anderen Normalerregungen (N).

Kreisende Erregungen im Bereich der Vorhöfe führen je nach Frequenz zu Vorhofflattern oder Vorhofflimmern. Nicht jede der am AV-Knoten eintreffenden Erregungen wird dabei auf die Kammern weitergeleitet, vielmehr erfüllt hier der AV-Knoten eine Rolle als „Frequenzsieb“, um eine unphysiologisch hohe Erregungsfrequenz der Ventrikel zu verhindern. Allerdings ist besonders beim Vorhofflimmern unbestimmt, welche der Erregungen letztlich zu einer Kammeraktion führt: Ergebnis ist ein unregelmäßiger Herzrhythmus wie in Abbildung 3.8 zu sehen ist. Bei einem Vorhofflattern kann es dagegen sein, dass sich ein festes Verhältnis von Vorhof- und Kammererregungen – meist als 2:1-Block [GH99] – ausbildet.



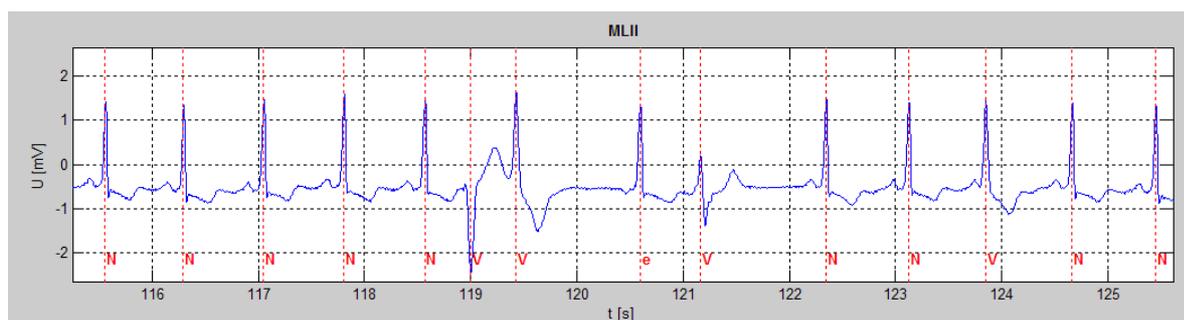
**Abbildung 3.8:** Vorhofflimmern mit resultierender Kammerarrhythmie durch unregelmäßige Überleitung der Erregung auf die Kammern. Das EKG-Beispiel stammt aus dem Datensatz 222 der MITDB, Spezifikation des Rhythmuswechsels durch die Ergänzung „(AFIB“ (Atrial Fibrillation)



**Abbildung 3.9:** Isolierte kompensierte ventrikuläre Extrasystole (V). Die durch die Lage des Erregungszentrums in der Kammer verursachte unphysiologische Erregung des Myokards ist durch die veränderte Form und Polarität im Vergleich zu den umgebenden Normalerregungen erkennbar. Das Beispiel stammt aus Datensatz 100 der MITDB.

### 3.4.2 Ventrikuläre Extrasystolen

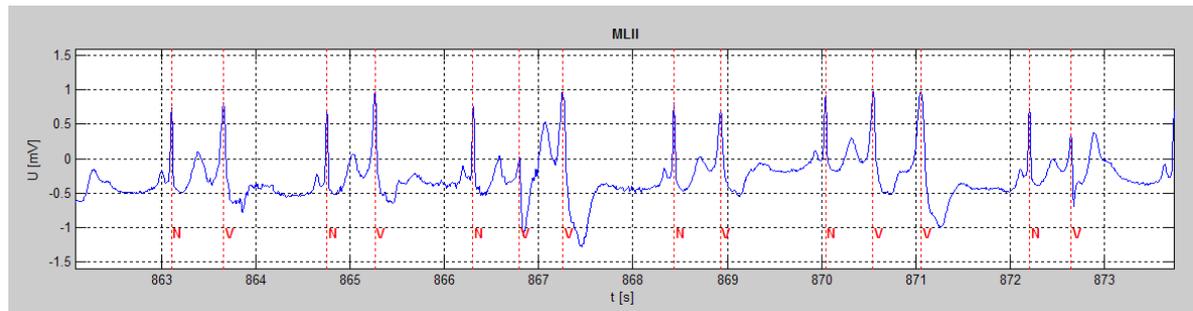
Ähnlich wie im vorhergehenden Abschnitt können auch ventrikuläre Extrasystolen (VES) isoliert auftreten. Ein solches Beispiel zeigt Abbildung 3.9. Die Morphologie der VES ist dabei stark abhängig vom Verlauf der Erregungsfront relativ zur Ableitungslinie, d.h. VES können sehr stark in Form, Amplitude und Polarität variieren.



**Abbildung 3.10:** Polymorphe Extrasystolen (V) in einem Couplet und nach einer supraventrikulären Ersatzsysteme (e) aus dem Datensatz 223 der MITDB.

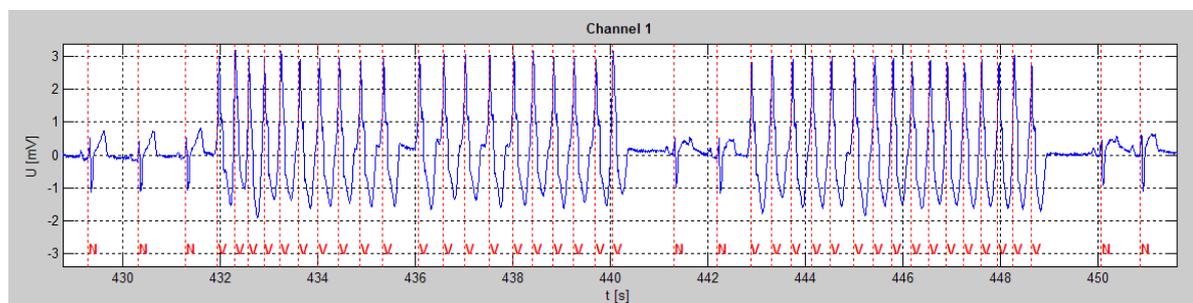
Abbildung 3.10 zeigt Beispiele von polymorphen Extrasystolen: Die beiden VES des Couplets weisen unterschiedliche Polarität auf und die T-Wellen haben ein unterschiedliches Aussehen, was auf unterschiedliche Erregungsursprünge hinweist. Auch die dritte VES zeigt wiederum andere Formen im QRS-Komplex und in der T-Welle. Bei dem Schlag dazwischen handelt es sich um eine supraventrikuläre Ersatzsysteme: Der QRS-Komplex ist normal geformt, die P-Welle entspricht jedoch nicht der Form der anderen Normalerregungen, d.h. der Vorhof wurde auf andere Weise erregt.

Das gehäufte Auftreten von Extrasystolen mit einer festen Kopplung zeigt Abbildung 3.11. Neben dem zu Grunde liegenden Bigeminus sind zusätzlich Couplets eingestreut, es liegt also ein Wechsel zwischen einer 1:1- und einer 1:2-Extrasystolie vor. Die Formen der VES lassen darauf schließen, dass auch hier mehrere konkurrierende zusätzliche Erregungszentren vorliegen.



**Abbildung 3.11:** Bigeminus mit eingestreuten Couplets. Die Daten stammen aus dem Datensatz 106 der MIT/BIH Arrhythmia Database [Phy05a]

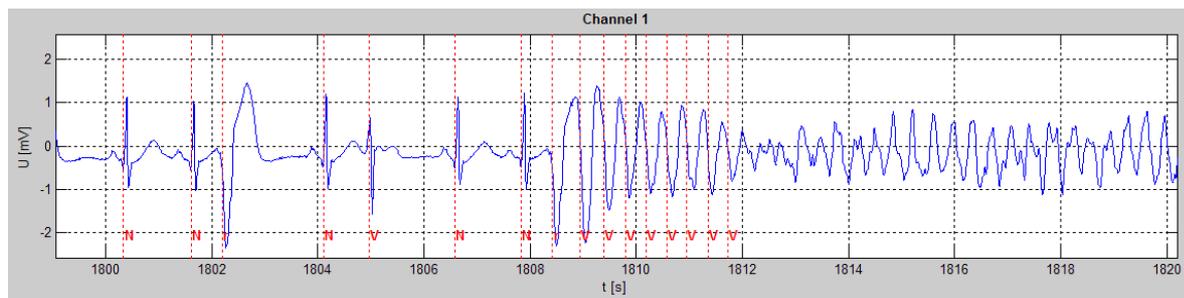
### 3.4.3 Tachykarde Rhythmusstörungen



**Abbildung 3.12:** EKG-Beispiel für tachykarde Salven, die nach mehreren kreisenden Erregungen von selbst terminieren. Danach stellt sich wieder ein normaler Sinusrhythmus ein. Die Daten stammen aus Datensatz 7204 der AHA Database (AHADB) [Ame05].

Gehäuftes Auftreten von VES kann zu längeren Perioden von aufeinanderfolgenden ventrikulären Erregungen führen, die aber von selbst wieder enden. Abbildung 3.12 zeigt Beispiele dieser sog. selbstterminierenden tachykarden Salven. Dabei sind die einzelnen Kammeraktionen noch gut voneinander zu unterscheiden. Die Herzraten schwanken in diesen Beispielen zwischen 140 und 160 bpm, was bei längerem Bestehen der ventrikulären Tachykardie zur Defibrillationspflicht führen würde.

Den spontanen Übergang in eine solche fortbestehende hochfrequente Kammertachykardie (VT) zeigt Abbildung 3.13, in diesem Fall hervorgerufen durch ein R-on-T-Phänomen: Die vorzeitige Kammererregung tritt so früh ein, dass sie die vulnerable Phase des Herzmuskels trifft, worauf sich sofort eine kreisende Erregung ausbilden kann. Zu Beginn der VT-Periode zeigt sich das typische Bild des Kammerflatters: Ein fast sinusförmiger Signalverlauf, bei dem die Trennung in Einzelkomplexe nur noch schwer möglich ist. Danach bricht das EKG weiter in unstrukturierte Komplexe auf. Das periodische An- und Abswellen der Signalamplitude sowie die Polaritätsumkehr der „spitzeren“ Signalkomplexe deutet auf eine Spitzenumkehrtachykardie („Torsade-de-pointes“) hin. Die Herzrate beträgt ca. 180 bpm, die Pumpleistung des Herzens dürfte somit stark eingeschränkt sein, es besteht in jedem Fall Defibrillationspflicht.



**Abbildung 3.13:** Einsetzende ventrikuläre Tachykardie: Da eine einheitliche Notation bei chaotischem Verlauf der Erregung nicht mehr möglich ist, wird bei tachykarden Rhythmusstörungen auf eine Einzelauszeichnung der Komplexe verzichtet. Die Daten stammen aus Datensatz 8201 der AHADB.

### 3.5 Störgrößen des EKG-Signals

Das EKG-Signal ist in der Realität von Störgrößen überlagert, die unterschiedliche Ursachen haben. In [FJJ<sup>+</sup>90] wird ein Überblick über die wichtigsten Störgrößen gegeben.

Eine dieser möglichen Störungen ist die Überlagerung des EKG-Signal mit einem 50 Hz-Signal und seinen Harmonischen. Dieses Signal entsteht durch kapazitive oder induktive Einkopplung aus dem Stromnetz. Im EKG-Signal wirkt sich diese Überlagerung auf den Frequenzgehalt und die Amplitude aus. Die Veränderungen des Signals, die durch diese Störung hervorgerufen werden, sind normalerweise während einer Messung gleichmäßig.

Durch den Kontakt der Elektroden, die zum Abnehmen des EKGs benötigt werden, entstehen ebenfalls Artefakte. Ihre Ursache liegt in Signalverlusten durch schlechten Kontakt zwischen Elektrode und Haut. Der schlechte Kontakt kann dauerhaft sein oder durch eine lockere Elektrode immer wieder auftreten. Die Bewegung der Elektrode relativ zur Haut ändert die Übergangsimpedanz zwischen Haut und Elektrode. Dadurch verändert sich auch das Signal. Besonders stark tritt dies beim Ziehen der Elektrode von der Haut weg auf, da dadurch die Kapazität des Elektroden-Haut-Systems verändert wird. Tiefere Informationen hierzu liefert [BU02]. Elektrodenartefakte sind häufig durch plötzliche starke Schwankungen der Nulllinie zu erkennen. Oft sind diese so stark, dass die EKG-Eingangsverstärker in die Sättigung gehen und kein Signal mehr erkennbar ist. Die häufigste Ursache für diese Bewegungsartefakte ist die Bewegung des Patienten.

Normalerweise liegt das durch Muskelkontraktion entstehende Elektromyogramm (EMG) im Millivoltbereich und damit im gleichen Bereich wie das EKG-Signal. Die Frequenzbereiche überlappen sich jedoch nur teilweise, so dass sich ein Teil der Artefakte herausfiltern lässt. Insgesamt sind die Störungen, die durch das EMG verursacht werden, am schwierigsten von dem eigentlichen EKG-Signal zu trennen.

Aufgrund der Atmung verschiebt sich die Grundlinie des EKG-Signals mit der Frequenz der Atmung. Die Amplitude des Signals wird ebenfalls durch die Atmung beeinflusst und schwankt um ca. 15% [FJJ<sup>+</sup>90].

**Tabelle 3.5:** Überblick über verschiedene Störgrößen des EKGs

Störgröße	Typische Parameter
Kapazitive Einkopplung aus dem Stromnetz	Frequenz: 50 Hz (Europa) 60 Hz (USA) Amplitude : bis zu 50% der EKG-Amplitude
Rauschen durch Elektrodenkontakt	Frequenz: 50/60 Hz Amplitude: Maximum des Aufnahmeeräteausgangs
Bewegungsartefakte	Amplitude: bis zu 500% der EKG-Amplitude Dauer: 100 - 500 ms
EMG	Frequenz: DC - 10 kHz Dauer: 50 ms
Nullliniendrift und Amplitudenmodulation durch Atmung	Frequenz: 0,15 - 0,3 Hz Amplitude: 15% der EKG-Amplitude

# 4 Mobiles EKG-Monitoring

Dieses Kapitel bietet einen Überblick über die zur Zeit am Markt befindlichen Systeme zur Langzeitaufnahme und Klassifikation von EKG-Signalen bei mobilen Patienten. Auf Grund der Fülle der am Markt befindlichen Anbieter und der unterschiedlichen Einsatzschwerpunkte der Geräte werden jedoch nur die wichtigsten Systemklassen definiert und einzelne Geräte exemplarisch vorgestellt. Der Hauptunterschied zwischen den vorgestellten Systemen besteht darin, ob sie für den stationären Einsatz innerhalb von Kliniken, Rehabilitations- oder Pflegeeinrichtungen konzipiert sind oder ob sie auf den Markt der Heim- und mobilen Überwachung zielen.

## 4.1 Kriterien zur Klassifikation von EKG-Überwachungssystemen

EKG-Überwachungs- und Auswertesysteme lassen sich in unterschiedliche Kategorien einteilen. Je nach Einsatzzweck, -dauer und -rahmenbedingungen spielen verschiedene Geräteaspekte eine Rolle, die teilweise sehr heterogene Anforderungen an das System stellen. Um eine solche Einteilung vorzunehmen sind zunächst einige Definitionen und Abgrenzungen von Begriffen notwendig.

**Mobileinheit:** Dies ist ein Gerät, das der Patient permanent bei sich trägt und das die physische Ankopplung des Messsystems an den Körper gewährleistet. In den meisten Fällen handelt es sich um eine Ableitung des EKG-Signals über herkömmliche Silber/Silberchlorid-Klebelektroden, auch wenn gegenwärtig viele Forschungsanstrengungen im Bereich der Integration der Elektroden in Textilien oder anderen Trockenelektroden unternommen werden. Die Mobileinheit ermöglicht es dem Patienten, sich ungehindert zu bewegen in dem Sinn, dass er nicht durch Kabelverbindungen oder andere Leitungen an ein sehr eng umschriebenes Areal wie beispielsweise sein Bett gebunden ist. Die Mobileinheit kann über einen nicht-flüchtigen Speicher verfügen, um das EKG-Signal über einen längeren Zeitraum hinweg zu speichern. Es ist jedoch auch möglich, dass das EKG direkt von der Mobileinheit aus übertragen wird. Auch Mischformen dieser Fälle sind denkbar. Die Mobileinheit bildet in jedem Fall nur einen Zwischenspeicher oder eine Relaisstation bei der Übertragung des EKG-Signals vom Körper des Patienten. Der sonstige Leistungsumfang der Mobileinheit ist damit nicht näher beschrieben.

**Zentraleinheit:** Diese Einheit ist die Datensinke zur permanenten Speicherung des EKG-Signals. Häufig, aber nicht gezwungenermaßen erfolgt hier auch die Weiterverarbeitung, Auswertung und Präsentation des EKG-Signals. Dies schließt nicht aus, dass

die Zentraleinheit als verteiltes System, beispielsweise als Client-Server-Architektur aufgebaut ist, sondern verdeutlicht ihre Aufgabe als zentralen Sammelpunkt der Patientendaten. Im Rahmen dieser Arbeit wird auch Zentralstation als Synonym verwendet.

**Überwachungsgebiet:** Hierunter ist das Areal zu verstehen, in dem der Patient über einen längeren Zeitraum beobachtet werden soll. Handelt es sich dabei um Einrichtungen wie Krankenhäuser, Rehabilitationszentren oder Pflegeheime ist das Gebiet, in dem sich die Patienten bewegen relativ genau umschrieben: Das eigene Zimmer, die Räume der Einrichtung und evtl. das umliegende Freigelände. Dieser Fall wird in der Folge daher stationärer Einsatz genannt. Ist das Überwachungsgebiet nicht so scharf einzugrenzen, da der Patient in seiner alltäglichen Umgebung, zu Hause, am Arbeitsplatz und in seiner Freizeit überwacht werden soll, wird dies als mobiler Einsatz bezeichnet. Im Extremfall muss hier von einem weltweiten Einsatz ausgegangen werden.

**Langzeitüberwachung:** Unter diesem Begriff ist die dauerhafte Applikation der Mobileinheit am Patienten für einen Zeitraum von 24 Stunden und mehr gemeint, abgesehen von kleineren Zeitlücken zur Körperpflege etc. Da viele pathologische Ereignisse im EKG nur selten und über einen langen Zeitraum verteilt auftreten, ist eine möglichst lange Applikationsdauer wünschenswert. Derzeit besitzen viele Geräte eine Laufzeit von 72 Stunden, wenige können länger als eine Woche eingesetzt werden. Bei entsprechend gefährdeten Patienten wäre ein dauerhafter Einsatz über Monate oder vielleicht sogar Jahre hinweg wünschenswert. Ein alternativer Begriff ist Langzeitmonitoring.

**Ereignisaufzeichnung:** Im Gegensatz zur Langzeitaufzeichnung werden bei der Ereignisaufzeichnung oder dem „Event-Recording“ nur Ausschnitte des EKGs dokumentiert. Dies geschieht vor dem Hintergrund, dass der größte Anteil des EKGs für den Mediziner ohne besonderen Informationsgehalt ist, da darin keine Änderungen der elektrischen Herzaktivität dokumentiert werden. Die für den Mediziner interessanten „Ereignisse“ sollen aber bei dieser Überwachungsform aufgezeichnet werden. Der Begriff Ereignisaufzeichnung definiert nicht, auf welche Weise entschieden wird, ob ein relevantes Ereignis eingetreten ist und die Aufzeichnung in Gang gesetzt wird.

**EKG-Analyse:** Darunter ist die automatische Auswertung des EKG-Signals zu verstehen, im Gegensatz zu der manuellen Befundung durch einen Arzt oder anderes medizinisch ausgebildetes Personal. Die Analyse kann eine unterschiedliche Komplexität aufweisen und von der Einzelschlagklassifikation bis hin zur Analyse der sympathikovagalen Regelgüte reichen.

**Online- und Offlineanalyse:** Dieses Begriffspaar definiert den zeitlichen Ablauf, wann die Analyse des aufgenommenen EKGs vorgenommen wird. Online-Analyse wird hier so verstanden, dass die Analyse des EKG-Signals so zeitnah erfolgt, dass sich zwischen Auftreten des Ereignisses und seines Erkennens durch das Klassifikationssystem ein aus therapeutischer Sicht irrelevantes Zeitintervall befindet. Da bei Eintreten von lebensbedrohlichen Rhythmusstörungen möglichst schnell gehandelt werden muss, beträgt dieses Zeitintervall jedoch maximal wenige Sekunden. Als Nebenbedingung der Online-Analyse

ergibt sich, dass diese auf der verwendeten Plattform unter allen Umständen in Echtzeit lauffähig sein soll. Unter Echtzeit wird hier verstanden, dass die Analyse eines Signal-samples in jedem Fall abgeschlossen ist, bevor das nächste aufgenommen wird. Dies ist bei Entwurf und Implementierung zu berücksichtigen.

Bei der Offline-Analyse dagegen können zwischen den aufgezeichneten Ereignissen und ihrer Auswertung Stunden, evtl. sogar Tage liegen. Die Zeitdauer der Auswertung ist damit weniger kritisch, so dass eine Echtzeitfähigkeit nicht unbedingt erforderlich ist. Auf der anderen Seite ist natürlich eine möglichst kurze Analysedauer speziell bei der Auswertung von Langzeitüberwachungen wünschenswert, so dass die Analysedauer in der Realität normalerweise deutlich unterhalb der Aufnahmedauer liegt. Dies wird jedoch bei der Offline-Analyse vorrangig durch den Einsatz leistungsfähiger Hardware realisiert.

**Elektrodenkonfiguration:** Hierunter sind Anzahl und Platzierung der verwendeten Elektroden zu verstehen. Daraus resultiert die Anzahl der abgeleiteten EKG-Kanäle. In Kapitel 3 wurden verschiedene in der Praxis gebräuchliche Konfigurationen vorgestellt. Im Bereich der Langzeitüberwachung haben sich vor allem Systeme mit 1-3 Kanälen durchgesetzt. Häufig eingesetzt werden Einthoven- und bestimmte Wilsonableitungen. Bei einigen Systemen kommen jedoch auch die vektorkardiographischen Systeme der Frank-Ableitungen oder der EASI-Leads zum Einsatz. Neben der Anzahl der Elektroden bestimmt auch die für ihre korrekte Platzierung notwendige Sorgfalt den Anwendungsbereich verschiedener Elektrodenkonfigurationen: Ist für die Anlage medizinischer Sachverstand (z.B. in Form des Ertastens von körperspezifischen Punkten wie bestimmten Rippenzwischenräumen) erforderlich, kann dies nur durch entsprechend geschultes Personal vorgenommen werden. Damit sind diese Ableitungen für die mobile Langzeitüberwachung eher ungeeignet. In diesem Fall sind Ableitungen zu bevorzugen, die vom Patienten selbst oder dessen Umfeld appliziert werden können.

## 4.2 Systeme für den stationären Einsatz

Systeme für den stationären Einsatz übernehmen z.B. die postoperative Überwachung auf einer kardiologischen Intensivstation. In diesem Fall wird die Überwachung häufig durch ein engmaschiges Netz von Access-Points gewährleistet, über die die Mobileinheiten ihre Signale zur Zentralstation senden. Dort können sie auf zentralen Überwachungsbildschirmen angezeigt werden. Oft ist eine umfangreiche Online-Analyse damit verbunden, um eine automatische Alarmierung des Personals zu ermöglichen, falls sich der Status des Patienten verschlechtert. Die Mobileinheiten der Patienten benötigen also nicht zwingend einen internen Speicher, da sie das EKG direkt in das Netzwerk übertragen. Um eine möglichst lange Laufzeit der Mobileinheiten zu gewährleisten, wird die Intelligenz dieser Geräte möglichst gering gehalten. Zwei etablierte Systeme sollen in der Folge detaillierter vorgestellt werden.

**General Electric TELEGUARD:** Das *TELEGUARD* System der dänischen General Electric Tochter Danica Biomedical [Dan05] ist ein klassisches System für den stationären Einsatz. Die Mobileinheiten sind für eine Vielzahl von verschiedenen Elektroden-



(a) Transmitter T3300 des TE-LEGUARD systems



(b) Transmitter des Philips Telemetry Systems

**Abbildung 4.1:** Beispiele für mobile Patienteneinheiten für stationäre EKG-Telemetriesysteme

konfigurationen ausgelegt, darunter auch die vektorkardiografischen Ableitungen nach Frank und EASI. Es können zusätzlich noch weitere Sensoren wie z.B.  $\text{SpO}_2$  oder ein Blutdruckmesssystem an die Mobileinheiten angeschlossen werden. Die aufgenommenen Daten werden über ein proprietäres Protokoll an die Zentraleinheit gesendet, wo sie automatisch analysiert werden. Auch eine Lokalisation des Patienten innerhalb der Einrichtung ist möglich. Die Zentralstation bietet vielseitige Möglichkeiten der Online-Analyse: Neben der Detektion von verschiedenen Arrhythmien liegt ein großer Schwerpunkt der Analyse in der Bewertung von ST-Streckenveränderungen für die Ischämieüberwachung und die Darstellung entsprechender Trends. Zeitgleich können bis zu 40 Patienten überwacht werden, die sich im Einzugsbereich der Empfängerantennen des Systems befinden.

**Philips Telemetry System:** Dieses System und seine zentrale Überwachungseinheit IntelliVue Information Center [Phi04a] bietet einen sehr ähnlichen Leistungsumfang. Die EKG-Transmitter können mit einer 3- oder 5-Elektroden-Konfiguration getragen werden, alternativ sind auch hier die EASI-Leads möglich. Das EKG kann zusammen mit optional erhobenen  $\text{SpO}_2$ -Daten an die Zentralstation übertragen werden, wo es ausgewertet wird. Der Transmitter kann in einen transportablen Bedside-Monitor eingeschoben werden, um eine direkte Visualisierung der Patientendaten z.B. während der Visite zu ermöglichen. Philips ist einer der wenigen Hersteller, der Daten zur Performance seines Auswertalgorithmus auf den Datensätzen der MIT/BIH-Datenbank (MITDB) [Phy05a] und der AHA-Datenbank (AHADB) [Ame05] macht. Die Daten sind in Tabelle 4.1 dargestellt. Auch dieses System besitzt eine Vielzahl von Algorithmen zur Überwachung von ST-Streckenänderungen und zu deren Trendanalyse. Zur Bedeutung und Berechnung der einzelnen statistischen Parameter siehe Anhang A.1.

**Weitere Systeme:** Ein Prototypensystem zur gezielten Detektion von lebensbedrohlichen VT-/VF-Rhythmen im häuslichen Umfeld wurde 2004 vorgestellt [BMTB04]. Die Datenübertragung erfolgt von einem Brustgurt, mit dem das EKG aufgenommen wird, über Bluetooth<sup>®</sup> zu einem fest installierten, ebenfalls mit einem Bluetooth<sup>®</sup>-Modul ausgestatteten Access-Point. Dort erfolgt die Auswertung des Signals und im Notfall

**Tabelle 4.1:** Detektionsgüten des Philips ST/AR Algorithmus auf der MIT/BIH- und AHA-Datenbank (aus [Phi04b], zu den Datenbanken siehe B)

Durchschn. erreichte Güte	MITDB	AHADB
Sensitivität QRS-Komplexe	99,66%	99,80%
Pos. Prädiktivität QRS-Komplexe	99,86%	99,87%
Sensitivität VES	94,25%	95,96%
Pos. Prädiktivität VES	96,38%	98,34%

wird über ein eingebautes Modem die Alarmierung der Rettungsleitstelle ähnlich wie bei einem Hausnotrufsystem ausgelöst. Durch die Verwendung von Bluetooth<sup>®</sup> ist der Aktionsradius relativ stark eingeschränkt, wobei allerdings durch die Installation von mehreren Bluetooth<sup>®</sup>-Access-Points und ein Roaming des Mobilsystems die Abdeckung eines größeren Areals denkbar wäre.

### 4.3 Systeme für den mobilen Einsatz

**Holter-Monitoring:** Erste Umsetzungen des mobilen Einsatzszenarios fanden mit der Einführung des Holter-Recorders bereits ab Ende der 1960er Jahre statt. Auch heute ist dies immer noch die bei Weitem gängigste Methode des Langzeitmonitorings: Die Mobileinheit zeichnet das EKG-Signal auf einem Speichermedium auf, bei der Rückgabe des Gerätes wird dieses Medium ausgelesen und anschließend findet eine Offline-Analyse des EKG-Signals statt. Früher wurden für Holter-Recorder häufig Bandlaufwerke auf Compact-Cassetten-Basis verwendet, die auch heute noch vereinzelt anzutreffen sind. Mit der Einführung digitaler Speichermedien sind insbesondere in Bezug auf Störungen des Signals durch mechanische Einflüsse beim Bandtransport sowie die Übertragungsgeschwindigkeiten der Daten zur Zentralstation Verbesserungen erzielt worden. Charakteristisch für Holter-Recorder-Systeme ist, dass in der Mobileinheit keine größere Signalverarbeitung stattfindet. Die EKG-Analyse findet erst auf der Zentralstation statt. Im Normalfall hat der Patient die Möglichkeit, über eine spezielle Markertaste besondere Vorkommnisse wie Bewusstseinsstörungen, Schmerzen, körperliche Aktivität etc. zu markieren. Die meisten Systeme besitzen darüber hinaus einen – meist Hardware-basierten – Detektor für Schrittmacherimpulse, um durch deren exakte Lokalisierung die spätere Analyse von Schrittmacher-EKGs zu erleichtern. Dies hat seinen Grund darin, dass diese Impulse durch die Eingangsfiterstufen des Geräts verzerrt werden und nicht mehr exakt lokalisiert werden können, was die weitere Analyse des EKGs erschwert.

**Event-Recorder:** Die Ereignisaufzeichnung ist historisch aus der Langzeitüberwachung entstanden, um mit dem begrenzten Speicher der Mobileinheiten und deren erhöhtem Strombedarf einen längeren Beobachtungszeitraum realisieren zu können. Anstatt das EKG wie bei den Holter-Rekordern kontinuierlich aufzuzeichnen, werden nur ausgewählte Ereignisse aufgezeichnet. Die Zeiten vor und nach dem Ereignis können dabei je nach Rekorder von einigen Sekunden bis zu mehreren Minuten variieren. Ein anderer Name für diese Systeme ist Loop-Rekorder, da das EKG kontinuierlich in einen Ringspeicher geschrieben wird, der nur beim Auslösen der Aufzeichnung dauerhaft gesi-

chert und ansonsten zyklisch überschrieben wird. Die Aufzeichnung der Ereignisse muss bei fast allen Systemen am Markt manuell durch den Patienten ausgelöst werden. Der Aspekt des geringeren Speicherbedarfs tritt bei modernen Systemen auf Grund der aktuellen Speichermedien und -technologien in den Hintergrund. Der andere Vorteil des Event-Recordings, nämlich die geringere auszuwertende Informationsmenge bei gleichzeitig höherer klinischer Relevanz der aufgezeichneten Ereignisse bleibt jedoch weiter bestehen. Der Nachteil besteht in der Möglichkeit, dass relevante Ereignisse nicht erfasst wurden, weil sie entweder vom Patienten unbemerkt blieben oder ihm keine Zeit mehr blieb, die Aufzeichnung auszulösen. Dies kann z.B. bei kurzzeitigen, durch Arrhythmien hervorgerufene Bewusstseinsstörungen, sog. kardialen Synkopen, der Fall sein.

**EKG-Telemetrie:** Moderne Telekommunikationstechnik bietet die Möglichkeit, das EKG über weite Strecken zu übertragen. Event-Rekorder mit eingebautem Akustik-Koppler sind schon seit Jahren v.a. in Flächenstaaten wie den USA verbreitet, das sie die Übertragung über jedes beliebige Telefon, auch Mobiltelefone ermöglichen. Andere Geräte können über Infrarot(IR)-Schnittstelle oder mit einem seriellen Kabel über ein angeschlossenes Mobiltelefon kommunizieren. Daneben gibt es einige wenige EKG-Recorder mit eingebautem GSM-Modem [Sch05].

Einen anderen Ansatz stellt das von der Firma Vitaphone angebotene HerzHandy [Vit05a] dar, bei dem ein Mobiltelefon mit Ableitelektroden versehen ist. Im Notfall leitet der Patient dann das EKG auf der Brust ab und versendet es an die Vitaphone-Servicezentrale. Für die Patientenlokalisierung ist zusätzlich ein GPS-Modul eingebaut. In Deutschland haben sich die „Tele-Event-Rekorder“ bisher nicht durchsetzen können, da auf Grund der guten medizinischen Versorgung die Vorteile dieser Systeme wie Zeitersparnis für Arzt und Patient, geringerer Arbeitsausfall durch notwendige Wege zum Arzt und schnellere Hilfeleistung im Notfall nicht so stark zum Tragen kommen. Telemedizinische Dienstleistungen sind bei vielen Krankenkassen bisher nicht gesondert abrechenbar und lohnen sich für den Arzt nicht. Hinzu kommt, dass in vielen Fällen zwar die technischen Voraussetzungen für eine EKG-Telemetrie gegeben sind, jedoch die eigentlich notwendige Betreuung rund um die Uhr durch den Arzt nicht gewährleistet werden kann. Der Aufbau einer entsprechenden Service-Struktur mit einem rund um die Uhr erreichbaren Call-Center mit medizinisch qualifiziertem Personal ist derzeit zumindest in Deutschland nur in wenigen Fällen betriebswirtschaftlich lohnend. Es ist jedoch anzunehmen, dass sich dies durch die ständig wachsende Bedeutung der Telemedizin und die ihr zugeschriebenen Einsparpotenziale schon in naher Zukunft ändern wird.

**Marktsituation:** Am Markt sind eine Vielzahl von Herstellern mit Holter- und Event-Rekordern vertreten, deren Aufzählung den Rahmen dieser Arbeit sprengen würde. Die Firma Medset hat 2003 im Rahmen des BMBF-Projekts TeDiaNet [TeD05a] eine Marktuntersuchung zu mobilen EKG-Rekordern mit der Möglichkeit zur Telemetrie durchgeführt [WRF03]. Dort wurden insgesamt 39 verschiedene Systeme identifiziert, wobei die vertretene Bandbreite von einem Herzschrittmacher mit Telemetrie zu einem speziellen externen GSM-Modem bis hin zu einem Gurtsystem für die kurzzeitige Ableitung eines 12-Kanal-EKGs reicht, so dass hier nicht von einer Mobileinheit im Sinne von Kapi-

tel 4.1 gesprochen werden kann. Bei der Mehrzahl der in dieser Studie aufgeführten Geräte handelt es sich jedoch um kleine, dauerhaft tragbare Systeme mit extrakorporaler EKG-Ableitung. Nur bei wenigen Anbietern (z.B. [Car05] [Nov05] [Del05]) erfolgt eine Online-Analyse des EKGs, so dass die Speicherung der relevanten Ereignisse meist durch den Patienten erfolgen muss. Das Versenden der Daten muss bei jedem der betrachteten Systeme durch den Nutzer manuell initiiert werden.

## 4.4 Mobiles Telemonitoring mit Online-EKG-Klassifikation

Der logische nächste Entwicklungsschritt, nämlich das automatische Versenden der EKG-Daten nach dem Auftreten eines relevanten Ereignisses, wurde jedoch, soweit bekannt, bisher nur für ein in Deutschland auf dem Markt befindliches System vollzogen, einem automatischen Loop-Rekorder der Firma Vitaphone [Vit05b] (siehe Abbildung 4.2). Für die Analyse werden die QRS-Komplexe detektiert und mit einer Rhythmusanalyse die Diagnose über das etwaige Vorliegen von Vorhofflimmern gestellt. Allerdings sind bei diesem Gerät keine Informationen über die Güte der verwendeten Algorithmen verfügbar.



**Abbildung 4.2:** Automatischer Loop-Event-Rekorder der Firma Vitaphone GmbH. Bei Rhythmusstörungen kann das EKG automatisch über Bluetooth<sup>®</sup> an ein Mobiltelefon und von dort aus weiter zur Servicezentrale der Firma übertragen werden.

Ein möglicher technischer Grund für die zögerliche Einführung dieser Geräte ist das Vorherrschen von Akustikkopplern bei den technischen Lösungen zur Datenübertragung, aber auch die hohen Systempreise, die durch den Einbau eines eigenen GSM-Moduls entstehen, das notwendig ist, um eine räumlich und zeitlich unabhängige Datenübertragung zu gewährleisten.

Den Aufbau eines drahtlosen Sensornetzwerks am Körper über Funkverbindungen mit kurzer Reichweite wie beispielsweise Bluetooth<sup>®</sup> war Inhalt des im Jahr 2001 begonnenen und 2004 beendeten PHMon-Projekts [Ins05]. Die Daten der einzelnen Sensoren werden zunächst in einem PDA oder Smartphone am Patienten gesammelt und von dort aus über Mobilfunk in eine elektronische Patientenakte (EPA) übertragen. Auf diese Weise ist dem Arzt die Möglichkeit gegeben, den Gesundheitszustand des Patienten

zeitnah zu überwachen. Der Schwerpunkt des Projekts lag jedoch mehr auf dem Aufbau der Kommunikationsinfrastruktur als in der automatischen Signalklassifikation, die den Kernpunkt dieser Arbeit darstellt. Ein anderes Beispiel für ein sehr ähnliches Vorhaben ist das Projekt MobiHealth, das im 5. Rahmenprogramm der EU von 2002-2003 gefördert wurde [Mob05]. Ein aktuelles EU-Projekt ist MyHeart [MyH05], das noch bis 2007 laufen wird.

Das TeDiaNet-Projekt [TeD05b] verfolgt einen ähnlichen Ansatz, um die Kommunikation zwischen Mobileinheit und Zentralstation durch automatische Anbindung eines Mobiltelefons über Bluetooth<sup>®</sup> zu ermöglichen. Dies entspricht der Kommunikation über eine IR- oder kabelgebundene Verbindung, eliminiert aber viele ihrer Nachteile wie notwendige Sichtverbindung, Interaktionsaufwand durch den Patienten oder den stark begrenzten Aktionsradius. Die Online-Analyse erfolgt in der EKG-Mobileinheit, da die Hardware eines Smartphones nicht leistungsfähig genug für die verwendeten Algorithmen ist und in jedem Fall zu starke Auswirkungen auf die Laufzeit und damit die Verfügbarkeit des Systems hätte. Dieses Projekt wird im folgenden Kapitel genauer vorgestellt.

Die prinzipielle Nutzbarkeit von PDAs als Plattform für die Implementierung eines Echtzeit-Klassifikationsverfahrens für EKG-Daten wurde in [RGnI05] nachgewiesen. Jedoch wurden keine Angaben über die tatsächlich erreichbare Systemlaufzeit gemacht.

# 5 Systemkonzept für ein mobiles Online-Monitoring

Die in Kapitel 4 vorgestellten Systeme deuten bereits eine zunehmende Entwicklung von mobilen EKG-Geräten in Richtung einer autarken Überwachung des Patienten an. Teilweise ermöglichen die Systeme eine (automatische) Datenübertragung zu einer Gegenstelle, bei der dann eine Nachanalyse - meist direkt durch medizinisches Personal - erfolgen kann. In den meisten Fällen bleibt die an dieser Gegenstelle vorzuhaltende Dienstleistung bzw. die dort handelnden Personen („der betreuende Arzt“) unklar. Nur bei den klinischen Systemen und beim Serviceangebot von Vitaphone ist diese Überwachungsaufgabe klar geregelt. Das im Rahmen des am FZI durchgeführten TeDiaNet-Projekts erarbeitete Systemkonzept bildet mit den daraus abzuleitenden Anforderungen an die EKG-Analyse die wesentlichen Grundlagen für die vorliegende Arbeit. Zunächst werden die Rahmenbedingungen für ein mobiles Monitoring vorgestellt, aus dem sich in der Folge die möglichen Parameter für eine solche Überwachung ergeben. Zum Schluss werden die sich daraus ergebenden Konsequenzen für die EKG-Klassifikation formuliert.

## 5.1 Aktuelle Situation in der Behandlung kardiovaskulärer Erkrankungen

Betrachtet man die heutige Situation in der Therapieführung bei Patienten mit diagnostizierter Herz-Kreislauf-Erkrankung, so lösen sich Intervalle sehr intensiver Betreuung (z.B. im Krankenhaus oder in der Rehabilitation) mit Zeiten sehr niedriger Kontroll-dichte (routinemäßiger Besuch beim Hausarzt oder Kardiologen) ab. Einen schematischen Verlauf von Gesundheitsniveau und Kosten zeigt Abbildung 5.1. Erst nach der Manifestation einer Krise setzt eine intensive Behandlung mit hohen Kosten ein, die den ursprünglichen Gesundheitszustand aber nicht mehr erreichen kann. Die Zeitintervalle, in denen der Patient im heimischen Umfeld ist, werden immer kürzer, die Klinikaufenthalte immer länger. Insgesamt nimmt die Gesundheit des Patienten deutlich ab. Routineuntersuchungen sind in der Darstellung nicht berücksichtigt. Die Kosten für Krankenhaus- und Rehabilitationsaufenthalte sind über die Gesamtdauer gemittelt dargestellt.

Etwaige Interventionszeitpunkte werden im Wesentlichen durch den Patienten auf Grund seines persönlichen Befindens vorgegeben. Bei routinemäßigen Nachuntersuchungen, z.B. mit Ruhe-EKG und Blutlabor, werden Momentaufnahmen des aktuellen Gesundheitsstatus erhoben, die nur eine begrenzte Aussagekraft besitzen. Ausführlichere Untersuchungen mit der Simulation einer Belastungssituation beispielsweise durch EKG-Ergometrie sind relativ aufwendig und lassen ebenfalls nur bedingt Rückschlüsse



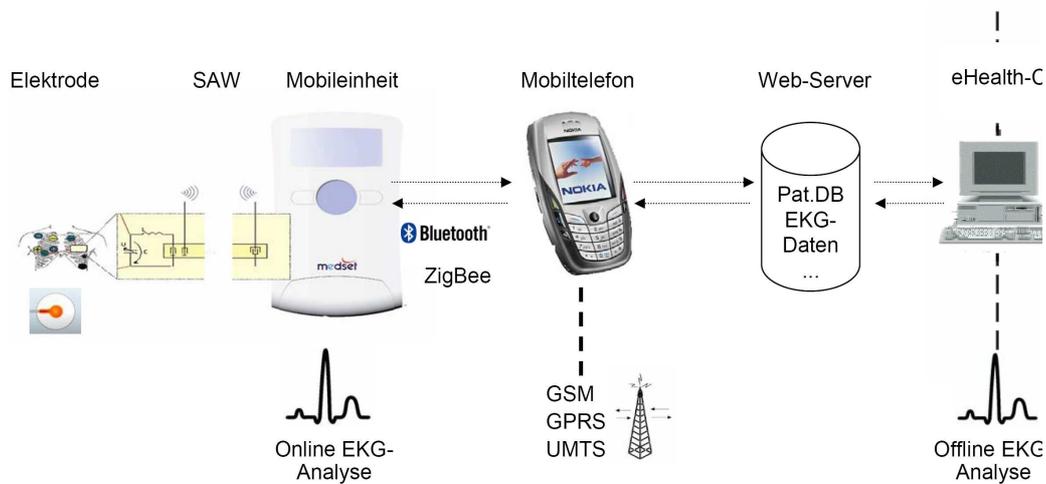
**Abbildung 5.1:** Schematischer Verlauf des Gesundheitszustandes und der Behandlungskosten eines Patienten mit kardiovaskulärer Erkrankung bei heutiger Therapieform.

auf das Langzeitverhalten der Erkrankung zu. Die Folge ist, dass in den meisten Fällen eine notwendige Modifikation der Therapie oder eine andere Intervention erst bei Manifestierung neuer Symptome, mithin also erst nach eingetretener Verschlechterung des Gesundheitszustandes erfolgt. Dies wiederum zieht hohe weitere Kosten für das Gesundheitssystem durch die dann notwendige, unter Umständen deutlich aufwendigere Therapie und die folgende Rehabilitation nach sich. Lohnersatzleistungen kommen in vielen Fällen hinzu. Weitere Kosten entstehen durch etwaige Erwerbsunfähigkeit oder Pflegebedürftigkeit.

Vor diesem Hintergrund ist einsichtig, dass durch entsprechende Prävention die notwendigen Behandlungskosten effektiv gesenkt werden könnten. Ein weiterer positiver Effekt wäre, dass damit auch der Gesundheitsstatus des Patienten für längere Zeit auf einem höheren Niveau gehalten werden könnte, was eine weitere Kostenersparnis bedeutet. Eine Möglichkeit, diese Prävention zu unterstützen, ist die engmaschige oder auch kontinuierliche Überwachung des Patienten. Allerdings müssen die Kosten, die durch diese verbesserte Prävention entstehen, nachweislich geringer sein als die potenziellen Mehrkosten, die durch den bisherigen Status quo bei der Therapieführung entstehen. Abbildung 5.2 zeigt einen Gesundheits-/Kostenverlauf, wie er idealerweise durch ein solches Monitoring erreicht werden könnte. Krisen werden frühzeitig erkannt und Einbußen



Implementierung eines solchen Konzepts zur Überwachung des EKGs, das im Folgenden detaillierter erläutert wird.



**Abbildung 5.3:** Blockbild des Teilprojekts Telex im Rahmen des BMBF-Projekts TeDiaNet. Mobileinheit und Zentralstation können über ein Mobiltelefon bidirektional miteinander kommunizieren. Die Übertragung erfolgt aus Energiegründen nicht kontinuierlich, sondern wird von einem der beiden Endgeräte initiiert.

Der Patient trägt dauerhaft eine Mobileinheit ähnlich den bereits am Markt befindlichen Holter-Recordern. Im Gegensatz zu diesen wird das EKG jedoch laufend online analysiert. Die Ankopplung an den Körper erfolgt derzeit über Standard-Elektroden, die im Blockbild eingetragenen SAW (*Surface Acoustic Wave*)-Transponder befinden sich noch in der Entwicklung [KFM05, FKJ05].

Die Mobileinheit kann EKG-, aber auch andere daraus gewonnene Daten an ein Mobiltelefon übertragen. Damit ist das Überwachungsgebiet - eine entsprechende Kommunikationsinfrastruktur vorausgesetzt - nahezu unbegrenzt. Die Kommunikation zwischen Mobilsystem und Telefon erfolgt derzeit über Bluetooth®. Das Mobilsystem kann auf Grund seiner EKG-Analyse selbständig eine Alarmerung auslösen. Die Daten werden an eine zentrale Datensinke - in Abbildung 5.3 als Web-Server bezeichnet - gesendet. Der Patient kann auch von sich aus eine solche Datenübertragung initiieren. Dies kann sowohl an der Mobileinheit als auch am Mobiltelefon über Tastendruck geschehen. Die Übertragung der Patientendaten auf den Server erfolgt über verschlüsselte Übertragungswege, um die Sicherheit der Daten zu gewährleisten.

Auf den Datenbestand des Web-Servers kann über ebenfalls gesicherte Kommunikationswege von der eigentlichen Zentralstation (im TeDiaNet-Konzept „eHealth-Center“ genannt) zugegriffen werden bzw. wird diese von neu eintreffenden Daten in Kenntnis gesetzt. Diese werden im eHealth-Center gegebenenfalls nochmals analysiert und schließlich medizinisch geschultem Personal präsentiert, das in der Folge weitere Maßnahmen ergreifen kann.

Auch von der Zentralstation kann eine Datenübertragung initiiert werden, um z.B. im Rahmen von routinemäßigen Übertragungen aufbereitete Kerndaten zu übertragen. Auch gezielte Übertragungen von auf der Mobileinheit gespeicherten Datenabschnitten

sind Bestandteil des Konzeptes. Auf diese Weise ist es dem behandelnden Arzt möglich, sich auch zwischen den bisher üblichen Routinekontrollen über den Zustand seines Patienten zu informieren.

Das eHealth-Center soll im TeDiaNet-Konzept als 24/7-Dienstleistung etabliert werden, so dass eine kontinuierliche telemedizinische Betreuung des Patienten sichergestellt werden kann.

### 5.2.1 Chancen und Vorteile des mobilen Online-Monitorings

Die Chancen und Vorteile, die sich mit einem auf diesem Konzept aufgebauten Dauermonitoring ergeben, lassen sich in folgenden Punkten zusammenfassen:

1. Durch die automatische EKG-Analyse erfolgt die Beurteilung des Gesundheitszustandes unabhängig vom subjektiven Empfinden des Patienten. Trotzdem hat er weiterhin wie bei bereits etablierten Angeboten die Möglichkeit, mit seinen betreuenden Medizinern in Kontakt zu treten. Das Gefühl der stetigen Betreuung kann einen positiven psychologischen Effekt haben und damit die subjektive Lebensqualität des Patienten und in Folge dessen Leistungsfähigkeit und Compliance seine Behandlung betreffend steigern.
2. Die automatisch initiierte Datenübertragung kann, zusammen mit der Re-Analyse in der Zentralstation und in der Folge eingeleiteten Maßnahmen eine deutliche Therapieverbesserung oder im Extremfall sogar lebensrettende Funktion haben, z.B. bei einem Herzstillstand, der durch plötzlich auftretendes Kammerflimmern verursacht wird. In diesem Fall bleibt dem Patienten keine Zeit mehr, selbst eine Datenübertragung zu starten. Je nach Situation kann damit das Auffinden, die Alarmierung des Rettungsdienstes und die Einleitung lebenserhaltender Maßnahmen auf Grund des kurzen Zeitfensters bis zum Eintreten bleibender Schäden (siehe Kapitel 2.2.3) zu lange dauern, um das Überleben des Patienten zu sichern. Andere Parameter können für die frühzeitige Erkennung oder sogar Prävention von Myokardinfarkt und plötzlichem Herztod herangezogen werden. Durch früh einsetzende Therapien könnten so massive Erkrankungen verhindert werden.
3. Durch die mobile Überwachung kann sich der Patient ungebunden überall bewegen und läuft nicht Gefahr, z.B. bei Verlassen seiner Wohnung nicht mehr überwacht zu werden. Dadurch kann er stärker als bisher bei vorhandener Erkrankung am gesellschaftlichen Leben teilnehmen, was wiederum positive Effekte im Hinblick auf Lebensqualität, Rehabilitation, Pflegebedürftigkeit etc. hat.
4. Durch die zentrale Datenhaltung ist der Informationsaustausch zwischen verschiedenen am Behandlungsprozess beteiligten Personen bzw. Parteien erleichtert oder wird überhaupt erst möglich. Gerade bei Behandlungen an der Schnittstelle zwischen Klinik und niedergelassenen Ärzten in der integrierten Versorgung ist dies notwendig. Der Patient selbst wird sogar erst in einem solchen Szenario effektiv auf seine eigenen Daten zugreifen können. Dies ist gegenwärtig nicht oder nur sehr eingeschränkt möglich.

5. Auch im Bereich des Screenings kann das System eingesetzt werden. Werden relevante pathologische Störungen im EKG vor Ablauf der eigentlich vorgesehenen Applikationsdauer registriert, kann die Therapie unter Umständen schon mehrere Tage früher einsetzen. Auf diese Weise können aber auch mehr Patienten versorgt werden, da sich die effektive Tragedauer der Systeme verkürzt und die Geräte an andere Patienten weitergegeben werden können.

Diese Vorteile werden zunehmend erkannt. Aufbauend auf die in Kapitel 4.4 angeführten Projekte hat beispielsweise das Bundesministerium für Bildung und Forschung (BMBF) im Rahmenprogramm Mikrosysteme 2004-2009 einen eigenen Forschungsschwerpunkt „Präventive Mikromedizin“ ausgeschrieben, in dem seit Ende 2005 acht ausgewählte anwendungsnahe Forschungsprojekte gefördert werden [VI05].

### 5.2.2 Grenzen und Risiken des mobilen Online-Monitorings

Diesen Vorteilen stehen natürlich auch technische Risiken, organisatorische Hemmnisse und ungeklärte Fragen zur Finanzierung gegenüber. Für die praktische Einführung von mobilen Langzeit-Monitoring-Systemen mit automatischer Signalklassifikation ist sicherlich die Frage der Finanzierung die wichtigste. Gegenwärtig finden sich telemedizinische Dienstleistungen nur sehr eingeschränkt im Leistungskatalog der Kassen. Dies ist ein wesentlicher Grund für das Scheitern vieler telemedizinischer Anwendungen in Deutschland im Lauf der letzten Jahre (vgl. [Pie00]) und eines der wesentlichen Hindernisse bei der Entwicklung und Etablierung der notwendigen Systeme und Dienstleistungen. Hier sind dringende Verbesserungen der Rahmenbedingungen notwendig. Die avisierte Einführung der elektronischen Gesundheitskarte (eGK) im Jahr 2006 und das erklärte Ziel des Gesetzgebers, zunehmend telemedizinische Leistungen zu etablieren, lassen in dieser Hinsicht jedoch hoffen. Dennoch muss gezeigt werden, dass mit dem oben skizzierten Überwachungssystem eine effektive Reduzierung der Behandlungskosten erzielt werden kann. Da die erzielbaren Einsparungen stark vom verwendeten System abhängen und bisher noch keine gesicherten Erkenntnisse mit vergleichbaren Konzepten vorliegen, muss dieser Nachweis erst noch in Zukunft innerhalb von Pilotstudien erbracht werden.

Neben diesen finanziellen Aspekten gibt es noch organisatorische Fragen zu klären, die aber auch juristische und abrechnungstechnische Relevanz besitzen: Darf der behandelnde Arzt beispielsweise die Überwachung delegieren? Ist diese Delegation vergleichbar mit dem Auftrag von Laboranalysen oder erfordert der Vorgang eine formale Überweisung? Können zum gegenwärtigen Zeitpunkt im Notfall die richtigen Maßnahmen ergriffen werden? Sind z.B. eventuelle Fehlfahrten des Rettungsdienstes auf Grund falscher Alarmierung durch das Service-Center abrechenbar? Ist der Serviceanbieter für eventuell unterbliebene Übertragungen auf Grund einer Fehlklassifikation des Systems oder wegen einer fehlenden Netzverbindung haftbar, wenn daraus Gesundheitsschäden für den Patienten entstehen? Die Beantwortung dieser Fragen wird die Akzeptanz des Systems nachhaltig beeinflussen.

Zum Schluss sind die technischen Risiken zu beurteilen, die sich mit dem Einsatz des mobilen Systems ergeben. Die verwendeten Analyseverfahren werden eine gewisse

Fehlerquote aufweisen, d.h. es werden relevante Ereignisse nicht als solche erkannt werden und eine Übertragung daher nicht stattfinden, obwohl dies aus medizinischer Sicht notwendig wäre. Andererseits wird das System Fehlalarme auslösen, was zu einer erhöhten Belastung der Zentralstation, aber auch zu einem erhöhten Energiebedarf durch die Übertragung führt und sich damit negativ auf die Laufzeit des Systems auswirkt. Der wesentliche Faktor, der über Erfolg oder Misserfolg eines solchen Systems entscheidet, wird daher die Güte der Klassifikationsverfahren sein.

Zwar kann in Industriestaaten wie Deutschland von einer nahezu flächendeckenden Versorgung im Bereich der mobilen Telekommunikation ausgegangen werden, doch besonders in ländlichen Gebieten kann es vorkommen, dass keine Übertragung möglich ist. Dies ist insofern kritisch, da im Notfall eine schnelle Alarmierung durch die größeren Anfahrtswege besonders wertvoll wäre.

In Bezug auf das Mobilsystem sind besonders noch Fragen der Elektrodenapplikation im Fall von Langzeitanwendungen zu klären. Dies betrifft vor allem die Vermeidung oder Minimierung von Hautirritationen bei Verwendung oder die Unterdrückung von Bewegungsartefakten. Klebeelektroden führen zu geringen Bewegungsartefakten, sind aber für das Dauermonitoring nur bedingt geeignet. Trockene, evtl. in Kleidung integrierte Elektroden können über lange Zeit eingesetzt werden, sind aber sehr anfällig gegenüber Bewegungen. An dieser Problematik wird aber gegenwärtig intensiv gearbeitet [OKGS04].

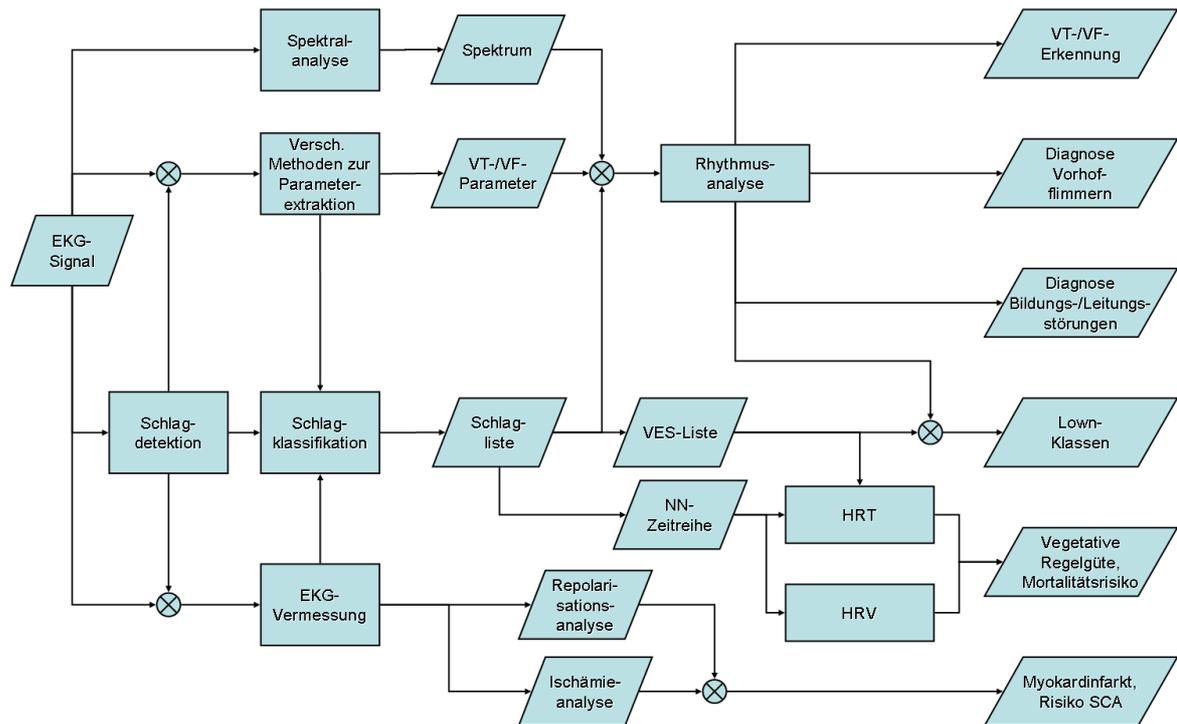
Ein weiterer Punkt ist die Datenübertragung zum Mobiltelefon und zur Zentralstation. Besonderes Augenmerk muss darauf gelegt werden, dass einerseits die für die Kommunikation verantwortliche Applikation auf dem Mobiltelefon nicht die normale Funktionsweise des Telefons beeinträchtigt, dieses andererseits aber ständig übertragungsbereit gehalten wird. Gegenwärtig gibt es immer wieder Probleme mit unterschiedlichen, teilweise fehlerhaften Implementierungen des Bluetooth<sup>®</sup>Stacks auf verschiedenen Mobiltelefonen, die die Entwicklung einer stabilen Applikation erschweren.

Ein weiterer technischer Aspekt, der unbedingt zu beachten ist, ist die Sicherheit der Patientendaten gegen Missbrauch. Daher müssen die Übertragungsstrecken, aber auch die Datenhaltung selbst effektiv geschützt werden.

## 5.3 Diagnostische Parameter für die mobile EKG-Überwachung

Abbildung 5.4 zeigt vereinfacht, auf welche Weise Diagnosen auf Grundlage des EKG-Signals erstellt werden können. Parallelogramme stellen die erhobenen Daten dar, Rechtecke bezeichnen die Prozesse bzw. die Anwendungen, mit deren Hilfe entweder neue Daten generiert werden oder medizinische Beurteilungen abgegeben werden. „SCA“ steht für *Sudden Cardiac Arrest* - plötzlicher Herztod.

Erster Schritt der EKG-Analyse ist die Schlagdetektion. Die detektierten QRS-Komplexe können dann vermessen werden oder bestimmte Parameter daraus extrahiert werden. Unabhängig von der Schlagdetektion können auch andere Parameter direkt aus dem EKG-Signal bestimmt werden. Eine spezielle Art der direkten Verarbeitung des EKG-Signals ist die Spektralanalyse, wobei hier nicht nur die klassische Fourier-



**Abbildung 5.4:** Veranschaulichung der Zusammenhänge zwischen dem EKG, den daraus extrahierten Parametern und deren Anwendungsbereichen bzw. den Diagnosen, die daraus abgeleitet werden können.

Transformation, sondern auch alternative Verfahren, z.B. aus dem Bereich der (nicht-)parametrischen Spektralschätzung gemeint sind. Die durch diese Schritte gewonnenen Informationen können in der Folge für die Schlagklassifikation eingesetzt werden. Die daraus gewonnene Schlagliste ist Grundlage für die weitere Beurteilung des EKGs: Die Anzahl der ventrikulären Extrasystolen und ihre Form dienen z.B. der Einordnung in die so genannten Lown-Klassen, wie sie in Tabelle 5.1 gezeigt sind. Das Spektrum und andere Parameter, die aus dem EKG-Signal oder daraus abgeleiteten Signalen berechnet werden können, können separat zur Detektion lebensgefährlicher Rhythmusstörungen eingesetzt werden. In Kombination mit der Schlagliste sind auch andere Diagnosen möglich, z.B. die Differentialdiagnostik von Erregungsbildungs- und Erregungsleitungsstörungen oder die Diagnose von Vorhofflimmern. Die Schlagliste bildet auch die Grundlage zur Berechnung von Parametern der Herzratenvariabilität (HRV) und Herzraturbulenz (HRT) (siehe Kapitel 2.3.1 und 2.3.2).

Durch Vermessung des EKG-Signals ist es möglich, Änderungen des QT-Intervalls und der ST-Strecke zu protokollieren. Eine verlängerte QT-Strecke kann auf Störungen der Repolarisation des Herzmuskels hindeuten und ist ein Risikofaktor für das Auftreten von Reentry-Phänomenen. Veränderungen der ST-Strecke sind Anzeichen von Ischämie im Herzmuskel und mithin Indiz für einen Myokard-Infarkt.

**Tabelle 5.1:** Klassifizierung ventrikulärer Rhythmusstörungen nach Lown und Wolf: Häufigkeit, aus der Morphologie ableitbarer Entstehungsort und zeitliches Auftreten relativ zu den Normalschlägen von ventrikulären Extrasystolen (VES) bilden die Grundlage für die Beurteilung der Schwere ventrikulärer Erregungsbildungsstörungen. Die Klassen 3 bis 5 sind prognostisch ernster zu bewerten [GH99]

Lown-Klasse	Auftreten von VES
0	keine VES
1	gelegentliche isolierte monomorphe (uniforme) VES (<30/h)
2	häufige monomorphe VES (>1/min oder >30/h)
3a 3b	polymorphe (multiforme) VES Bigeminus
4 4a 4b	repetitive VES: Paarbildung, Couplet Salve von mindestens drei konsekutiven VES, ventrikuläre Tachykardie
5	frühzeitige VES mit R-auf-T-Phänomen

## 5.4 Konsequenzen für die Online-Klassifikation

Aus dem vorigen Kapitel lassen sich verschiedene Anforderungen für die EKG-Signalverarbeitung und -Klassifikation in einem mobilen System ableiten. Diese werden ergänzt durch praktische Anforderungen des Dauermonitorings bzw. limitiert durch technische und medizinische Grenzen des Aufnahmesystems. Die letztendlich daraus formulierbaren Anforderungen bilden die Grundlage für die vorliegende Arbeit.

### Verwendete Ableitungen

Bisher sind im Bereich der Langzeit-EKG-Auswertung zwei bis drei Ableitungskanäle üblich. Aus Gründen der Applikationssicherheit, der Rechenleistung des Mobilsystems und der verfügbaren Bandbreite zur Übertragung der EKG-Daten wird sich die Zahl der Kanäle nicht deutlich steigern lassen. Dabei werden von den herkömmlichen Ableitungen (Einthoven, Goldberger, Wilson) von Fall zu Fall unterschiedliche Kombinationen verwendet, so dass keine wirklich festen Ableitungskonfigurationen vorgegeben werden können. Meist wird eine Einthoven-Ableitung in Kombination mit einer oder zwei Wilson-Ableitungen verwendet. Auch modifizierte Ableitungen sind möglich.

Die Auswertung und Übertragung eines 12-Kanal-EKGs ist nur unter Verwendung einer vektorkardiographischen Ableitung (Frank oder EASI) denkbar. Auf Grund der Elektrodenanzahl wären in diesem Fall eindeutig die EASI-Leads zu bevorzugen. In beiden Fällen ist aber zu beachten, dass das 12-Kanal-EKG nur berechnet werden kann, was zu Verfälschungen des Signals führt. Dies ist bei der weiteren Diagnose zu beachten, so dass Verfahren zur Beurteilung von klinisch abgeleiteten 12-Kanal-EKGs eventuell

versagen könnten. Auf dem Mobilsystem hingegen sollte von einer internen Umrechnung der vektorkardiographischen Kanäle aus Kostengründen abgesehen werden. Leider sind kaum oder gar keine Datensätze mit Frank- oder EASI-Ableitungen zugänglich, die als Referenz während des Entwicklungsverlaufs verwendet werden könnten. In Europa kommt hinzu, dass diese beiden Ableitungskonfigurationen sehr wenig verwendet werden.

Als Fazit kann formuliert werden, dass das Mobilsystem in der Lage sein sollte, zwei bis drei EKG-Kanäle in Echtzeit zu klassifizieren. Als EKG-Kanäle kommen dabei sowohl Einthoven- als auch Wilson-Ableitungen in Betracht, wobei sich dies nicht von vornherein sagen lässt. Das Klassifikationssystem sollte daher möglichst unabhängig von der aktuell verwendeten Ableitung arbeiten können.

### **Schlagdetektion**

Die Schlagdetektion sollte multikanalfähig und möglichst wenig störanfällig sein. Insbesondere Bewegungsartefakte und schlechte Signal-Rausch-Verhältnisse in einer Minderzahl der Kanäle sollte die Detektion möglichst wenig negativ beeinflussen. Die Detektion sollte robust gegenüber Amplituden- und Polaritätswechseln, sowie Nullliniendrift sein. Unterschiedliche und wechselnde QRS-Morphologien sollten keine negativen Auswirkungen auf die Detektion haben. Spikes im EKG, die durch Schrittmacherimpulse verursacht werden, sollten durch hardwarebasierte Detektoren detektiert werden. Diese Information kann dann bei der weiteren Signalverarbeitung berücksichtigt werden. Die Anforderungen an Sensitivität und positive Prädiktivität sind sehr hoch, da bereits bei einer Fehlerquote von 1% im Laufe von 24 Stunden ca. 1000 Schläge falsch klassifiziert werden.

### **Schlagklassifikation**

Die Schlagklassifikation muss in der Lage sein, zumindest QRS-Komplexe mit supraventrikulärem und ventrikulärem Ursprung zu differenzieren. In [ans], [ans98] und [en602] (siehe Anhang A.2) werden darüber hinaus noch Schlagklassen für supraventrikuläre Extrasystolen, Fusionsschläge und schrittmacherinduzierte Schläge eingeführt. Um mit diesen Standards konform zu sein, sollte das System nach Möglichkeit ebenfalls in diese Schlagklassen klassifizieren. Auf Grundlage der Schlagklassifikation und der daraus erstellten Schlagliste sind weitere rhythmologische Betrachtungen, insbesondere die Identifikation von Vorhofflimmern, möglich. Für die Diagnose von Leitungsstörungen ist darüber hinaus zusätzlicher Aufwand notwendig. Während ventrikuläre Leitungsstörungen durch Begutachtung der QRS-Morphologie identifiziert werden könnten, ist für die Erkennung supraventrikulärer und atrioventrikulärer Leitungsstörungen die zusätzliche Detektion und Vermessung der P-Welle notwendig. Dies ist im ambulanten Umfeld nur schwer mit der notwendigen Güte möglich. Daher steht hier die Erkennung ventrikulärer Leitungsstörungen im Vordergrund.

### **Erkennung lebensbedrohlicher ventrikulärer Rhythmusstörungen**

In Deutschland erleiden pro Jahr ca. 120.000 Menschen einen plötzlichen Herzstillstand, dem zumeist eine ventrikuläre Tachykardie (VT) oder Kammerflimmern (VF) zu Grun-

de liegt [RSBL02]. Bei 70% der Betroffenen ist eine kardiale Vorerkrankung bekannt, so dass sie direkt zur Zielgruppe des neuen Systems gehören. Damit ist klar, dass das System in der Lage sein muss, eine VT/VF zu erkennen und daraufhin einen Alarm auszulösen. Der Schwerpunkt liegt dabei weniger in der Erkennung der genauen Grenzen (Anfang und Ende von VT/VF), sondern in dem Vorliegen einer solchen Rhythmusstörung unter der Nebenbedingung, dass diese möglichst schnell nach ihrem Einsetzen erkannt werden soll. Weiterhin ist wichtig, dass möglichst alle solcher Episoden erkannt werden. Auf Grund der potenziellen Schwere der Komplikation erscheint hier eine höhere Quote von falsch positiven Alarmen akzeptabel.

### Vegetative Regelgüte

Zur Bestimmung der HRT-Parameter Turbulence Onset und Turbulence Slope steht ein genaues Protokoll zur Verfügung [SMB<sup>+</sup>99], so dass eine Implementierung sehr einfach ist. Voraussetzung ist natürlich eine Schlagliste hoher Qualität. Da die Bestimmung der Parameter nur im Einzelfall erfolgt, sind die Kosten für die Rechenzeit als niedrig anzusetzen, so dass die Berechnung ohne Probleme auf dem Mobilsystem durchgeführt werden können sollte. Einziges Problem ist die Interpretation der erhaltenen Werte, insbesondere die Einführung von Alarmschwellen, falls sich diese im Laufe der Zeit ändern, da hier noch wenig medizinische Erfahrungen vorliegen.

Im Bereich der HRV existieren eine Vielzahl von Parametern. Leider gibt es praktisch keine verlässlichen Normwerte, da die als physiologisch angegebenen Werte stark von den Aufzeichnungsgegebenheiten und der körperlichen Belastung abhängen [Tas96]. Es ist also extrem schwierig, auf Grundlage von HRV-Parametern ohne weitere Kontextinformation eine „eingeschränkte HRV“ zu diagnostizieren und Alarmschwellen festzulegen. Auf Grund des geringen Rechenaufwands erscheint es noch am sinnvollsten, einfache Zeitbereichsparameter der HRV wie SDNN, pNN50, RMSSD oder SDSD (siehe [Tas96] für eine Erläuterung dieser Parameter) zu verwenden. Diese werden von vielen Langzeit-EKG-Systemen am Markt im Rahmen der Offline-Analyse ebenfalls berechnet, wobei die Interpretation immer dem Arzt obliegt. Die Verwendung des HRV-Spektrums erscheint nicht sinnvoll, da zum einen der Rechenaufwand hoch, zum anderen die Aussagequalität zweifelhaft ist (siehe bspw. [SWH<sup>+</sup>05]).

### Repolarisation und Ischämieanalyse

Die genaue Analyse des QT-Intervalls ist stark abhängig von der exakten Lokalisierung des QRS-Beginns und des Endes der T-Welle. Durch die bei ambulanten EKGs auftretenden Störungen wird eine exakte Lokalisation erschwert. Hinzu kommen Unklarheiten in der medizinischen Interpretation der QT-Dauer, auch in ihrer herzfrequenzkorrigierten Form  $QT_c$ . Insgesamt erscheint dieser Parameter schlecht geeignet für den Einsatz in der mobilen Analyse. Für etwaige Nachanalysen, routinemäßige Kontrollen oder Kontrollen für Herzmedikamente, bei denen der Nachweis erbracht werden muss, dass sie das QT-Intervall nicht verlängern, sollte er aber in Betracht gezogen werden. Diese Analysen können jedoch auch offline gemacht werden.

Bei der Ischämiebeurteilung durch Beobachtung der ST-Strecke muss berücksichtigt werden, dass die klinische Diagnose eines Myokardinfarkts nur auf Grund eines 12-

Kanal-EKGs erfolgen kann. Ambulante Untersuchungen der ST-Strecke auf zwei oder drei Kanälen können daher nur grobe Indizien für das Vorliegen einer Ischämie liefern. Daher sollte eine aufwendige Analyse auf dem Mobilsystem eher unterbleiben und auf die standardmäßige Bestimmung der ST-Abweichung und der ST-Steigung beschränkt werden.

# 6 Signalklassifikation mit Neuro-Fuzzy-Systemen

## 6.1 Grundlagen neuronaler Netze

Die Entwicklung künstlicher Neuronaler Netze (kNN) ist durch die Art der Informations- und Reizverarbeitung in biologischen Nervensystemen motiviert. Für die Analogie zwischen biologischen und künstlichen neuronalen Netzen sei auf die Vielzahl einschlägiger Fachliteratur verwiesen [BKKN03], [Bot98], [ZLRT98]. Die Darstellung der Grundlagen in dieser Arbeit folgt im Wesentlichen der in [BKKN03].

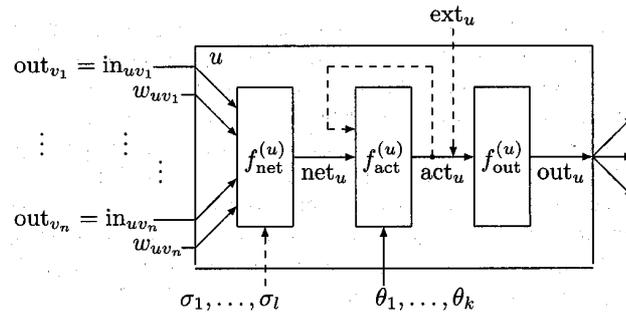
### 6.1.1 Grundbegriffe

Ein kNN ist ein gerichteter Graph mit einer Menge von Knoten  $U$ , die durch eine Menge von Kanten  $C$  miteinander verbunden sind. Ein kNN besitzt einen mehrschichtigen Aufbau, wobei zwischen der Schicht der Eingabeknoten  $U_{in}$  und der Ausgabeschicht mit den Knoten  $U_{out}$  eine oder mehrere versteckte Schichten (engl. *hidden layers*) von Knoten  $U_{hidden}$  liegen können. Ein- und Ausgabeschicht agieren mit der „Umwelt“ des Netzes, wobei Neuronen sowohl der Ein- als auch der Ausgabeschicht angehören können. Jedes Neuron besitzt drei Zustandsgrößen:

1. die Netzeingabe  $net_u$ ,
2. die Aktivierung  $act_u$ ,
3. die Ausgabe  $out_u$ .

Neuronen der Eingangsschicht besitzen darüber hinaus noch die Zustandsgröße  $ext_u$ , deren Gesamtmenge für alle  $u \in U_{in}$  die externen Eingaben in das Neuronale Netz darstellen. Für die Verarbeitung der „Reize“ in den einzelnen Neuronen stehen drei verschiedene Funktionen zur Verfügung:

1. die Netzeingabefunktion  $f_{net}^{(u)}$ , mit der die Ausgaben der Vorgängerneuronen zur Netzeingabe  $net_u$  verarbeitet werden,
2. die Aktivierungsfunktion  $f_{act}^{(u)}$ , die die Eingangsgröße  $net_u$  zur Aktivierung  $act_u$  weiterverarbeitet,
3. die Ausgabefunktion  $f_{out}^{(u)}$ , die  $act_u$  schließlich in die Ausgabe  $out_u$  umsetzt.



**Abbildung 6.1:** Darstellung eines allgemeinen Neurons (entnommen aus [BKKN03]).

Netzeingabe- und Aktivierungsfunktion sind zusätzlich parametrisierbar. Die Kanten des Neuronalen Netzes können zusätzlich durch Gewichte  $w_{ij}$  Einfluss auf die Netzeingabe eines Neurons nehmen. Insgesamt ergibt sich die Darstellung eines verallgemeinerten Neurons nach Abbildung 6.1.

Unter der Topologie oder Netzstruktur eines kNN versteht man die quadratische Matrix

$$W = \begin{pmatrix} w_{u_1u_1} & w_{u_1u_2} & \dots & w_{u_1u_r} \\ w_{u_2u_1} & w_{u_2u_2} & \dots & w_{u_2u_r} \\ \vdots & & \vdots & \\ w_{u_ru_1} & w_{u_ru_2} & \dots & w_{u_ru_r} \end{pmatrix} \quad (6.1)$$

aller Verbindungsgewichte  $w_{u_iu_j}$ , die angibt, welcher Knoten mit welchem verbunden ist. Knoten können dabei auch auf sich selbst verweisen (Diagonalelemente der Matrix). Existiert keine Verbindung zwischen den Knoten, so ist das Kantengewicht 0. Im Allgemeinen gilt  $w_{u_iu_j} \neq w_{u_ju_i}$ , da es sich um einen gerichteten Graphen handelt.

Besitzt der Graph keine Schleifen, ist er also azyklisch, so nennt man das Netz vorwärtsbetrieben (engl. *feed forward network*). Verweist ein Knoten (indirekt) auf einen seiner Vorgänger, so ist das Netz rückgekoppelt (engl. *recurrent network*). In einem rückgekoppelten Netz kann es abhängig von der Reihenfolge der Berechnung der einzelnen Funktionen in den Neuronen zu unterschiedlichen Ausgaben kommen, während sich ein vorwärtsbetriebenes Netz in dieser Hinsicht deutlich einfacher verhält, weil dort die Berechnung gemäß der topologischen Ordnung des Graphen erfolgen kann.

### 6.1.2 Training Neuronaler Netze

Durch Veränderung der Kantengewichte in  $W$  oder der Parameter der Funktionen  $f_{net}^{(u)}$  und  $f_{act}^{(u)}$  können die Ausgaben eines kNN beeinflusst werden. Auf diese Weise ist die Anpassung eines Neuronalen Netzes an bestimmte Klassifikationsaufgaben möglich. Für das Training unterscheidet man zwischen festen und freien Lernaufgaben. Bei einer festen Lernaufgabe soll das Netz eine Menge von Eingangsvektoren  $\vec{i}^{(l)}$  möglichst genau auf eine Menge von Ausgängen  $\vec{o}^{(l)}$  abbilden. Die Menge  $l = (\vec{i}^{(l)}, \vec{o}^{(l)})$  beinhaltet die für das Training verwendeten Lernmuster. Als Abbruchkriterium verwendet man entweder die Anzahl der Trainingszyklen oder einen zu erreichenden Mindestfehler bei der Zuord-

nung der Lernmuster. Bei freien Lernaufgaben soll das Netz so trainiert werden, dass es für ähnliche Eingangsvektoren ähnliche Ausgaben erzeugt. Ein Beispiel für eine freie Lernaufgabe ist die Definition von Clustern in Daten, also die Zusammenfassung von Vektoren in Gruppen. Die „Ähnlichkeit“ der Vektoren innerhalb eines Clusters kann als ein mögliches Abbruchkriterium dienen, eine andere Möglichkeit wäre die Vorgabe der Anzahl von Gruppen und ein Mindestanteil von zugeordneten Eingangsvektoren.

Bei den Klassifikationen im Rahmen dieser Arbeit handelt es sich um feste Lernaufgaben, bei denen auf unterschiedliche Weise gewonnene Eingangsvektoren einer festen Referenzklasse zugeordnet werden.

Für das Training können verschiedene Strategien angewendet werden, deren Beschreibung an dieser Stelle zu weit führen würde. Auch hier sei auf die einschlägige Fachliteratur verwiesen. Die von den im Rahmen dieser Arbeit verwendeten Verfahren implementierten Strategien sind genauer in den Kapiteln 6.5.1 bis 6.5.3 beschrieben.

## 6.2 Grundlagen der Fuzzy-Logik

Die Theoriebildung für unscharfe Mengen erfolgte ab 1965, zu Beginn v.a. durch L. A. Zadeh, der seinen Grundlagenartikel [Zad65] in diesem Jahr veröffentlichte. Es dauerte aber noch bis Mitte der 1980er, Anfang der 1990er Jahre, bevor die ersten Anwendungen für diese Theorie entwickelt wurden und in industriellen Produkten zum Einsatz kamen. Seitdem aber nimmt die Bandbreite von Applikationen stark zu. Ein favorisierter Einsatzbereich für Fuzzy-Logic ist die Regelungstechnik, da hier für physikalische Sachverhalte und Systeme, die nur schwer oder nicht geschlossen modellierbar sind, relativ einfache Reglerstrukturen entworfen werden können. Ein weiterer Vorteil ist die linguistische Problemformulierung, die den Zugang zu Expertenwissen stark vereinfacht. Dies spielt auch bei den in dieser Arbeit behandelten Klassifikationsaufgaben eine wichtige Rolle.

Um in der Folge unscharfe von scharfen Mengen zu unterscheiden, werden unscharfe oder Fuzzy-Mengen mit Buchstaben  $A, B, C, \dots$  bezeichnet, scharfe oder Boolesche Mengen dagegen mit Buchstaben  $\mathcal{A}, \mathcal{B}, \mathcal{C}, \dots$ . Zugehörigkeitsfunktionen unscharfer Mengen werden mit  $\mu_A, \mu_B, \mu_C, \dots$  gekennzeichnet, die scharfer Mengen mit  $\mu_{\mathcal{A}}, \mu_{\mathcal{B}}, \mu_{\mathcal{C}}, \dots$

### 6.2.1 Grundbegriffe

In Anlehnung an [BG93] und [Bot98] werden zunächst einige wichtige Grundbegriffe vorgestellt und erklärt.

Eine unscharfe Menge  $A$  wird repräsentiert durch eine *Zugehörigkeitsfunktion*  $\mu_A$ , die eine Abbildung eines Grundbereichs  $\mathcal{X}$  auf das Intervall  $[0, 1]$  darstellt.

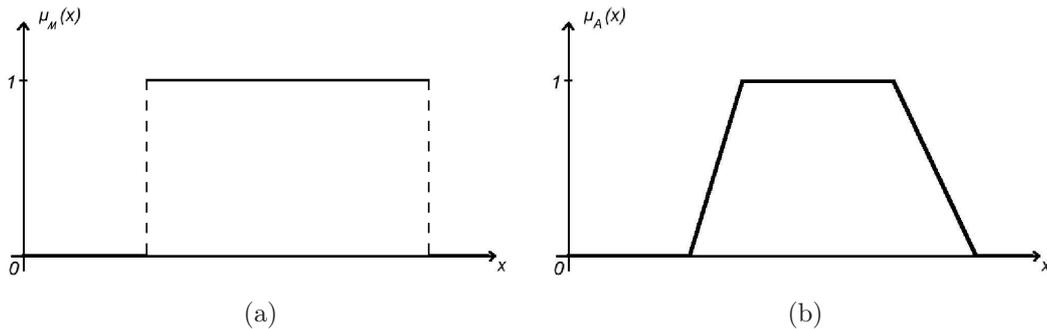
$$\mu_A : \quad \mathcal{X} \longrightarrow [0, 1] \quad (6.2)$$

Die Werte  $x$  des Grundbereichs  $\mathcal{X}$  können dabei kontinuierlich oder diskret sein. Eine scharfe Menge  $\mathcal{M}$  ist unter diesem Gesichtspunkt als ein Spezialfall der unscharfen

Mengen anzusehen, nämlich:

$$\mu_{\mathcal{M}}(x) = \begin{cases} 1 & , \text{ falls } x \in \mathcal{M} \\ 0 & , \text{ sonst} \end{cases} . \quad (6.3)$$

Beispiele für Zugehörigkeitsfunktionen scharfer und unscharfer Mengen zeigen die Abbildungen 6.2(a) bzw. 6.2(b). Grundsätzlich lassen sich für unscharfe Mengen die gleichen Begriffe und Beziehungen definieren wie für herkömmliche Mengen aus der Booleschen Algebra. Hier sollen nun einige elementare Begriffe und Beziehungen erläutert werden.



**Abbildung 6.2:** Zugehörigkeitsfunktionen scharfer und unscharfer Mengen. Die Abbildung (a) zeigt eine scharfe Zugehörigkeitsfunktion, die die Form einer Sprungfunktion besitzt. Abbildung (b) zeigt die Zugehörigkeitsfunktion einer unscharfen Menge  $A$  in Trapezform.

Zwei unscharfe Mengen  $A$  und  $B$  heißen gleich, wenn für ihre Zugehörigkeitsfunktionen gilt:

$$A = B \iff \mu_A(x) = \mu_B(x) \quad \forall x \in \mathcal{X}. \quad (6.4)$$

Die Stützmenge  $\mathcal{S}(A)$  einer unscharfen Menge  $A$  ist die scharfe Menge aller Elemente  $x$  aus dem Grundbereich, für die der Wert der Zugehörigkeitsfunktion  $\mu_A(x)$  größer als Null ist, also:

$$\mathcal{S}(A) = \{x \in \mathcal{X} \mid \mu_A(x) > 0\} \quad (6.5)$$

Ein Alpha-Schnitt (oder  $\alpha$ -Schnitt) von  $A$  ist eine scharfe Menge aus Elementen  $x$  des Grundbereichs, deren Zugehörigkeitsgrad größer als oder gleich  $\alpha$  ist:

$$\mathcal{A}_\alpha = \{x \in \mathcal{X} \mid \mu_A(x) \geq \alpha\} \quad (6.6)$$

Üblicherweise sind die verwendeten Zugehörigkeitsfunktionen normalisiert, d.h. die Höhe von  $\mu_A(x)$  ist

$$\text{hgt}(A) = \sup\{\mu_A(x)\} \equiv 1. \quad (6.7)$$

Es können jedoch auch subnormale unscharfe Mengen auftreten.

Mit Kardinalität oder Mächtigkeit einer unscharfen Menge  $A$  bezeichnet man im diskreten Fall die Summe, im kontinuierlichen Fall das Integral über die Zugehörig-

keitswerte  $\mu_A(x)$ , also

$$\text{card}(A) = \sum_{x \in \mathcal{X}} \mu_A(x) \quad \vee \quad \text{card}(A) = \int_{\mathcal{X}} \mu_A(x) dx. \quad (6.8)$$

Die relative Kardinalität ist die absolute Kardinalität bezogen auf die Mächtigkeit des Grundbereichs  $\mathcal{X}$

$$\text{card}(A) = \frac{\sum_{x \in \mathcal{X}} \mu_A(x)}{\sum_{x \in \mathcal{X}} 1} \quad \vee \quad \text{card}(A) = \frac{\int_{\mathcal{X}} \mu_A(x) dx}{\int_{\mathcal{X}} dx}. \quad (6.9)$$

## 6.2.2 Nutzung von Expertenwissen

Neben diesen formalen Begriffen gibt es noch Termini, die den problemorientierten Ansatz der Fuzzy-Theorie besser zum Ausdruck bringen. Steht bei der "traditionellen" Entwicklungsarbeit die Modellbildung - also der bestmögliche Kompromiss zwischen physikalischer Realität und ihrer idealisierten Beschreibung - im Vordergrund, so wird bei der Fuzzy-Theorie zunächst eine Problembeschreibung durch Expertenwissen vorgenommen. Ein Beispiel dafür ist die Beurteilung, ob ein QRS-Komplex eine ventrikuläre Extrasystole darstellt, an Hand seiner Breite. Laut [GH99] ist der QRS-Komplex in einem solchen Fall „(oft weit) über 0,12s verbreitert“. Die Einführung einer scharfen Grenze zur Beurteilung, ob eine VES vorliegt oder nicht, würde zu vielen Fehleinschätzungen führen, selbst wenn man noch weitere Parameter zur Beurteilung heranziehen würde, da eine nur leicht geringere Breite des QRS-Komplexes zur Klassifikation „keine VES“ führen würde.

Für die Problembeschreibung werden sogenannte linguistische Variablen verwendet, die jeweils einen Grundbereich bilden. Diese können Größen bzw. Messwerte wie „QRS-Breite“ oder „QRS-Amplitude“ sein, jedoch auch beschreibende Größen wie „Herzrhythmus“ oder „relative Breite“. Diese letzten Variablen sind für den Menschen leicht zu formulieren und zu verstehen, in einem traditionellen technischen Prozess aber schwierig zu integrieren. Für die linguistischen Variablen werden zugehörige linguistische Terme gebildet, die diese Variable beschreiben oder einteilen. Beispiele dafür sind für die QRS-Breite Begriffe wie „schmal“, „breit“ oder „sehr breit“ oder für die linguistische Variable „Herzrhythmus“ die Termdefinitionen „normal“, „ventrikulär gestört“ oder „defibrillationspflichtig“. Der beschreibende Charakter dieser linguistischen Terme liegt dabei in den mit ihnen assoziierten Zugehörigkeitsfunktionen über dem von den linguistischen Variablen gebildeten Grundbereich. Für eine gute Problembeschreibung ist zunächst die sinnvolle Auswahl von linguistischen Variablen notwendig. Hierfür und für die Erstellung der Zugehörigkeitsfunktionen ist der Zugang zu Expertenwissen wichtig, der aber durch den verbalen Charakter der Beschreibungsweise stark vereinfacht wird. Die dritte Komponente der Nutzung von Expertenwissen ist die Verknüpfung ausgewählter linguistischer Terme von verschiedenen linguistischen Variablen zu sinnvollen Regeln mit entsprechenden Folgerungen, die so genannte Inferenzbildung (siehe Kapitel 6.2.4).

### 6.2.3 Operationen auf Fuzzy-Mengen

Genauso wie bei Booleschen Mengen lassen sich bei unscharfen Mengen Operationen wie Durchschnitt, Vereinigung und Komplement vornehmen. Ebenso lassen sich Rechengesetze wie Kommutativität, Assoziativität, Distributivität, Idempotenz und Monotonie herleiten. Die Tabellen 6.1 und 6.2 zeigen die entsprechenden Definitionen.

**Tabelle 6.1:** Fuzzy-Operationen: Operationsdefinitionen für unscharfe Mengen. Diese Operationen wurden bereits von Zadeh definiert und sind hier aus [BG93] entnommen.

Name	Schreibweise	Definition ( $\forall x \in \mathcal{X}$ )
Vereinigung	$C := A \cup B$	$\mu_C(x) = \max\{\mu_A(x), \mu_B(x)\}$
Durchschnitt	$D := A \cap B$	$\mu_D(x) = \min\{\mu_A(x), \mu_B(x)\}$
Komplement	$K := A^C$	$\mu_K(x) = 1 - \mu_A(x)$

**Tabelle 6.2:** Fuzzy-Rechengesetze. Zadeh formulierte ebenfalls die für Boolesche Mengen geltenden Rechengesetze für unscharfe Mengen um. Diese Definitionen sind wiederum [BG93] entnommen.

Name	Vorschrift
Kommutativität	$A \cup B = B \cup A$
Assoziativität	$A \cup (B \cup C) = (A \cup B) \cup C$
Distributivität	$A \cup (B \cap C) = (A \cup B) \cap (A \cup C)$ $A \cap (B \cup C) = (A \cap B) \cup (A \cap C)$
Idempotenz	$A \cup A = A$
Monotonie	$A \subseteq B \Rightarrow A \cup C \subseteq B \cup C$

Erwähnenswert ist dabei noch, dass die Komplementarität für Durchschnitt und Vereinigung unscharfer Mengen im Allgemeinen nicht gilt:

$$A \cap A^C \neq \emptyset \quad \text{und} \quad A \cup A^C \neq \mathcal{X}. \quad (6.10)$$

Als Schreibweise für die Verknüpfung zweier linguistischer Terme hat sich das logische UND ( $\wedge$ ) für die Durchschnittsbildung und das logische ODER ( $\vee$ ) für die Vereinigungsoperation durchgesetzt. Klar ist bei diesen einfachen Operationen, dass keine Zugehörigkeitswerte zwischen  $\mu_A$  und  $\mu_B$  eingenommen werden können, also keine Kompensation von extremen Zugehörigkeitswerten vorgenommen werden kann. Darum wurden im Laufe der Zeit alternative Operationen wie das algebraische, beschränkte und drastische Produkt oder die algebraische, beschränkte und drastische Summenbildung definiert. Ebenso gibt es andere arithmetische Verknüpfungen wie Summe, Differenz, Produkt und Quotient aus verschiedenen unscharfen Mengen. Näheres dazu ist in [BG93] und [Bot98] zu finden. Für die in dieser Arbeit vorgestellten Anwendungen

sind jedoch die in Tabelle 6.1 aufgeführten - auch Fuzzy-Operatoren genannten - Typen ausreichend.

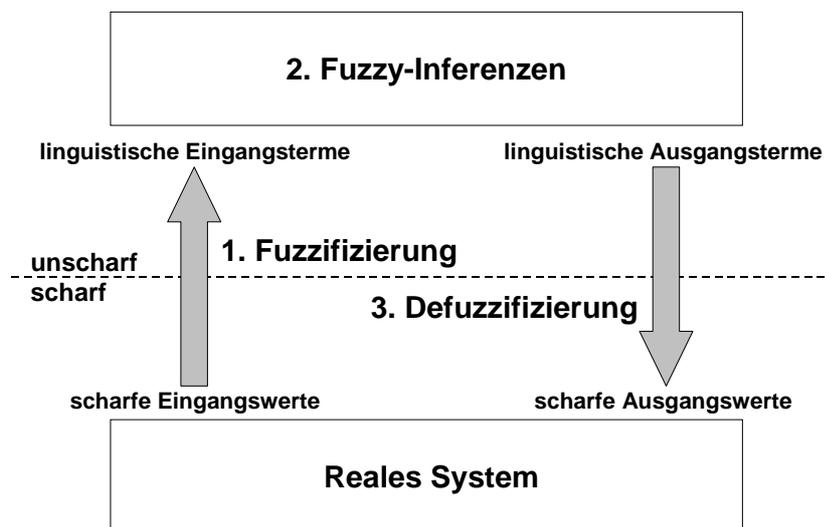
Um doch eine Kompensationsmöglichkeit zu haben, ist die einfache Lösung denkbar, dass die Regeln an sich gewichtet werden. Damit teilt man im Prinzip einen Grad zu, zu dem diese Regel gültig ist; „0“ entspräche dann dem Grad „überhaupt nicht gültig“, „1“ dem Grad „vollständig gültig“. Die mathematisch korrekte Formulierungsweise dafür ist

$$\begin{aligned} \mu_{\delta, A \wedge B}(x) &= \delta \cdot (\mu_A(x) \wedge \mu_B(x)) \\ \text{bzw. } \mu_{\delta, A \vee B}(x) &= \delta \cdot (\mu_A(x) \vee \mu_B(x)) \quad \text{mit } \delta \in [0, 1]. \end{aligned} \quad (6.11)$$

Dieser Ansatz führt aber zu verschiedenen Problemen bezüglich der Interpretierbarkeit der Regelbasis [BKKN03].

## 6.2.4 Aufbau eines Fuzzy-Systems

Charakteristisch für ein Fuzzy-System ist sein Aufbau aus drei Funktionsstufen, die Abbildung 6.3 zeigt.



**Abbildung 6.3:** Prinzipieller Aufbau eines Fuzzy-Systems mit den drei charakteristischen Arbeitsstufen Fuzzifizierung, Inferenzenbildung und Defuzzifizierung.

Der erste Schritt ist die Fuzzifizierung oder Fuzzifikation eines scharfen Eingangswerts anhand der für diese linguistische Variablen definierten Zugehörigkeitsfunktionen  $\mu(x)$ . Ergebnis sind Werte für die einzelnen linguistischen Terme der linguistischen Variablen oder anschaulicher gesprochen: Für den Eingangswert  $x \in \mathcal{X}$  wird das Maß seiner Zugehörigkeit zu den verschiedenen Zugehörigkeitsfunktionen bestimmt.

In der zweiten Stufe des Fuzzy-Systems werden Inferenzen ausgewertet, die durch die Verknüpfung verschiedener linguistischer Terme gebildet wurden. Die Inferenzen werden dabei als Regeln (Prämissen) formuliert, die zunächst einen führenden Konditionalteil (Antezedens) beinhalten, dem ein Konsequenzenteil (Konsequens) folgt. Eine prägnante verbale Formulierung ist wie bereits schon in Kapitel 6.2.2 angesprochen:

IF <Konditionalteil> THEN <Konsequenzenteil>.

Beispielsweise könnte eine Regel zur Beschreibung einer VES dann folgendermaßen lauten:

IF QRS-Breite ist *breit* AND RR-Intervall ist *klein* AND QRS-Komplex ist *stumpf* THEN ventr. Extrasystole

Im Konditionalteil werden die linguistischen Terme mit den in Kapitel 6.2.3 aufgeführten Fuzzy-Operatoren verknüpft und auf einen neuen linguistischen Term abgebildet. In der so genannten normalisierten Darstellung können nur zwei linguistische Terme auf einmal miteinander verknüpft werden. Soll eine Inferenz nach dem Muster

IF  $A = a$  OR  $B = b$  THEN  $C$

ausgewertet werden, so muss sie in die zwei Teilregeln

IF  $A = a$  THEN  $C$

IF  $B = b$  THEN  $C$

zerlegt werden. Diese werden dann nacheinander ausgewertet und schließlich mit dem ODER-Operator verknüpft.

Der letzte Schritt innerhalb eines Fuzzy-Systems ist die Rückübersetzung der durch Auswertung aller formulierten Regeln gewonnenen Ausgangsterme, wie z.B. Reglerstellungen, Verstärkungsfaktoren oder Klassifikationsergebnisse. Diesen Schritt nennt man Defuzzifikation oder Defuzzifizierung und kann mit Hilfe verschiedener Methoden vorgenommen werden [Bot98]. Bei Klassifikationsaufgaben ist der Ausgaberaum in scharfe Mengen aufgeteilt, so dass in der vorliegenden Arbeit die Max-Defuzzifikations-Methode (MAX) verwendet wird.

## 6.3 Neuro-Fuzzy-Systeme

Für Neuronale Netze gibt es zahlreiche Methoden, um sie für bestimmte Einsatzzwecke zu optimieren. Je nach gewählter Netzstruktur und Funktionen der Netzknoten ist jedoch eine Beurteilung kaum mehr möglich, auf welche Art und Weise das Ergebnis für einen bestimmten Eingangsvektor zustande kam; das System ist für den Nutzer intransparent und nicht interpretierbar. Vorwissen kann nicht zur Initialisierung des Netzes verwendet werden, eine ungünstige Wahl der Netzparameter kann das Ergebnis stark (negativ) beeinflussen. Anpassungen des Systems an eine veränderte Problemstruktur sind sehr aufwendig [BKKN03].

Bei Fuzzy-Systemen ist oft das notwendige Wissen für eine linguistische Regelbasis zur Lösung des gegebenen Problems vorhanden. Diese Regelbasis ist vergleichsweise transparent und interpretierbar. Die Schwierigkeit bei Fuzzy-Systemen besteht dagegen in der Optimierung der Zugehörigkeitsfunktionen und gegebenenfalls der Regelbasis, für die keine formalen Methoden existieren [BKKN03].

Durch die Kombination beider Ansätze in so genannten Neuro-Fuzzy-Systemen lassen sich die Stärken beider Verfahren nutzen: Es entsteht ein interpretierbares System,

das in der Lage ist, durch entsprechendes Lernen ein „optimales“ Ergebnis zu liefern. Der Lernprozess kann sich dabei auch auf die Regelbasis selbst erstrecken, d.h. das Neuro-Fuzzy-System erstellt an Hand der Lernmuster und vorläufig definierten Zugehörigkeitsfunktionen selbständig geeignete Regeln oder optimiert ein vorhandenes Regelwerk durch Entfernen oder Ergänzen von Regeln. Zweiter Teil des Lernprozesses ist die Optimierung der Zugehörigkeitsfunktionen, meist durch Parametrisierung.

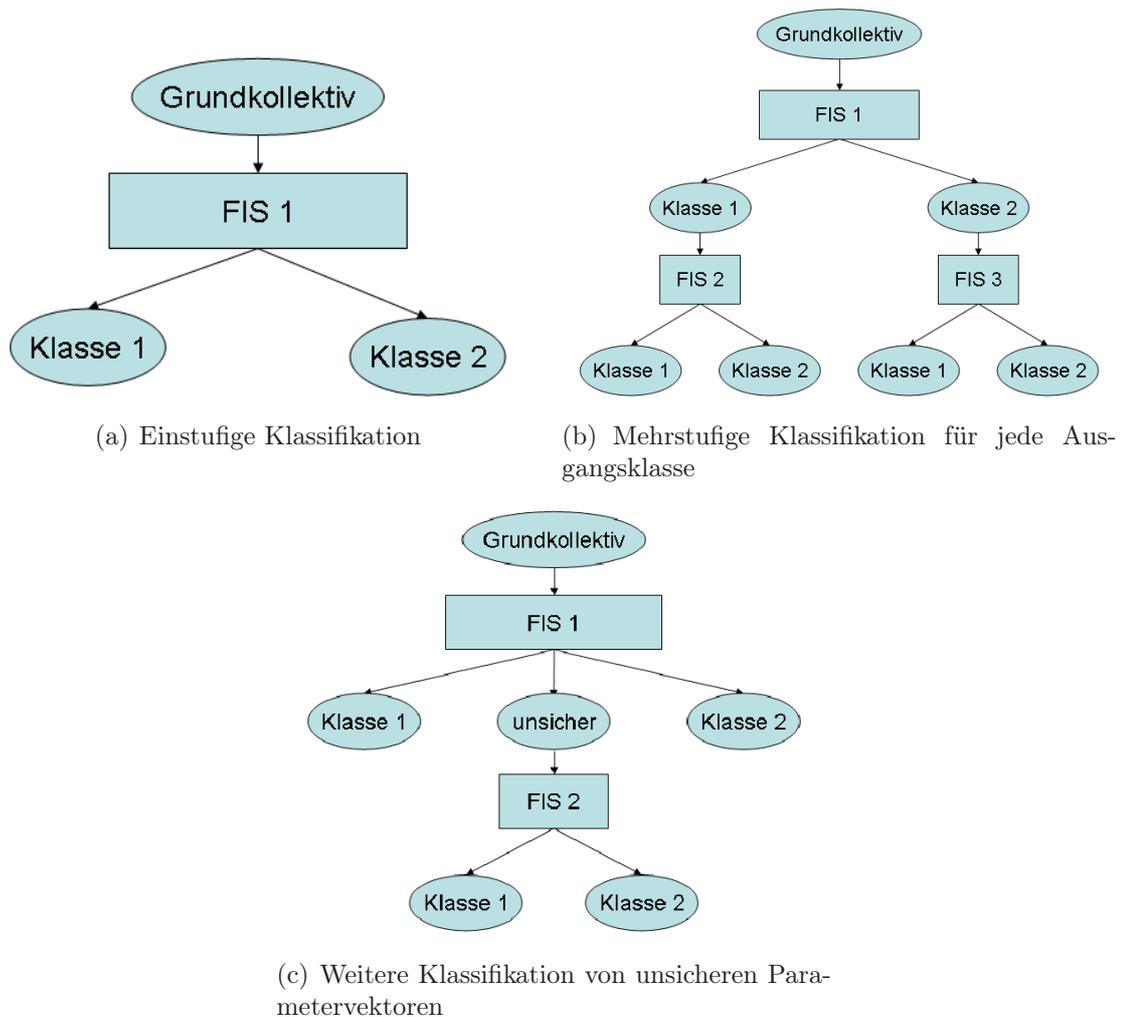
## 6.4 Kombination verschiedener Fuzzy-Inferenzsysteme

In vielen Fällen wird versucht, die gegebene Klassifikationsaufgabe durch Definition eines einzigen Fuzzy-Inferenz-Systems (FIS) zu lösen, wie dies in Abbildung 6.4(a) zu sehen. Dies ist für viele Problemstellungen ausreichend, v.a. wenn zur Beschreibung wenige Parameter herangezogen werden können und die verschiedenen Ausgangsklassen eine starke Clusterung aufweisen. Ist dies nicht der Fall, führt das durch die dann notwendige feinere Aufteilung des Parameterraums mit Hilfe von mehr Zugehörigkeitsfunktionen oder durch die Verwendung von mehr Parametern zur Beschreibung des Klassifikationsproblems zu sehr großen Regelwerken. Für ein FIS, das aus vier Parametern mit je drei Zugehörigkeitsfunktionen besteht, gibt es bereits  $3^4 = 81$  Regeln, mit denen sich alle Hyperquader des Parameterraums beschreiben lassen. Auch wenn nur eine Untermenge dieser Regelmenge zur vollständigen Beschreibung des Klassifikationsproblems ausreicht, geht die Transparenz des Verfahrens für den Anwender verloren: Die Erstellung oder Ergänzung einer Regelbasis werden stark erschwert.

Diese Transparenz lässt sich durch sequentielles Klassifizieren mit verschiedenen FIS wieder herstellen. Dieses Vorgehen kombiniert die Erstellung einer heuristischen Regelbasis, die traditionell mit scharfen Grenzen für die Klassifikation arbeitet, und die Stärken unscharfer Klassifikation. Zwei prinzipielle Topologien für die Kombination von verschiedenen FIS sind möglich:

1. Ein erstes FIS klassifiziert die Parametervektoren in die gewünschten Ausgangsklassen. Danach wird jede dieser Klassen durch ein weiteres FIS klassifiziert (Abbildung 6.4(b)). Dieses Vorgehen ist nicht nur zweistufig, sondern auch mehrstufig denkbar. Ebenso ist es möglich, dass FIS der zweiten Schicht nicht alle Ausgangsklassen abdecken, da sie für die Differenzierung verwandter Klassen spezifiziert sind, die durch die Grobklassifikation der vorangegangenen Stufen nicht ausreichend voneinander getrennt werden konnten.
2. Nach der Klassifikation der ersten Stufe werden die „unsicheren“ Vektoren in einer zweiten Stufe ein weiteres Mal untersucht (Abbildung 6.4(c)). Als „unsicher“ gilt ein Parametervektor, wenn folgende Bedingungen erfüllt sind:
  - Sei  $R = \bigcup R_{K_j}$  die Menge aller Regelaktivierungen für die verschiedenen möglichen Klassifikationen  $K_j$  für einen Parametervektor  $\vec{x}$ .
  - Die Aktivierung der für die Klassifikation verantwortlichen Regel ist  $A_{K_i} = \max(R)$
  - Gilt nun  $A_{K_j} = \max(\bigcup R_{K_j})|_{j \neq i} \geq q$ , dann folgt  $\vec{x} \Rightarrow$  unsicher.

Als „unsicher“ gilt ein Parametervektor also dann, wenn die maximale Aktivierung einer Regel, die für eine andere Ausgangsklasse spricht als die Gewinnerregel einen bestimmten „Unsicherheitsschwellwert“  $q$  überschreitet. Dieser wird durch ein vorgegebenes Verhältnis zur Aktivierung der Gewinnerregel gebildet. Beispielsweise können alle Vektoren als unsicher eingestuft werden, deren maximale Aktivierung einer Regel für eine andere Klasse mindestens das 0,9-fache der Aktivierung der Gewinnerregel beträgt. Auch diese Topologie kann mehr als zwei Schichten aufweisen.



**Abbildung 6.4:** Verschiedene Vorgehensweisen für die Klassifikation, im Beispiel für zwei Ausgangsklassen. Auch Mischformen zwischen den Strategien aus 6.4(b) und 6.4(c) sind möglich.

Darüber hinaus ist auch die Kombination beider Topologien möglich, also z. B. die nach Klassen getrennte Weiterverarbeitung von Vektoren, die vorher als unsicher eingestuft wurden und durch ein FIS neu klassifiziert wurden. Im Folgenden wird eine solche Kombination von Fuzzy-Inferenz-Systemen auch FIS-Netz genannt. In der vorgestellten Topologie ähneln diese FIS-Netze Entscheidungsbaum, haben aber zwei Vorteile: Die

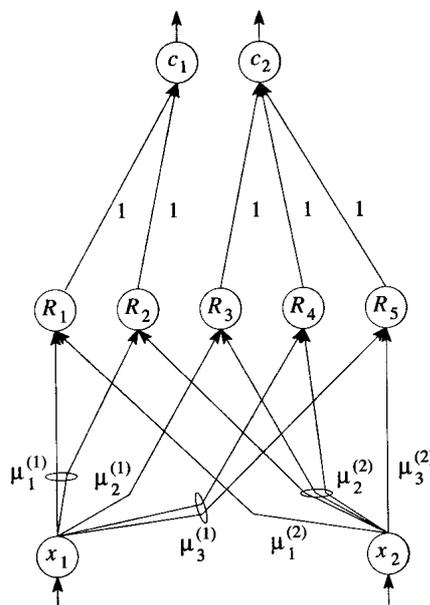
unscharfe Klassifikation und die Berücksichtigung mehrerer Parameter bei der Entscheidung in einem Knoten. Die Verhaltensweise eines Entscheidungsbaums kann ebenfalls simuliert werden, indem bei der Klassifikation nur ein Parameter berücksichtigt wird.

## 6.5 Verwendete Klassifikationssysteme

Im Rahmen dieser Arbeit wurden drei verschiedene Lern- bzw. Optimierungsverfahren für Fuzzy-Inferenz-Systeme bei verschiedenen Klassifikationsaufgaben aus dem Bereich der EKG-Klassifikation eingesetzt. Diese sollen in Folge kurz dargestellt werden.

### 6.5.1 NEFCLASS

NEFCLASS (NEuro-Fuzzy-CLASSification) ist ein Neuro-Fuzzy-Modell für die Klassifikation von Daten, das in den 1990er Jahren von Nauck et al. entwickelt wurde [NK95], [NK99]. Es basiert auf einem Fuzzy-Perceptron, das in der Struktur einem dreilagigen vorwärtbetriebenen Netz entspricht. Die Kantengewichte zwischen der Eingangsschicht ( $U_1$ ) und der verdeckten Schicht ( $U_2$ ) werden jedoch mit Hilfe von Fuzzy-Zugehörigkeitsfunktionen berechnet, können also je nach Eingangswert unterschiedlich sein. Die mittlere Schicht  $U_2$  entspricht den Regeln des Fuzzy-Systems, in denen die Aktivierung der Regelknoten durch eine Minimum-S-Norm gebildet wird. Die Ausgabeschicht  $U_3$  enthält die Klassen, denen die Eingangsvektoren zugeordnet werden sollen. Die Aktivierung der Neuronen in dieser Schicht wird durch eine Maximum-T-Norm gewonnen, wobei die endgültige Zuordnung zu einer Klasse nach einer „Winner-takes-all“-Regel erfolgt. Abbildung 6.5 zeigt ein Beispiel für eine NEFCLASS-Struktur.



**Abbildung 6.5:** Struktur des NEFCLASS-Systems mit zwei Eingängen, fünf Regeln und zwei Ergebnisklassen (aus [BKKN03]).

## Das Lernverfahren von NEFCLASS

Das Lernverfahren von NEFCLASS besteht aus zwei Teilen

- dem Regellernalgorithmus
- dem Lernalgorithmus für die Zugehörigkeitsfunktionen,

die nacheinander durchlaufen werden.

Das Erlernen der Regelbasis erfolgt durch die Verarbeitung eines Eingangsmusters auf Grundlage der vorhandenen Regeln und den für jede Eingangsvariable definierten Zugehörigkeitsfunktionen. Wird das aktuelle Muster davon nicht abgedeckt, wird eine entsprechende neue Regel unter Nutzung der am meisten zutreffenden Zugehörigkeitsfunktionen gebildet. Auf diese Weise müssen im Regelfall nicht alle möglichen Hyperquader des Parameterraums durch eine separate Regel beschrieben werden, was sonst zu einer Regelbasis mit  $\prod_{i=1}^N q_i$  Regeln ( $N$ : Anzahl der Eingangsvariablen  $x_i$ ,  $q_i$ : Anzahl der Zugehörigkeitsfunktionen der Variable  $x_i$ ) führen würde.

Im Folgenden wird von dreiecksförmigen (triangulären) Zugehörigkeitsfunktionen  $\mu$  ausgegangen, die durch drei Parameter wie folgt definiert werden:

$$\mu : \mathfrak{R} \rightarrow [0, 1], \mu(x) = \begin{cases} \frac{x-a}{b-a} & \text{falls } x \in [a, b), \\ \frac{c-x}{c-b} & \text{falls } x \in [b, c], \\ 0 & \text{sonst} \end{cases} \quad (6.12)$$

mit  $a \leq b \leq c$ . An den Rändern der Wertebereiche  $\mathcal{X}_j$  der Eingangsvariablen  $x_i$  sind die Zugehörigkeitsfunktionen „geschultert“. Am linken Rand des Wertebereichs spricht man von einer „linksgeschulterten“ Zugehörigkeitsfunktion, für die gilt  $\mu(x) = 1$  für  $x < b$  und am rechten Rand von einer „rechtsgeschulterten“ Zugehörigkeitsfunktion mit  $\mu(x) = 1$  für  $x > b$ .

Die Optimierung von triangulären Zugehörigkeitsfunktionen geschieht folgendermaßen (es wird von einer einheitlichen Regelgewichtung ausgegangen):

1. Bestimme für jeden Ausgangsknoten  $c_i$  den Abstand  $\delta_{c_i}$  der Aktivierung  $a_{c_i}$  zur Zielvorgabe  $t_{c_i}$ .

$$\delta_{c_i} = t_i - a_{c_i} \quad (6.13)$$

Bei der vorliegenden Klassifikationsaufgabe ist  $t_k = 1$  für die Klasse  $k$  und  $t_i = 0 \quad \forall i \neq k$ .

2. Für jeden Regelknoten mit einer Aktivierung  $a_R > 0$  durchlaufe folgendes Verfahren:

- Bestimme ein regelspezifisches

$$\delta_R = a_R(1 - a_R) \sum_i W(R, c_i) \delta_{c_i} \quad (6.14)$$

, wobei  $W(R, c_i) = 1$ , wenn die Regel  $R$  den Ausgangsknoten  $c_i$  beschreibt, und sonst 0 ist.

- Bestimme die Variable  $x$  der Regel  $R$  mit dem niedrigsten Zugehörigkeitsgrad  $\mu_x$  (diese ist verantwortlich für die Aktivierung der Regel).
- Für die Parameter  $a, b, c$  der Zugehörigkeitsfunktion bestimme Verschiebungen  $\delta_a, \delta_b$  und  $\delta_c$  an Hand der Lernrate  $\sigma$  nach folgendem Schema:

$$\delta_b = \sigma \cdot \delta_R \cdot (c - a) \cdot \text{sgn}(x - b) \quad (6.15)$$

$$\delta_a = -\sigma \cdot \delta_R \cdot (c - a) + \delta_b \quad (6.16)$$

$$\delta_c = \sigma \cdot \delta_R \cdot (c - a) + \delta_b \quad (6.17)$$

, sofern dadurch nicht bestimmte Randbedingungen (Reihenfolge oder Symmetrie der Zugehörigkeitsfunktionen, Schnittpunkte benachbarter Zugehörigkeitsfunktionen) verletzt werden.

3. Überprüfe, ob das Abbruchkriterium (Anzahl durchlaufener Epochen, Fehlerquote) erreicht ist.

### Implementierungen von NEFCLASS

Es gibt verschiedene plattformspezifische Implementierungen von NEFCLASS für Windows-PCs und Unix/Linux. 1999 wurde eine Java-basierte Implementierung (NEFCLASS-J) vorgestellt [NNK99], die einen erweiterten Funktionsumfang mit folgenden Features aufweist:

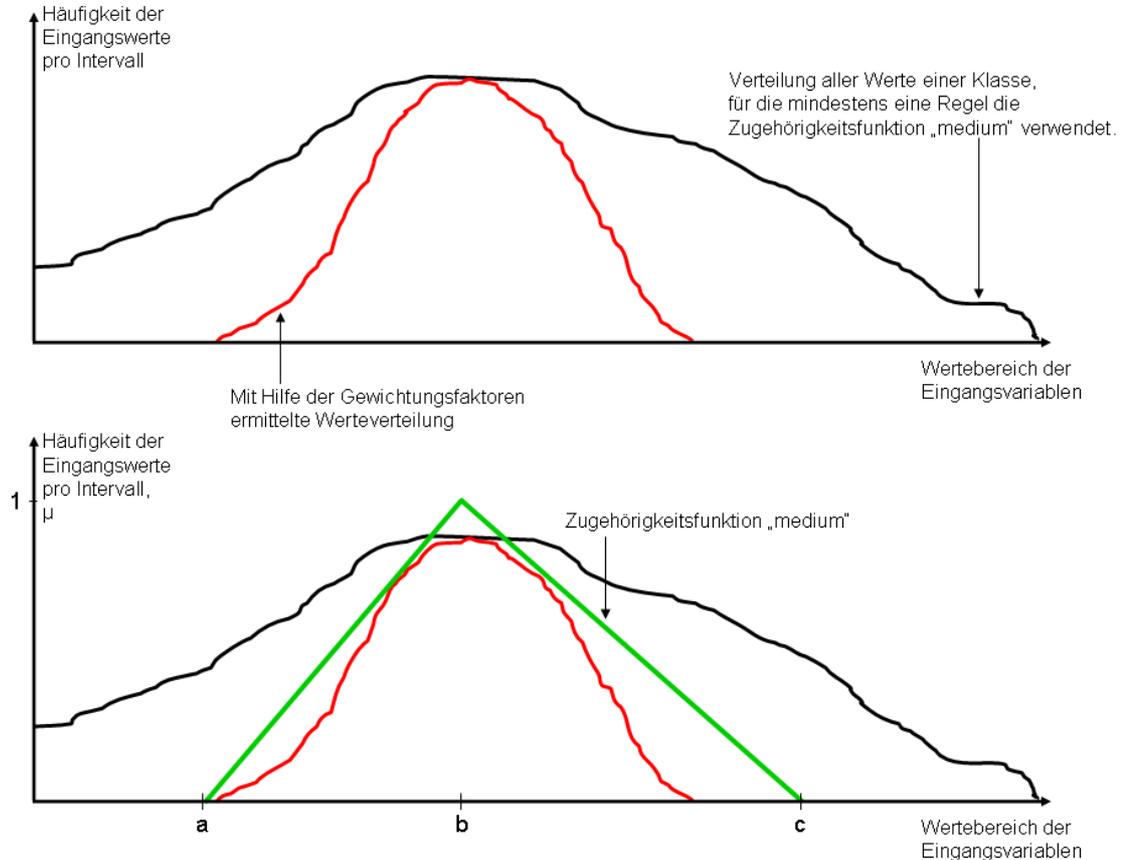
- Behandlung fehlender Werte
- Verarbeitung numerischer und symbolischer Daten
- Automatische Bestimmung der Regelanzahl
- Strategien zur automatischen Vereinfachung des Klassifizierers (Entfernung von Regeln und Zugehörigkeitsfunktionen)
- Unterstützung von trapezoidalen und glockenförmigen Zugehörigkeitsfunktionen

Für die Schlagklassifikation (siehe Kapitel 8) und die VT/VF-Detektion (siehe Kapitel 9) wurde NEFCLASS-J als eine der Klassifikationsmethoden evaluiert.

### 6.5.2 Wissensoptimierter Lernalgorithmus für Neuro-Fuzzy-Systeme

Basierend auf NEFCLASS-PC wurde ein neuer Lernalgorithmus für die Optimierung der Parameter von dreiecksförmigen Zugehörigkeitsfunktionen nach Gleichung 6.12 entwickelt ([Som02], [SSB03]). Dieser versucht, vorhandenes Vorwissen über die Parameterverteilungen besser zu nutzen, als dies mit dem streng formalistischen Vorgehen des NEFCLASS-Algorithmus möglich ist. Dies geschieht durch Gewichtung der Eingangsvektoren in Bezug auf ihre Relevanz für die betrachtete Zugehörigkeitsfunktion, um so zu einer besseren Parametrisierung kommen. Die Netzstruktur entspricht der von NEFCLASS. Das Verfahren verwendet eine feste Regelbasis, d.h. es enthält keine Methoden, um die Regeln im Verlauf des Trainings anzupassen.

Das Verfahren besteht aus zwei Teilschritten, die ähnliche Strategien zur Bestimmung der optimalen Trennpunkte benachbarter Zugehörigkeitsfunktionen verwenden: Die Vorverteilung, in der die Zugehörigkeitsfunktionen initialisiert werden, und das Lernverfahren, in dem sie optimiert werden.



**Abbildung 6.6:** Ermittlung einer Zugehörigkeitsfunktion „medium“: Oben die Dichtefunktion der Variable für einen bestimmten Ausgang (schwarz) und ihr gewichteter Verlauf (rot), darunter zusätzlich die daraus gewonnene Zugehörigkeitsfunktion (grün).

### Vorverteilung

Bei der Vorverteilung werden für jede linke Flanke der Zugehörigkeitsfunktionen einer Variablen  $x$  für jeden Ausgangsknoten  $c_i$  zwei Mengen aus der Gesamtmenge der Parameterwerte gebildet:  $a_{pos}$  enthält alle Werte, bei denen in mindestens einer Regel die aktuelle Zugehörigkeitsfunktion für den Ausgang  $c_i$  verwendet wird. Alle anderen Werte werden  $a_{neg}$  zugeordnet. Dann wird der Trennpunkt  $x'$  so bestimmt, dass möglichst viele der Elemente von  $a_{pos}$  in der Teilmenge  $a'_{pos}$  rechts vom Trennpunkt und damit eher in der Zugehörigkeitsfunktion bzw. möglichst viele Elemente von  $a_{neg}$  links davon in der Teilmenge  $a'_{neg}$  und damit außerhalb der Zugehörigkeitsfunktion liegen. Dies geschieht

durch Maximierung des folgenden Produkts:

$$\frac{|a'_{pos}|}{|a_{pos}|} \cdot \frac{|a'_{neg}|}{|a_{neg}|} \quad (6.18)$$

Der Wert der Zugehörigkeitsfunktion für  $x'$  wird zu 0,5 bestimmt. Der Fußpunkt  $a$  der Flanke wird um einen Faktor  $q$  links neben den kleinsten Wert von  $a_{pos}$  gesetzt.  $q$  wird aus dem prozentualen Anteil von Daten im linken Drittel des Wertebereichs von  $a_{pos}$  an der Gesamtmenge und dem Wertebereich der Variablen  $x$  bestimmt. Analog wird der rechte Fußpunkt  $c$  der nächstkleineren Zugehörigkeitsfunktion rechts von  $\max(a_{pos})$  berechnet. Damit sind die Flanken eindeutig bestimmt.

## Lernverfahren

Das Lernverfahren besteht aus zwei Teilen: Der Modifikation des Center-Parameters  $b$  der dreieckigen Zugehörigkeitsfunktion und der Modifikation der beiden Fußpunkte  $a$  und  $c$ .

Für die Modifikation des Center-Parameters der Zugehörigkeitsfunktion  $\mu_x^{(k)}$  werden aus allen Werten für die Variable  $x$  durch Propagation der Parametervektoren durch das aktuelle Inferenzsystem drei Teilmengen gebildet, die für jede Regel nach folgenden Kriterien gefüllt werden:

- Ist der Parametervektor korrekt klassifiziert worden, wird der Wert in  $a_{pos}$  gespeichert.
- Ist die Klassifikation nicht korrekt und existiert wenigstens eine Regel für die Referenzklasse, die eine größere oder kleinere Zugehörigkeitsfunktion als die aktuelle verwendet, wird der Wert  $a_{neg}^{larger}$  bzw.  $a_{neg}^{smaller}$  zugewiesen.

Durch die regelbasierte Zuweisung kann es geschehen, dass ein Wert mehreren dieser Mengen zugewiesen wird.

Um aus der Verteilung der Werte zu einer gewichteten Dichtefunktion wie in Abbildung 6.6 illustriert zu kommen, werden die Werte zusätzlich mit einem Gewichtungsfaktor  $g$  bewertet. Ziel dieser Bewertung ist es, die Dichtefunktion für die zu optimierende Zugehörigkeitsfunktion so zu konzentrieren, dass die Bestimmung der Funktionsparameter erleichtert wird. Der Gewichtungsfaktor  $g$  wird aus vier Teilfaktoren nach folgender Beziehung gebildet:

$$g = \prod_{i=1}^4 g_i \quad (6.19)$$

Die vier Faktoren beschreiben folgende Komponenten:

- **$g_1$ : Anzahl der Vektoren der Zielklasse am Gesamtkollektiv**  
Unterscheiden sich die Größen der Ergebnisklassen im betrachteten Kollektiv stark, so kann es geschehen, dass die Zugehörigkeitsfunktionen von Klassen, die selten auftreten, zugunsten von Zugehörigkeitsfunktionen von häufig auftretenden Klassen verändert werden. Dies erniedrigt den Gesamtfehler, führt aber für diese Ergebnisklassen zu einer Verschlechterung der Klassifikationsgüte. Besonders bei der EKG-Klassifikation, bei der es um die Detektion relativ seltener pathologischer

zwischen einer Vielzahl „normaler“ Ereignisse ist dies nicht wünschenswert. Um hier einen Ausgleich zu schaffen, werden Vektoren seltener Klassen höher gewichtet als die häufig auftretender Klassen. Sei  $X_k$  die Menge aller Parametervektoren für den Ausgangsknoten  $c_k$ , so wird der Faktor  $g_1$  folgendermaßen gebildet:

$$g_{1,k} = \frac{\min(X|_{\forall c_k \in U_3})}{X_k} \quad (6.20)$$

Vektoren, der am seltensten auftretenden Klasse erhalten also das Gewicht 1, alle anderen Vektoren ein kleineres Gewicht.

- **$g_2$ : Zuständigkeit der Regeln**

Regeln, die die betrachtete Zugehörigkeitsfunktion verwenden und eine hohe Aktivierung aufweisen, werden als zuständig eingestuft und führen zu einem hohen Gewichtungsfaktor. Regeln, bei denen eine oder mehrere Zugehörigkeitsgrade  $< 0,1$  durch das Antezedens bestimmt werden, erhalten dagegen eine niedrige Gewichtung und nehmen geringeren Einfluss auf die Veränderung der Zugehörigkeitsfunktion.

- **$g_3$ : Güte der bisherigen Klassifikation**

Dieser Faktor berücksichtigt, wieviele Vektoren bereits richtig klassifiziert werden. Noch falsch klassifizierte Vektoren erhalten ein großes Gewicht, damit sie möglichst starken Einfluss auf die Anpassung der Zugehörigkeitsfunktion nehmen können. Das Mindestgewicht für einen richtig klassifizierten Vektor ist 0,5. Falsch klassifizierte Vektoren, bei denen die Aktivierung aller Regeln für die korrekte Klassifikation 0 ist, erhalten das Höchstgewicht 1.

- **$g_4$ : Lage des Wertes im Wertebereich**

Ausgehend von der Verteilung der Parameterwerte in  $a_{pos}$  und in Abhängigkeit davon, ob die Werte auch noch in anderen Regeln mit anderen Zugehörigkeitsfunktionen benutzt werden, werden die Randbereiche der Parameter als nicht vertrauenswürdig eingestuft und mit einem Gewichtungsfaktor 0,1 versehen. Der Faktor nimmt dann zur Mitte des Wertebereichs zu und erreicht dort seinen maximalen Wert 1.

Insgesamt ergeben sich für die Mengen  $a_{pos}$ ,  $a_{neg}^{smaller}$  und  $a_{neg}^{larger}$  neue, gewichtete Parameterverteilungen, auf die die Verfahren aus der Vorverteilung analog angewendet werden, um die optimalen Trennpunkte zu finden.

Nach dem Trennpunkt wird der Center-Parameter so bestimmt, dass das Produkt der durchschnittlichen, gewichteten Aktivierung für  $a_{pos}$  und  $a_{neg}^{smaller}$  bzw.  $a_{neg}^{larger}$  (je nach betrachteter Flanke) maximal wird. Entsprechend der aktuellen Lernrate  $\sigma$  wird der aktuelle Center-Parameter dann in Richtung dieses so bestimmten „optimalen“ Center-Parameters verschoben.

Die Verschiebung der Fußpunkte geschieht nur in eine Richtung, nämlich zur Mitte der Zugehörigkeitsfunktion. In der Vorverteilung wurde die Fuzzymenge breiter als der Wertebereich der in Frage kommenden Variablenwerte gewählt. Im Lernverfahren wird versucht, die Zugehörigkeitsfunktion wieder zu verkleinern. Dazu wird eine Menge von

Datensätzen gebildet, die falsch klassifiziert werden und der untersuchten Zugehörigkeitsfunktion zugeordnet werden. Anschließend werden in 20 gleichgroßen Schritten über den Wertebereich Intervalle, die 15% des Wertebereichs abdecken, untersucht. Wenn in einem dieser Intervalle mehr als 20% der Werte enthalten sind, so berechnet das Verfahren einen virtuellen Fußpunkt, bei dem dieses Intervall außerhalb der Merkmalsfunktion liegt. Es wird jedoch überprüft, ob dieses Vorgehen eine Verbesserung bringt. Anschließend wird der alte Fußpunkt der Menge in Abhängigkeit von  $\sigma$  eine Teilstrecke zwischen dem alten und dem virtuellen Fußpunkt verschoben.

Dieser Lernalgorithmus wurde ursprünglich für die Klassifikation von Schlafstadien entwickelt und hat bei dieser deutlich bessere Ergebnisse als der NEFCLASS-Algorithmus erzielt [SSB03]. Daher wurde er im Rahmen dieser Arbeit auch für die QRS-Detektion und -Klassifikation herangezogen und für diesen Einsatz angepasst. Diese Änderungen betrafen v.a. die Behandlung von Ausreißern in der Parameterverteilung und die Erweiterungen der Protokollierungsmöglichkeiten, um das Auffinden fälschlicherweise aktiver Regeln, die dafür verantwortlichen Variablen und in der Folge die Rückverfolgung falsch klassifizierter Vektoren zu ermöglichen. Das System erwies sich aber über weite Strecken als unpflegbar, so dass eine Neuimplementierung in Angriff genommen werden musste. Zusätzlich müssen einige der getroffenen Maßnahmen, die teilweise erheblichen Rechenaufwand erfordern, hinsichtlich ihrer Effektivität in Zweifel gezogen werden, da zugleich die Randbedingungen für die Anpassung der Zugehörigkeitsfunktionen durch die Beschränkung auf dreiecksförmige Funktionen sehr hart sind. Dies motivierte die Entwicklung eines neuen Verfahrens zur Bestimmung der optimalen Fuß- und Trennpunkte von benachbarten Zugehörigkeitsfunktionen, das im folgenden Kapitel erläutert wird.

### 6.5.3 Neue Strategie für die Optimierung von Zugehörigkeitsfunktionen

Beim Verfahren aus [Som02] werden bei der Berechnung der Parameter pro Zugehörigkeitsfunktion aufwendig die optimalen Trennpunkte benachbarter Zugehörigkeitsfunktionen bestimmt und in Abhängigkeit davon die Fuß- und Schulterpunkte bzw. Center-Parameter der Funktionen bestimmt. Pro Flanke werden also drei Punkte bestimmt, wobei nach Bestimmung des Fußpunktes und des Center-Parameters der Trennpunkt immer wieder verworfen wird. Da jede Flanke separat berechnet wird, ist das Verfahren eigentlich auf die Berechnung von 4 Parametern pro Zugehörigkeitsfunktion zugeschnitten, jedoch hat eine Dreiecksfunktion nur 3 Freiheitsgrade. Durch diese Beschränkung ist es sehr wahrscheinlich, dass die aufwendigen Maßnahmen zur Bestimmung optimaler Flanken zum Teil ineffektiv bleiben, da die Beschränkungen für den Center-Parameter zu stark sind. Eine Maßnahme, dies zu verbessern, ist die Erweiterung der erlaubten Zugehörigkeitsfunktionen auf Trapezfunktionen mit vier Parametern:

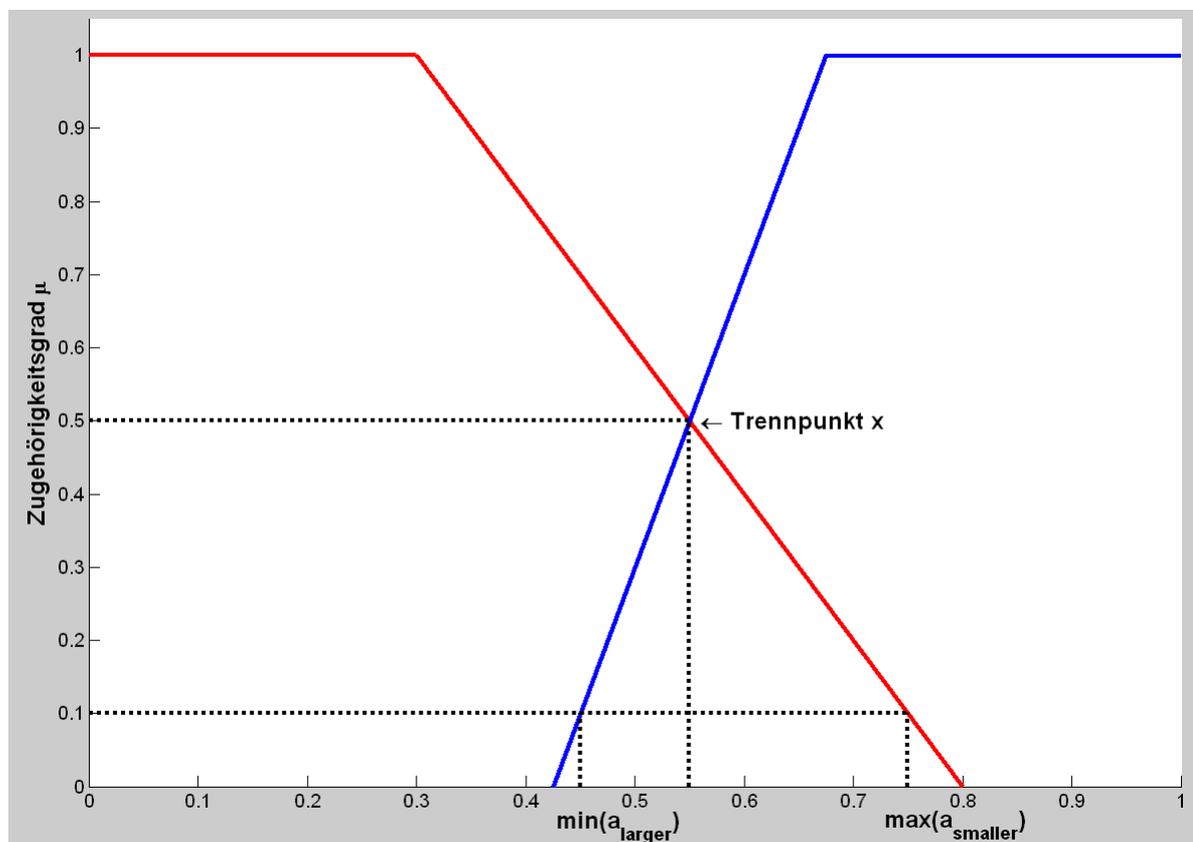
$$\mu : \mathfrak{R} \rightarrow [0, 1], \mu(x) = \begin{cases} \frac{x-a}{b-a} & \text{falls } x \in [a, b), \\ 1 & \text{falls } x \in [b, c], \\ \frac{d-x}{d-c} & \text{falls } x \in (c, d], \\ 0 & \text{sonst} \end{cases} \quad (6.21)$$

Es gilt  $a \leq b \leq c \leq d$ .

Diese Grundidee und die im vorigen Kapitel angesprochenen Probleme bei der Erweiterung des vorhandenen Verfahrens waren Auslöser für die Entwicklung eines neuen Verfahrens zur Optimierung der Zugehörigkeitsfunktionen in einem Fuzzy-System mit vorgegebener Regelbasis [Haa05b].

### Bestimmung der Trennpunkte

In [Som02] wird eine Zugehörigkeitsfunktion gegen alle größeren bzw. kleineren Funktionen abgegrenzt. Im neuen Verfahren wird die Zugehörigkeitsfunktion nur zur nächsthöheren bzw. nächstniedrigeren Zugehörigkeitsfunktion abgegrenzt. Die Abgrenzung zu weiter entfernten Mengen erfolgt dadurch implizit. Damit wird nicht mehr über die Menge aller Zugehörigkeitsfunktionen iteriert und für jede Funktion jeweils beide Flanken betrachtet, sondern es werden die Zwischenräume zwischen den Zugehörigkeitsfunktionen analysiert und der Trennpunkt für die beiden sich dort schneidenden Flanken berechnet.



**Abbildung 6.7:** Illustration der Bestimmung der Fußpunkte der Flanken bei Zugehörigkeitsfunktionen ausgehend vom ermittelten Trennpunkt.

Dazu werden für jeden Zwischenraum die beiden Mengen  $a_{smaller}$  und  $a_{larger}$  ähnlich zu  $a_{neg}$  und  $a_{pos}$  in [Som02] aufgebaut. Datensätze, deren Klassifikation eine Regel beinhaltet, die die größere Zugehörigkeitsfunktion benutzt, werden  $a_{larger}$  zugeordnet.

Datensätze, deren Klassifikation eine Regel beinhaltet, die die kleinere Fuzzymenge benutzt, kommen nach  $a_{smaller}$ . Damit können Datensätze durch ihre unterschiedliche Verwendung in verschiedenen Regeln beiden Mengen zugeordnet werden.

Im Gegensatz zum vorherigen Verfahren wird vor der Berechnung der Trennpunkte überprüft, ob eine der Mengen Teilmenge der anderen ist. Ist dies der Fall, so bedeutet das, dass für jede Klassifikation, die in einer ihrer Regeln die eine Zugehörigkeitsfunktion benutzt, es eine andere Regel für diese Klassifikation gibt, die die andere der beiden Zugehörigkeitsfunktionen benutzt. Es ist zu diesem Zeitpunkt also nicht möglich, die beiden Funktionen sinnvoll zu trennen. Deshalb wird als Trennpunkt einfach der Schwerpunkt der kleineren der beiden Mengen genommen.

Ist keine der beiden Mengen  $a_{smaller}$  und  $a_{larger}$  Teilmenge der anderen, so werden aus beiden Mengen diejenigen Datensätze entfernt, die in beiden enthalten sind. Dadurch werden diejenigen Datensätze entfernt, die keinen Aufschluss darüber geben, wie die beiden Mengen zu trennen sind. Anschließend werden die Teilmengen mit dem Gewicht  $g_1$  aus [Som02] gewichtet und Extremwerte über einen einstellbaren Schwellwert aus dem Kollektiv entfernt. Nach diesem Schritt wird für die Identifikation des Trennpunktes analog zu [Som02] das Produkt aus Gleichung 6.18 maximiert ( $a_{pos}$  wird durch  $a_{larger}$  ersetzt und  $a_{neg}$  durch  $a_{smaller}$ , Ersetzung der Teilmengen analog). Sollte es mehrere mögliche Trennpunkte geben, bei denen das Produkt maximiert wird, dann wird der Mittelwert dieser Werte genommen.

## Bestimmung der Fußpunkte

Dieses Verfahren versucht, den Abstand der Fußpunkte möglichst gering zu halten. Deshalb werden für den Fall, dass  $a_{smaller}$  und  $a_{larger}$  nicht Teilmengen von einander sind, dieselben Mengen verwendet wie zur Bestimmung des Trennpunktes der beiden Zugehörigkeitsfunktionen.

Die Fußpunkte werden nun so gelegt, dass durch die minimalen und maximalen Werte in der jeweiligen Menge der  $\alpha$ -Schnitt  $A_{0,1}$  definiert ist. Das bedeutet, dass

$$x_{leftBase}^k = \min(a_{larger}) \quad (6.22)$$

k: Index der Zugehörigkeitsfunktion

$$x_{rightBase}^{k-1} = \max(a_{smaller}) \quad (6.23)$$

jeweils den Wert  $\mu(x_{leftBase}) = \mu(x_{rightBase}) = 0, 1$  liefern.

Die zwei Punkte *leftBase* und *rightBase* werden Sockelpunkte genannt und sollen sicherstellen, dass diese Parameterwerte noch eine ausreichende Regelaktivierung verursachen können. Mit Hilfe der Sockel- und Trennpunkte werden dann die Fußpunkte *leftFoot* (linker Fußpunkt der größeren Fuzzymenge) und *rightFoot* (rechter Fußpunkt der kleineren Fuzzymenge) und die Schulterpunkte *leftShoulder* (linker Schulterpunkt der größeren Fuzzymenge), *rightShoulder* (rechter Schulterpunkt der kleineren Fuzzy-

menge) bestimmt:

$$\text{leftFoot} = \min(a_{\text{larger}}) - \frac{1}{4} \cdot (x - \min(a_{\text{larger}})) \quad (6.24)$$

$$\text{leftShoulder} = x + (x - \text{leftFoot}) \quad (6.25)$$

$$\text{rightFoot} = \max(a_{\text{smaller}}) + \frac{1}{4} \cdot (x - \max(a_{\text{smaller}})) \quad (6.26)$$

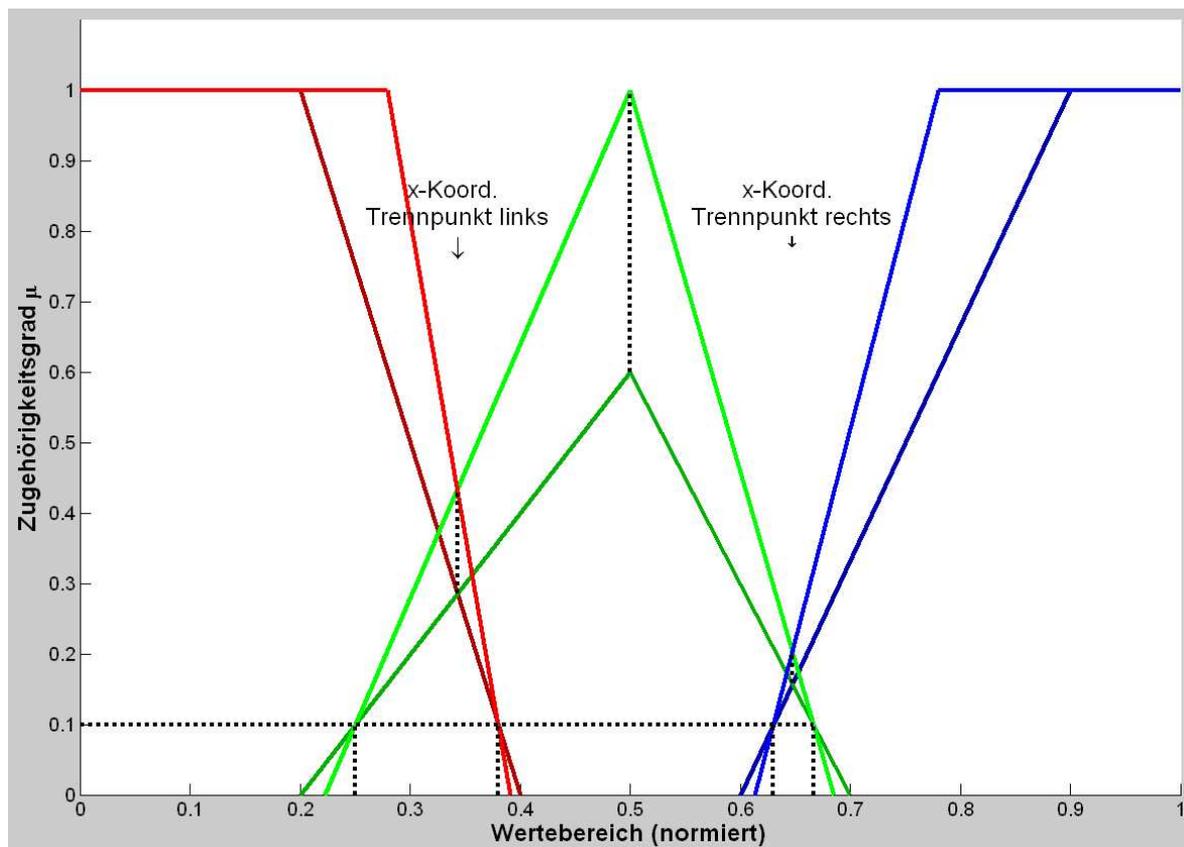
$$\text{rightShoulder} = x - (\text{rightFoot} - x) \quad (6.27)$$

Abbildung 6.7 verdeutlicht das Vorgehen bei dieser Berechnung.

## Normalisierung der Zugehörigkeitsfunktionen

Da die Flanken einer Zugehörigkeitsfunktion getrennt voneinander bestimmt werden, ist deren Gestalt von ihrem Schnittpunkt abhängig. Ein Schnittpunkt bei  $\mu = 1$  führt zu einer dreiecksförmigen, ein Schnittpunkt mit  $\mu > 1$  zu einer trapezoidalen Zugehörigkeitsfunktion, da  $\mu \in [0, 1]$ . Der dritte Fall ist durch einen Schnittpunkt der Flanken der Zugehörigkeitsfunktion bei einem Wert  $\mu < 1$  gegeben. Um den Einfluss dieser subnormalen Zugehörigkeitsfunktion auf das Klassifikationsergebnis nicht von vornherein zu verringern, wird sie so normalisiert, dass wieder  $\max(\mu) = 1$  gilt. Würde man diese Anpassung allerdings nur für die betroffene Zugehörigkeitsfunktion durchführen, würden sich die Trennpunkte zwischen ihr und den benachbarten Funktionen verschieben. Um dies zu verhindern, werden die Flanken an den Trennpunkten modifiziert. Für diese Modifikation wurden zwei verschiedene Methoden implementiert, die sich leicht in ihrer Wirkung unterscheiden:

1. NFC 1: Bei dieser Methode werden die Sockelpunkte der zu normalisierenden Zugehörigkeitsfunktion fixiert und die Flanken so angepasst, dass für ihren Schnittpunkt  $\mu_{\text{neu}} = 1$  gilt. Aus den Zugehörigkeitsgraden der Flankenschnittpunkte  $\mu_{\text{alt}}$  und  $\mu_{\text{neu}}$  wird ein Normalisierungsfaktor  $q = \frac{\mu_{\text{neu}}}{\mu_{\text{alt}}} = \frac{1}{\mu_{\text{alt}}}$  gebildet. Mit diesem werden die alten Zugehörigkeitswerte für die x-Koordinaten der Trennpunkte für die Flanken der benachbarten Zugehörigkeitsfunktionen multipliziert und auf Grundlage dieser neuen Punkte ihre Schulterpunkte und Fußpunkte neu berechnet.
2. NFC 2: Die Flanken am Trennpunkt werden so modifiziert, dass die x-Koordinaten des Trennpunkts und der Sockelpunkte exakt erhalten bleiben, die Fuß- und Schulterpunkte der betroffenen Zugehörigkeitsfunktionen werden entsprechend angepasst. Zunächst werden der Schnittpunkt der beiden Flanken auf den Wert  $\mu = 1$  normalisiert und mit den Sockelpunkten die neuen Flanken der Zugehörigkeitsfunktion bestimmt, woraus der neue Zugehörigkeitsgrad für den Trennpunkt zur benachbarten Zugehörigkeitsfunktion berechnet werden kann. Zusammen mit dem Sockelpunkt der Flanke dieser Zugehörigkeitsfunktion liegen zwei Punkte dieser Flanke fest, aus denen der neue Fuß- und Schulterpunkt bestimmt werden kann. Abbildung 6.8 zeigt dieses Vorgehen.



**Abbildung 6.8:** Normalisierung einer Dreiecksfunktion, deren Flanken sich in einem Wert  $\mu < 1$  schneiden nach der Methode NFC 2. Die x-Koordinaten des Schnittpunkts und der Trennpunkte werden beibehalten, die Schulterpunkte der benachbarten Zugehörigkeitsfunktionen gemäß der Bedingungen für die Sockelwerte angepasst.

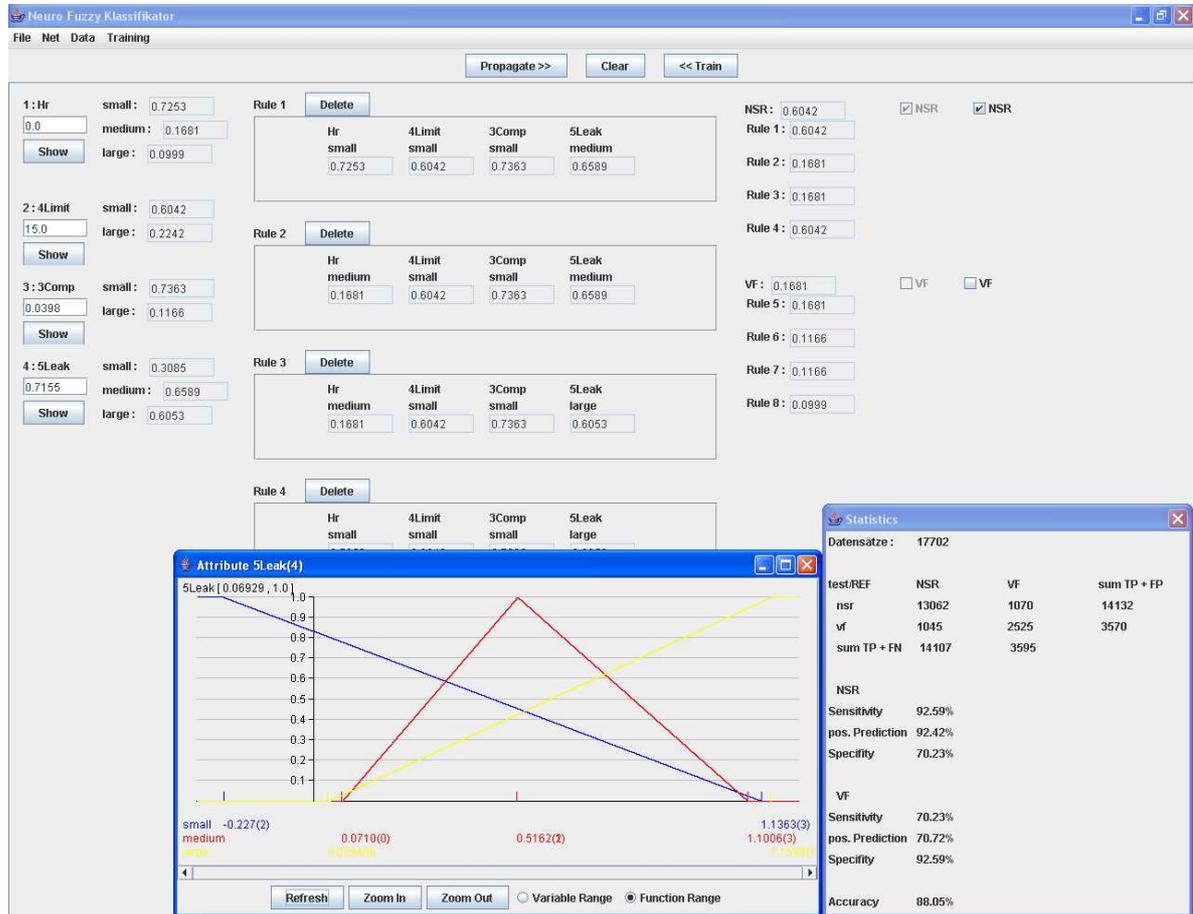
## Implementierung

Da die Implementierungen von NEFCLASS-J und des Verfahrens nach [Som02] nicht für das neue Trennverfahren erweiterbar waren, wurde für dieses neue Verfahren eine eigene Implementierung in Java vorgenommen, um die trainierten FIS im TeDiaNet-Framework (siehe Kapitel 7.3.2) einsetzen zu können.

Abbildung 6.9 zeigt einen Screenshot dieser NFC (für Neuro-Fuzzy-Classificator) genannten Anwendung. Mit ihr können für eine vorgegebene Kombination aus Datenkollektiv und Regelbasis die Fuzzy-Zugehörigkeitsfunktionen bestimmt und das Datenkollektiv mit den wichtigsten statistischen Kennwerten aus A.1 evaluiert werden. Darüber hinaus kann man das Datenkollektiv so trennen, dass eine schrittweise Optimierung von Fuzzy-Netzen nach den in Kapitel 6.4 angesprochenen Topologien möglich wird. Dazu können aus dem gegebenen Datenkollektiv die einzelnen Ergebnisklassen extrahiert und als neue Parameterdatei exportiert werden. Außerdem können nur die Indices der betroffenen Merkmalsvektoren exportiert werden. Auf diese Weise ist es möglich, auch neue Parameterkombinationen zu testen, falls das ursprüngliche Datenkollektiv nur eine Untermenge der möglichen Parameter darstellt. Diese Exportmöglichkeiten stehen auch für „unsichere“ Vektoren gemäß der Beschreibung in Kapitel 6.4 zur Verfügung.

Zusätzlich können auch deren Komplementärmenge, die „sicheren“ Vektoren, auf gleiche Weise behandelt werden.

Diese Java-Applikation enthält auch eine Implementierung des in Kapitel 6.5.2 beschriebenen Trainingsalgorithmus nach [Som02], die zur besseren Identifikation im weiteren Verlauf als NFS (Neuro-Fuzzy-System) referenziert wird.



**Abbildung 6.9:** Screenshot der Java-Anwendung für die optimierte Bestimmung von Trennpunkten benachbarter Zugehörigkeitsfunktionen. Neben den Regeln können auch die Zugehörigkeitsfunktionen dargestellt werden. Für die Auswertung werden die Ergebnisse statistisch aufbereitet.

## 6.5.4 Matlab ANFIS

Bei den bisher vorgestellten Systemen handelt es sich um Fuzzy-Systeme vom Mamdani-Typ [BKKN03], wobei für die Ausgangsvariablen (Klassifikationen) der Regeln diskrete Werte (Klassen) definiert sind. Die Matlab Fuzzy-Logic Toolbox [Mat00] stellt eine Implementierung des „Adaptive-Network-based Fuzzy Inference System“ (ANFIS) von [JR93] zur Verfügung, das Sugeno-Fuzzy-Inferenzen verwendet. Fuzzy-Inferenz-Systeme vom Sugeno-Typ sind dadurch spezifiziert, dass der Aktivierungswert einer Regel als Linearkombination der Eingangswerte dargestellt werden kann. Diese Akti-

vierung  $o_r$  einer Regel  $R_r$  ist gegeben durch

$$o_r = \bar{\tau}_r \cdot (\alpha_0^r + \alpha_1^r x_1 + \dots + \alpha_n^r x_n) \quad (6.28)$$

Dabei stellen  $x_1, \dots, x_n$  die Eingangswerte und  $\bar{\tau}_r$  den normalisierten Erfüllungsgrad von  $R_r$  dar. Dieser wird aus dem Erfüllungsgrad der Regel

$$\tau_r = \prod_{i=1}^n \mu_{j_r}^{(i)}(x_i) \quad (6.29)$$

durch Normalisierung über die Summe der Erfüllungsgrade für alle Regeln berechnet. Die Zugehörigkeitsfunktionen für die Eingangsvariable  $x_i$  sind durch  $\mu^{(i)}$  spezifiziert. Der Index  $j_r$  gibt an, welche von ihnen in der Regel  $R_r$  benutzt werden soll. Der Ausgabewert des Sugeno-FIS mit  $N$  Regeln ist dann über folgende Formel gegeben:

$$y = \sum_{r=1}^N o_r \quad (6.30)$$

ANFIS bietet die Möglichkeit, die Zugehörigkeitsfunktionen und die Parameter der Ausgabefunktion durch einen zweiteiligen Trainingsalgorithmus zu optimieren. Die Matlab-Implementierung bietet nur die Möglichkeit, ANFIS-Modelle mit einer Ausgabegröße  $y$  zu berechnen. Durch die Berechnungsweise entspricht dies bereits einem defuzzifizierten Wert. Für Klassifikationsausgaben müssen die Ergebnisklassen durch diskrete Zahlenwerte vorgegeben werden. Diese werden dann durch den Trainingsalgorithmus zu approximieren versucht. Für den produktiven Einsatz muss der Ausgabewert des Fuzzy-Inferenz-Systems sinnvoll auf einen scharfen Wert aus der Menge der Ergebnisklassen abgebildet werden, z.B. durch Rundung.



# 7 Verfahren zur Detektion von QRS-Komplexen im EKG

Der QRS-Komplex ist die prominenteste Wellenform im EKG-Signal. Für eine einfache Rhythmusdiagnostik ist das Auffinden der R-Zacke bereits ausreichend. Die zuverlässige Detektion des QRS-Komplexes ist damit der unabdingbare erste Schritt für die weitere EKG-Analyse.

In diesem Kapitel wird zunächst ein Überblick über die in der Literatur beschriebenen Verfahren für die Detektion von QRS-Komplexen im Oberflächen-EKG gegeben. Anschließend werden die Kriterien erläutert, die zur Auswahl der in dieser Arbeit näher untersuchten Verfahren zur QRS-Detektion geführt haben. Diese drei Verfahren werden im Anschluss detailliert mit ihren diversen Modifikationen vorgestellt und am Schluss wird eine Übersicht über die erzielten Ergebnisse gegeben.

## 7.1 Übersicht über QRS-Detektionsverfahren

Auf Grund der großen Vielzahl von Verfahren kann an dieser Stelle nicht der Anspruch auf Vollständigkeit erhoben werden. Die Tatsache, dass auch nach mittlerweile Jahrzehnten der rechnergestützten EKG-Analyse immer wieder neue Verfahren für die QRS-Detektion vorgestellt werden, zeigt jedoch deutlich die Relevanz wie auch die Problematik des Themas.

Einen sehr guten und umfassenden Überblick über die Arbeiten in diesem Bereich gibt der Artikel von Köhler et al. aus dem Jahr 2002 [KHO02]. Exemplarisch werden im Weiteren einige der Verfahren näher beschrieben und einander gegenübergestellt.

Neun verschiedene Algorithmen wurden in [FJJ<sup>+</sup>90] auf ihre Rauschunempfindlichkeit getestet. Die Ansätze zur QRS-Detektion sind zum Teil sehr unterschiedlich. Ein vielverwendetes Kriterium ist die erste Ableitung des EKG Signals, da diese schnell zu ermitteln ist. Dieses Kriterium tritt auch in Kombination mit der zweiten Ableitung oder der Amplitude des QRS-Komplexes auf. Der von Engelse/Zeelenberg vorgeschlagene Algorithmus [EZ79] schnitt bei den Tests in [FJJ<sup>+</sup>90] am besten ab. Eine Erklärung dafür liegt in der Signalvorverarbeitung, die aus der Hintereinanderschaltung mehrerer digitaler Filter besteht. Zur QRS-Komplex-Detektion wird gezählt, wie oft die erste Ableitung des Signals einen Schwellwert kreuzt. Ist dies zwei bis vier Mal der Fall, so handelt es sich um einen QRS-Komplex; bei einem Mal um eine Nulllinienverschiebung. Wird der Schwellwert mehr als viermal über- bzw. unterschritten, ist Rauschen aufgenommen worden.

Die Resultate von [FJJ<sup>+</sup>90] werden in [So97] verwendet, um einen Algorithmus zu entwickeln, der resistenter gegen Rauschen ist. Dabei wird der Beginn des QRS-Komplexes durch einen Schwellwert, den die erste Ableitung überschreiten muss, bestimmt. Dieser

Schwellwert wird über die maximale Steigung angepasst, da so weniger falsche QRS-Komplexe detektiert werden.

Vor der eigentlichen QRS-Komplex-Detektion wird bei Pan [PT85] und der darauf aufbauenden Arbeit von Hamilton [HT86] das Signal mit einem Bandpass gefiltert, um Störgrößen im Signal zu reduzieren. Danach wird das gefilterte Signal abgeleitet, quadriert und abschließend mit einem gleitenden Mittelwertfilter geglättet. Das Ausgangssignal dieser letzten Stufe, der so genannten *Moving Window Integration* (abgekürzt MWI), dient auch als Feature-Signal für die QRS-Detektion. Eine modifizierte Version dieses Algorithmus ist seit 2002 auch als Open Source in einer C-Implementierung verfügbar [Ham02].

Die Detektion des QRS-Komplexes durch nichtlineare Transformation des differenzierten EKG-Signals wurde zuerst von Wrublewski in [WSB89] vorgestellt und in der Folge von Suppappola weiterentwickelt [SS90][SS91][SS94] und um eine Bedingung der Vorzeichenkonsistenz der verwendeten Differenzen ergänzt. Das Verfahren zeichnet sich durch seine geringe Detektionsverzögerung aus.

Li [LZT95] stellte 1995 ein waveletbasiertes Verfahren für die QRS-Detektion vor, das in weiteren Veröffentlichungen verwendet wurde ([BHH97], [MAO<sup>+</sup>04]). Dieses wird in der Folge noch genauer erläutert.

Das Design von optimalen quasi-linearen und quadratischen polynomialen Filtern für die QRS-Detektion mit Hilfe eines genetischen Algorithmus wird in [PCV95] beschrieben. Die QRS-Detektion erfolgt auf dem Ausgangssignal des Filters mit einer adaptiven Maximumssuche.

Eine QRS-Detektion über das topologische Mapping des eindimensionalen EKG-Signals zu einer zweidimensionalen Vektorschleife wird in [LJYM96] vorgestellt. Aus dem zweidimensionalen Plot wird die modifizierte Raumgeschwindigkeit (*Modified Spatial Velocity - MVS*) bestimmt und für die QRS-Detektion genutzt.

In [SSC97] wird nach einer stabilen Flanke gesucht, um den QRS-Komplex zu finden. Dazu muss das differenzierte Signal über einem festen Schwellwert liegen und dieses Kriterium für eine Mindestzeit erfüllt sein, um eine Detektion auszulösen. Der Anfang bzw. das Ende des QRS-Komplex wird über den ersten bzw. letzten Abtastwert, der zu der gefundenen Flanke gehört, bestimmt. Das sich dazwischen befindenden Maximum des Signals gibt die Position der R-Zacke an.

Einen der waveletbasierten QRS-Detektion verwandten Ansatz beschreibt [ATNL99], der das EKG-Signal mit einer 32-Kanal-Filterbank verarbeitet. Die QRS-Detektion erfolgt über das gleichzeitige Auftreten von Signalkomponenten in den ersten vier Subbändern, für die sechs verschiedene Merkmale bestimmt werden. Daran schließt sich eine ausgefeilte Detektionslogik an, die auch eine Mehrkanaldetektion ermöglicht.

Moraes et al. [MFVC02] kombinieren zwei verschiedene Detektionsverfahren, um die Anfälligkeit auf Signalstörungen zu reduzieren. Eines ist das Verfahren aus [EZ79], das andere basiert auf [LK83] und [PT85].

In [Chr04] werden zwei aufeinander aufbauende Algorithmen für die Mehrkanaldetektion in (Pseudo-)Echtzeit vorgestellt. Im Echtzeitverfahren werden aufsummierte Absolutwerte von differenzierten EKG-Signalen mit einem adaptiven Schwellwert verglichen. Dieser Schwellwert wird aus drei Einzelparametern gebildet. Die Pseudo-Echtzeit-Implementierung arbeitet mit einer gewissen Verzögerung, um eventuell im ersten Durchgang nicht detektierte QRS-Komplexe noch detektieren zu können.

Tabelle 7.1 zeigt eine Übersicht über die Detektionsgüte der meisten oben angeführten Detektoren. Die Werte sind größtenteils den Originalpublikationen entnommen. Bei [PT85], [LZT95] und [BHH97] gibt es Unstimmigkeiten zwischen den angegebenen Werten für die Sensitivität und die positive Prädiktivität und den aufgeführten Ergebnissen auf den einzelnen Datensätzen. Für diese Verfahren werden die in [MAO<sup>+</sup>04] angegebenen Werte aufgelistet. Auch in [Chr04] treten diesbezüglich Ungereimtheiten auf, weswegen die Werte aus den angegebenen Konfusionsmatrizen für die einzelnen Datensätze berechnet wurden. Ein standardkonformer und vollständig dokumentierter Test von Mehrkanaldetektoren auf allen in Anhang B.3 erwähnten Datenbanken ist in der Literatur nicht zu finden. Dagegen gibt es zahlreiche Veröffentlichungen, die Ergebnisse auf Teilen der Datenbanken vorstellen. Zum Großteil werden Resultate von Einkanaldetektoren präsentiert. In den meisten Fällen wird die MITDB zur Evaluation herangezogen, wobei immer wieder Datensätze von der Analyse ausgeschlossen oder nur auf einigen der Datensätze Ergebnisse produziert werden. Dies betrifft aber selten die Datensätze mit schrittmacherinduzierten Schlägen.

## 7.2 Auswahl von Verfahren für das mobile Online-Monitoring

Die folgenden Verfahren wurden testweise unter Matlab implementiert und auf wenigen Datensätzen der MIT/BIH Database [Phy05a] getestet:

- Das Ableitungsfiler nach [EZ79]
- Das sequentielle Filterverfahren nach [PT85]
- Die nicht-lineare Filterung aus [WSB89] und [SS94]
- Das waveletbasierte Verfahren nach [LZT95]
- Das Ableitungsfiler nach [So97]
- Das Flankenkriterium aus [SSC97]

Auf Grund von Detektionsproblemen auf den Testdatensätzen wurden die Verfahren aus [EZ79], [So97] und [SSC97] nicht weiter verfolgt und für eine nähere Betrachtung im Rahmen dieser Arbeit damit folgende Algorithmen ausgewählt:

- Das Verfahren nach Pan/Tompkins [PT85]
- Das MOBD-Verfahren nach Suppappola [SS94]
- Das waveletbasierte Verfahren nach Li [LZT95]

Das Pan/Tompkins-Verfahren ist ein in der Literatur sehr häufig referenziertes Verfahren mit guten Detektionsergebnissen. Die Auslegung der Filter erlaubt eine einfache Implementierung und erfordert nur eine geringe Rechenzeit. Allerdings weist das Verfahren auf Grund seiner Signalverarbeitung und den integrierten Search-Back-Algorithmus

**Tabelle 7.1:** Übersicht über die Detektionsgüte von einigen der in der Literatur vorgestellten Verfahren. Weiterhin werden Informationen darüber gegeben, auf welchen Datenbanken getestet wurde und ob dieser Test standardkonform ablief. SE: Sensitivität, PP: positive Prädiktivität, siehe hierzu auch Anhang A.1.

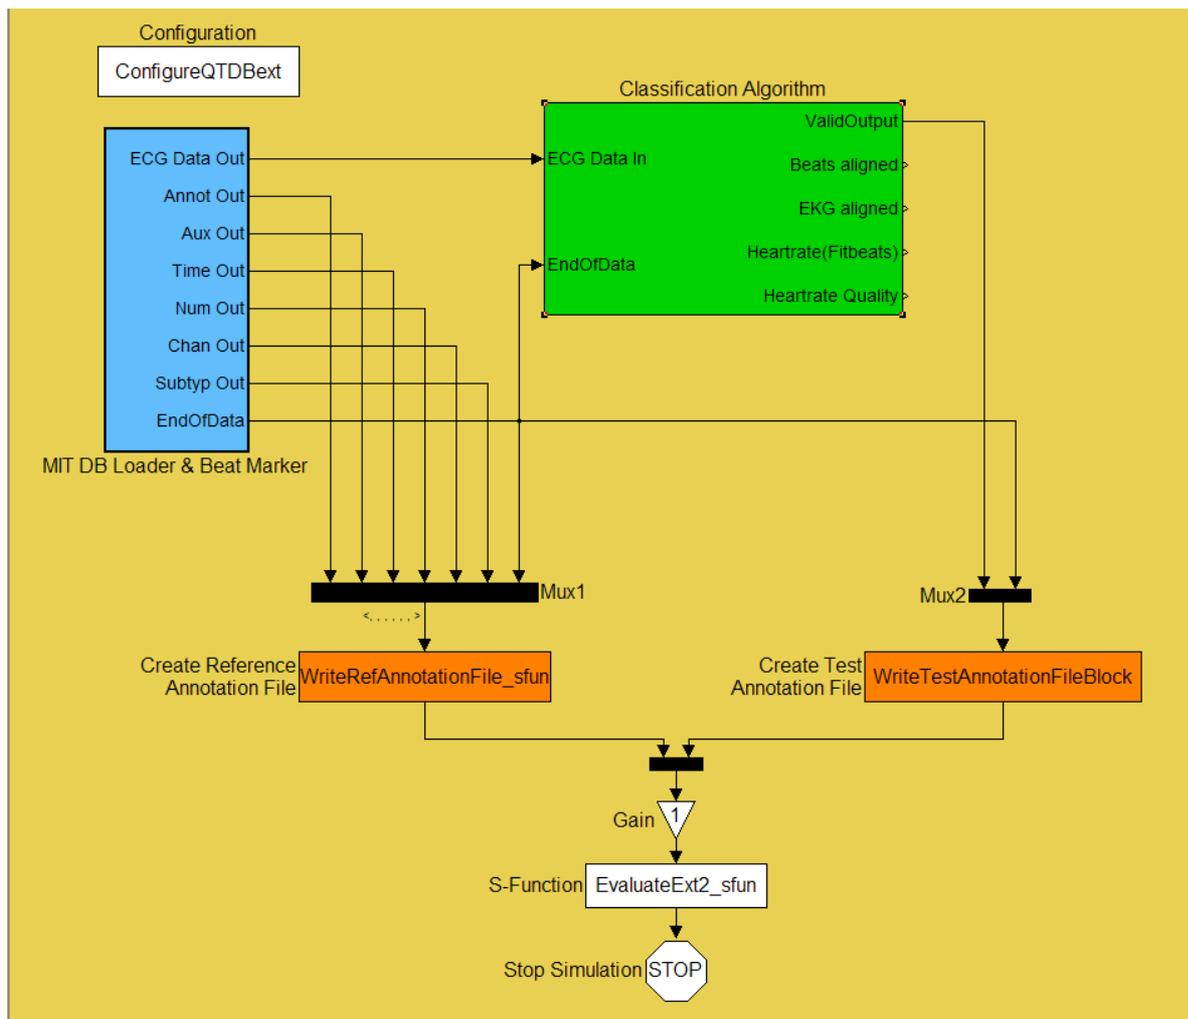
Verfahren	SE[%]	PP[%]	Datenbanken	standardkonformer Test	Kanalanzahl
Pan/Tompkins [PT85] [Ham02]	99,75	99,54	MITDB	nein	1
	99,77	99,80	MITDB	ja	1
	99,71	99,85	AHADB (1201-7210)	nein	
Genetische Filter [PCV95]	99,60	99,50	MITDB	nein	1
Topologisches Mapping [LJYM96]	99,69	99,88	MITDB	nein	1
Filterbänke [ATNL99]	99,59	99,56	MITDB	ja	>1
Detektorenkombination [MFVC02]	99,22	99,73	MITDB	?	1
Li-Wavelets [LZT95] [BHH97] [MAO <sup>+</sup> 04]	99,89	99,94	MITDB	nein	1
	99,83	99,88	MITDB	nein	1
	99,80	99,86	MITDB	nein	1
	99,61	99,48	EDB	nein	
Summenschwellwert [Chr04]					
Verf. 1	99,73	99,80	MITDB	nein	>1
Verf. 2	99,78	99,78	MITDB	nein	>1

eine relativ große Detektionsverzögerung auf. Die sehr geringe Verzögerung ist dagegen einer der Vorzüge des MOBD-Verfahrens, der aber mit einem erhöhten Aufwand zur Erkennung von Artefakten und Anpassung der Detektion bei wechselnden Signalamplituden einhergeht. Das Verfahren bleibt trotzdem das schlankeste der untersuchten und ist problemlos auf einer mobilen Plattform implementierbar. Das waveletbasierte Verfahren ist die Signalverarbeitung und -auswertung betreffend deutlich aufwendiger als die beiden ersten Verfahren, erreicht aber in der Literatur mit die höchste Detektionsgüte ([LZT95], [KHO02], [BHH97], [MAO<sup>+</sup>04]) und wurde bereits erfolgreich auf einem DSP für eine Echtzeitanwendung implementiert [BHH97]. Darüber hinaus bietet die inhärente Signalverarbeitung dieses Verfahrens die Möglichkeit, effektiver Methoden zur weiteren Signalanalyse, z.B. zur VT-/VF-Detektion (siehe Kapitel 9), einzusetzen, die bei den beiden anderen Verfahren weitere Implementierungen notwendig machen würden.

## 7.3 Verwendete Entwicklungs- und Testumgebungen

### 7.3.1 Entwicklung mit Matlab und Simulink

Ein Großteil der Entwicklungsarbeiten wurde in Matlab und teilweise in Simulink geleistet. Matlab ist das Kernprodukt der Firma MathWorks [Mat05]. Matlab ist die Abkürzung von *Matrix Laboratory* und beschreibt auf diese Weise die matrixorientierte Ausrichtung des Produkts. Auf diese Weise eignet sich Matlab besonders gut für die Lösung von (nicht-)homogenen Differentialgleichungssystemen. Große Vorteile bietet



**Abbildung 7.1:** Oberste Ebene des Simulink-Modells zur Evaluation von QRS-Detektionsverfahren. Zur Beschreibung der einzelnen Blöcke siehe Text.

Matlab auch bei der Verarbeitung von Vektoren und Arrays, da für viele Aufgaben in diesem Bereich im Gegensatz zu anderen Programmiersprachen keine aufwendigen Programmschleifen verwendet werden müssen. Diese „Vektorisierung“ des Codes bedeutet in vielen Fällen einen beträchtlichen Performancegewinn. Dieser ist besonders wertvoll, da Matlab-Funktionen über eine eigene Skriptsprache programmiert werden, die teilweise zur Laufzeit interpretiert wird. Dadurch sind im Vergleich zu nativen Program-

miersprachen grundsätzlich Leistungseinbußen vorhanden. Der Vorteil ist aber, dass die Entwicklung durch die Möglichkeit, Codefragmente direkt von der Kommandozeile aus zu erproben, effizient unterstützt wird. Matlab bietet eine Vielzahl von speziellen Erweiterungen, so genannte Toolboxes. So finden sich einen Vielzahl von Funktionen aus dem Bereich der digitalen Signalverarbeitung, der Regelungstechnik, der künstlichen Intelligenz, aber auch der Finanzmathematik. Für den Aufbau von Messsystemen etc. stehen außerdem Toolboxen für die Ansteuerung verschiedener externer Komponenten oder den Datenaustausch mit anderen Programmen zur Verfügung.

Simulink ist ein weiteres Produkt von MathWorks, das den grafisch orientierten Aufbau und die Simulation von dynamischen Systemen ermöglicht. Diese können sowohl kontinuierlich als auch zeitdiskret sein. Wie bei Matlab gibt es auch hier viele spezielle Erweiterungen, sog. Blocksets. Beispiele hierfür sind das DSP-Blockset mit Blöcken für typische Aufgaben der digitalen Signalverarbeitung oder das Fixed-Point Blockset, das die Simulation von Systemen mit begrenzter Genauigkeit ermöglicht. Simulink bietet weiterhin eine Anzahl von Tools für das Rapid-Prototyping an, darunter Codegeneratoren für verschiedene DSP-Plattformen hauptsächlich von Texas Instruments.

Im Rahmen dieser Arbeit wurde zunächst ein Simulink-Framework entwickelt, welches das Laden von EKG-Daten aus WFDB-Datensätzen (siehe Anhang B) ermöglicht. Abbildung 7.1 zeigt die oberste Ebene des zugehörigen Simulink-Modells. Der Block **Configuration** dient der Konfiguration des Modells, sofern dies nicht von extern über ein Matlab-Skript realisiert wird. Im Block **MIT DB Loader & Beat Marker** werden die EKG-Daten geladen und die zugehörigen Annotationen ausgelesen. Diese können je nach Bedarf abgeändert werden, so dass das Zusammenfassen von WFDB-Annotationscodes nach Tabelle B.1 zu neuen Klassen möglich ist.

### 7.3.2 Entwicklung mit dem TeDiaNet-Framework

Im Rahmen des TeDiaNet-Projekts wurde eine universelle Schnittstelle spezifiziert, die Methoden für den Zugriff auf EKG-Daten und weitere Informationen (Events, Schrittmacherimpulse etc.) zur Verfügung stellt. Diese Schnittstelle ist in Java definiert und bietet die Möglichkeit, die weitere Verarbeitung und Auswertung von dem (binären) Format, in dem die Daten vorliegen, komplett zu trennen.

Über dieses so genannte TeDiaNet-Interface können beliebige Abschnitte des Signals ausgelesen werden und nach der Auswertung die gewonnenen Informationen (z.B. Listen mit den ermittelten QRS-Komplexen, aber auch gewonnene Signalverläufe) abgespeichert werden. Das UML-Klassendiagramm in Abbildung 7.2 zeigt eine Übersicht der definierten Java-Interfaces und -Klassen. Das TeDiaNet-Interface wurde im Rahmen des Projekts exemplarisch durch die beteiligte Firma Medset in ihre Langzeit-EKG-Auswertungssoftware CARIOLIGHT implementiert und im Rahmen dieser Arbeit zur Evaluierung der Java-Implementierungen der QRS-Detektionsverfahren Pan/Tompkins und MOBD eingesetzt.



## 7.4 Das Detektionsverfahren nach Pan/Tompkins

### 7.4.1 Funktionsprinzip des Verfahrens

Als Grundlage für diesen QRS-Detektor dienen die Veröffentlichungen [PT85] und [HT86]. Den groben Ablauf der QRS-Komplex-Detektion zeigt Abbildung 7.3.

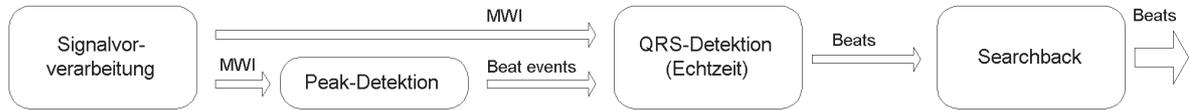


Abbildung 7.3: Stufen des QRS-Detektors.

Die erste Stufe der Signalvorverarbeitung besteht in einer Bandpassfilterung des Signals mit einem Durchlassbereich von ca. 5–11 Hz bei einer Abtastrate von 200 Hz. Dieses Filter wird durch einen Tiefpass (TP) und einen dahinter geschalteten Hochpass (HP) realisiert, die durch die folgenden Übertragungsfunktionen charakterisiert sind:

$$H_{TP}(z) = \frac{1 - 2z^{-6} + z^{-12}}{2 - 4z^{-1} + 2z^{-2}} \quad (7.1)$$

$$\begin{aligned} H_{HP}(z) &= z^{-16} - \frac{1}{32} \cdot \frac{1 - z^{-32}}{1 - z^{-1}} \\ &= \frac{1}{32} \cdot \frac{-1 + 32z^{-16} - 32z^{-17} + z^{-32}}{1 - z^{-1}} \end{aligned} \quad (7.2)$$

Sämtliche Filterkoeffizienten stellen sich somit als Ganzzahlen bzw. Potenzen von 2 dar. Dadurch lassen sich die Filter durch Bitschiebe- und Addieroperationen nachbilden.

Auch der Differentiator der nächsten Stufe besitzt nur Integerkoeffizienten und die Übertragungsfunktion

$$H_{Diff}(z) = \frac{1}{10} \cdot 2 + z^{-1} - z^{-3} - 2z^{-4} \quad (7.3)$$

Daraus resultiert ein linearer Frequenzgang von 0–30 Hz.

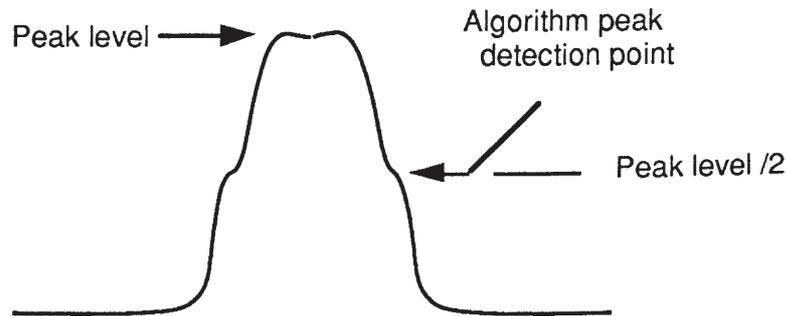
Nach der anschließenden Quadrierung erfolgt die Filterung mit einem gleitenden Mittelwertfilter, der in diesem Fall *Moving Window Integrator*, kurz *MWI* genannt wird. Dessen Übertragungsfunktion lautet:

$$H_{MWI}(z) = \frac{1}{N} \sum_{k=0}^{N-1} z^{-k} \quad (7.4)$$

In der Originalveröffentlichung von Pan wird die Breite des MWI-Filters zu  $N = 30$  bei einer Abtastrate von 200 Hz gewählt, was einer Zeit von 150 ms, also etwas mehr als der Breite eines normalen QRS-Komplexes entspricht.

Abbildung 7.4 zeigt den typischen Verlauf des MWI-Signals. Für jeden QRS-Komplex ergibt sich im Idealfall ein trapezförmiger Impuls. Nach erfolgter Detektion des MWI-Maximums wird der QRS-Komplex dann abschließend zugewiesen, wenn der Signalpegel

des MWI-Signals die Hälfte des Maximums unterschreitet oder eine Zeit von 175 ms verstrichen ist.



**Abbildung 7.4:** Ausgangssignal des Pan/Tompkins-Mittelwertfilters.

Um die Detektion zuverlässiger zu machen, werden noch folgende zusätzliche Maßnahmen getroffen:

- Vergleich der Amplitudenmaxima des MWI-Signals und des Bandpass gefilterten Signals mit laufenden Schwellwerten
- Einleiten einer wiederholten Suche (Searchback), falls für eine zu lange Zeit kein QRS-Komplex detektiert wurde
- Einführen einer Refraktärzeit nach einem QRS-Komplex, in der kein weiterer Komplex detektiert werden kann
- Einführen einer Latenzzeit nach dem QRS-Komplex, in der ein neuer Kandidat nur unter bestimmten Bedingungen akzeptiert wird

Sowohl für das MWI-Signal als auch für das gefilterte EKG-Signal werden laufend Signalpegel ( $SPK$ ) und Rauschpegel ( $NPK$ ) nach derselben Methodik geschätzt. Aus diesen Signalpegeln werden dann die zugehörigen Schwellwerte  $Thr1$  und  $Thr2$  für jedes Signal bestimmt. Sei  $U_1$  der Signalpegel eines Peaks in einem der beiden Signale, so werden  $SPK$ ,  $NPK$ ,  $Thr1$  und  $Thr2$  an Hand folgender Formeln berechnet:

$$SPK_{neu} = 0,125U_1 + 0,875SPK_{alt}, \text{ falls } U_1 \text{ Signal-Peak} \quad (7.5)$$

$$NPK_{neu} = 0,125U_1 + 0,875NPK_{alt}, \text{ falls } U_1 \text{ Noise-Peak} \quad (7.6)$$

$$Thr1 = NPK_{neu} + 0,25(SPK_{neu} - NPK_{neu}) \quad (7.7)$$

$$Thr2 = 0,5 \cdot Thr1 \quad (7.8)$$

Für die Detektion eines QRS-Komplexes muss  $Thr1$  in beiden Signalen überstiegen werden.  $Thr2$  dagegen wird während des Searchback benutzt. Diese wiederholte Suche wird eingeleitet, wenn die verstrichene Zeit seit der letzten QRS-Detektion das 1.66-fache des Durchschnitts der letzten acht RR-Intervalls übersteigt. In diesem Fall wird der Signalpegel  $SPK$  auf etwas andere Art berechnet:

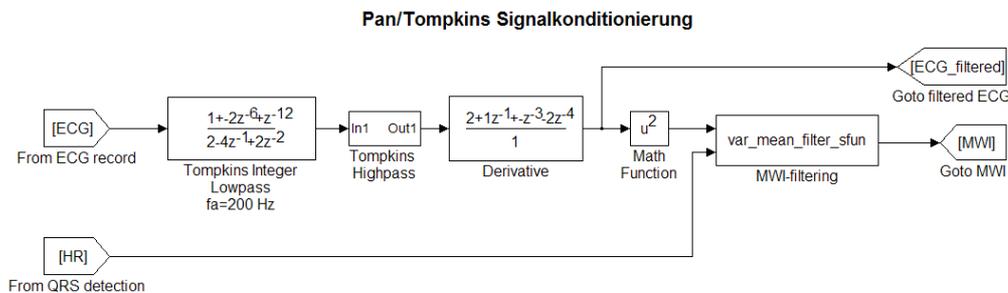
$$SPK_{neu} = 0,25U_1 + 0,75SPK_{alt} \quad (7.9)$$

Man beachte, dass wechselweise der Signal- und Rauschpegel angepasst werden, je nachdem ob  $U_1$  als zu einem QRS-Komplex gehörig klassifiziert wird.

Dies wird durch die beiden letzten Maßnahmen ermöglicht: Wird ein Peak innerhalb der Refraktärzeit von 200 ms nach dem letzten QRS-Komplex detektiert, so kann es sich keinesfalls um einen QRS-Komplex handeln. Folgt der nächste Peak innerhalb der Latenzzeit von 360 ms, so wird er nur akzeptiert, wenn seine maximale Steigung mindestens die Hälfte der Steigung der letzten erkannten R-Zacke beträgt. Andernfalls wird davon ausgegangen, dass es sich um eine T-Welle handelt.

## 7.4.2 Simulink-Implementierung des Pan/Tompkins-Algorithmus

Das Pan/Tompkins-Verfahren wurde unter Simulink in dem in Kapitel 7.3.1 vorgestellten Framework implementiert und getestet. Abbildung 7.5 zeigt den Aufbau der Signalkonditionierung in dem zugehörigen Modell. Die MWI-Filterung wurde als MEX-File implementiert.



**Abbildung 7.5:** Simulink-Modell der Signalkonditionierung beim Pan/Tompkins-Verfahren.

Im Anschluss daran erfolgt im Block `Peak_det_sfun` die Peak-Detektion im MWI-Signal. Der eigentliche QRS-Detektor (Subsystem `QRS detection`) erhält als Eingangsinformation das MWI-Signal, das gefilterte EKG-Signal und das binäre Peak-Detektionssignal. Der Detektor wird nur aktiviert, wenn im MWI-Signal ein Peak erkannt wurde. Daraufhin wird überprüft, ob der Peak zu einem QRS-Komplex gehört. Im Block `Fit_beats_sfun` findet abschließend eine genauere Detektion der R-Zacke statt. Das zugehörige Simulink-Modell zeigt Abbildung 7.6.

Mit der festen Fensterbreite für das MWI-Filter kann es bei hohen Herzfrequenzen zu Schwierigkeiten bei der Trennung aufeinanderfolgender QRS-Komplexe kommen, wodurch diese nicht mehr richtig detektiert werden können. Dies beeinträchtigt den Einsatz dieses QRS-Detektors besonders bei Abschnitten mit ventrikulären Tachykardien oder Kammerflimmern. Andererseits kann eine zu kleine Fensterbreite unter Umständen zur unerwünschten Auflösung des MWI-Signals in Einzelmaxima für R-Zacken und T-Wellen führen. Daher wird die Breite des MWI-Fensters in Abhängigkeit von der aktuellen Herzrate bestimmt. Für Herzfrequenzen bis 100 bpm beträgt die Fensterbreite 35 Samples, danach wird sie linear heruntergeregelt bis zu einem Minimalwert von 8 Samples bei 200 bpm.

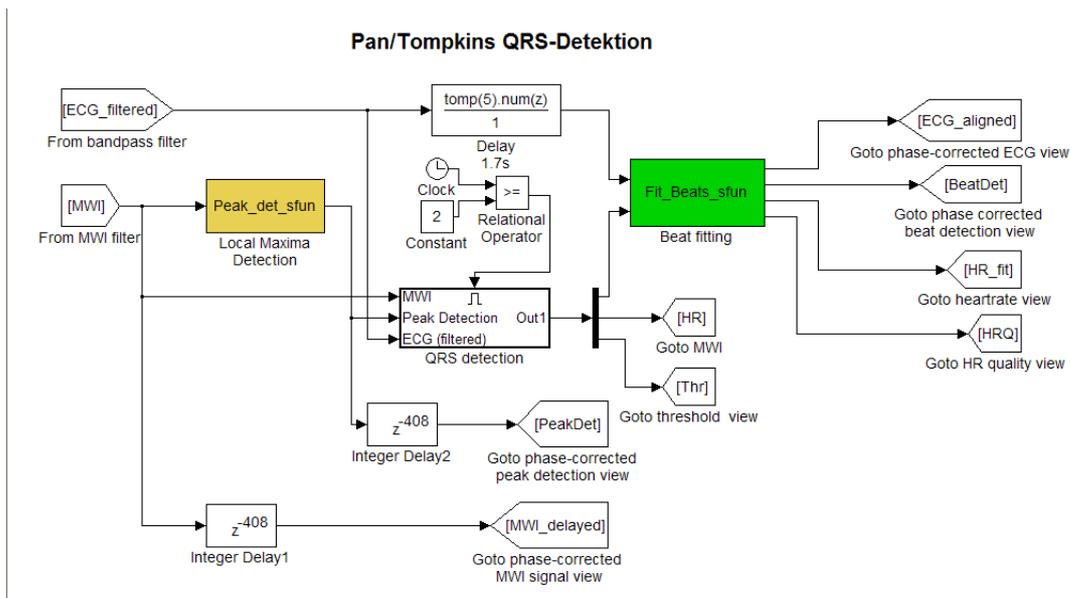


Abbildung 7.6: Simulink-Modell der QRS-Detektion für das Pan/Tompkins-Verfahren.

Diese modifizierte Implementierung des Pan/Tompkins-Verfahrens ist als Einkanal-Detektor ausgelegt. Ergebnisse für die QRS-Detektion auf den einzelnen Kanälen der MIT/BIH Arrhythmia Database (MITDB, siehe Anhang B.3.1) sind in Kapitel 7.7 aufgeführt.

### 7.4.3 Erweiterung für Mehrkanal-Detektion

Bei der Umsetzung im TeDiaNet-Framework wurde das Verfahren durch verschiedene Maßnahmen für eine Mehrkanaldetektion ausgebaut und weiter versucht, die Detektionsgüte zu verbessern. In Kürze wurden folgende Schritte unternommen:

- Interpolation von Schrittmacherimpulsen, falls Hardware-Trigger dafür vorhanden sind.
- Ein Kanal wird nur dann ausgewertet, wenn die Varianz seines Signals groß genug ist.
- Einführen eines Zeitfensters, in dem QRS-Komplexe in den weiteren EKG-Kanälen des Datensatzes liegen müssen, sobald eine Detektion in einem Kanal erfolgte.
- Einführen einer *Channel Credibility*, die Auskunft darüber gibt, wie zuverlässig die QRS-Detektion für diesen Kanal ist.

Im Folgenden werden die Maßnahmen im Detail beschrieben.

**Schrittmacherinterpolation:** Impulse von Herzschrittmachern – im Folgenden auch Pacer-Spikes genannt – zeichnen sich oft als hohe, scharfe Spitzen im EKG-Signal ab. Je nach Stimulationsort im Herzen und dessen Lage zur verwendeten Ableitung können

sie aber auch kaum sichtbar sein. Die durch sie induzierten Kammererregungen können im EKG quasi normal oder stark verformt erscheinen. Auch dies hängt von der Art der Stimulation ab. In vielen Fällen werden die Kammern nicht auf physiologischem Weg erregt, so dass Schenkelblock ähnliche oder ventrikulären Schlägen ähnelnde EKG-Bilder entstehen. Um diese Komplexe sicher erkennen und klassifizieren zu können, ist daher eine Detektion der Schrittmacherimpulse notwendig. Ebenso wichtig ist die Ermittlung des Zeitabstands zwischen Pacer-Spike und Kammerkomplex, da auf diese Weise entschieden werden kann, ob die Kammerkontraktion wirklich durch den Schrittmacher induziert wurde oder evtl. eine Eigenerregung oder ein Fusionsschlag vorliegt. Direkt aus dem EKG heraus ist dies jedoch nicht möglich, da die Pulse durch die bei den meisten EKG-Aufnahmegeräten verwendeten Eingangsfiler und Abtastraten verschmiert werden und daher nicht exakt lokalisiert werden können. Wie oben gesagt sind sie häufig auch gar nicht im EKG erkennbar. Viele Aufnahmesysteme besitzen daher spezielle – oft in reiner Hardware realisierte – Schrittmacherdetektoren, die auf die im Vergleich zu QRS-Komplexen deutlich steileren Flanken der Pacer-Spikes triggern. Auf diese Weise können die Schrittmacherimpulse gut lokalisiert werden und diese Information zusätzlich zum aufgenommenen EKG abgespeichert werden. Die Zeitpunkte dieser „Pacer-Trigger“ stehen dann bei der Auswertung zur Verfügung, so dass eine Auslöschung etwaiger Pacer-Spikes im EKG vor der weiteren Signalverarbeitung möglich ist. In diesem Fall wurde eine lineare Interpolation über ein Zeitfenster von 20 ms rund um den Pacer-Trigger gewählt.

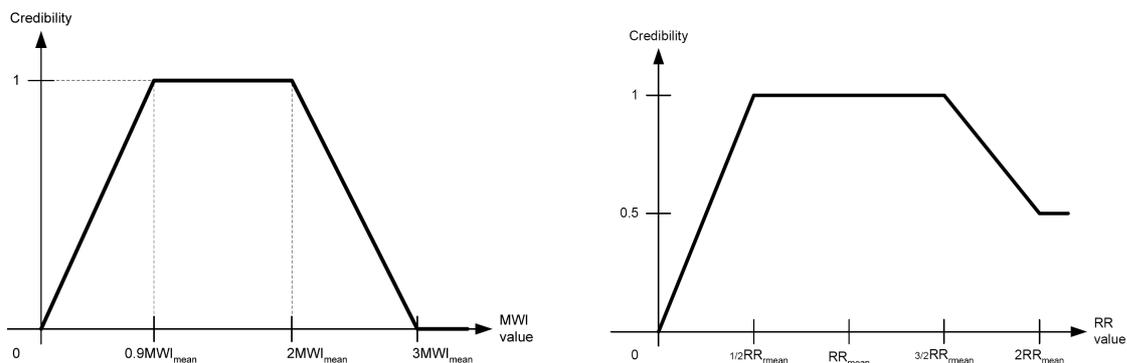
**Signalvarianz:** Bei EKG-Signalen mit kleiner Amplitude ist keine verlässliche Detektion und Klassifikation mehr möglich. Eine andere Möglichkeit ist, dass sich die Verstärker der Eingangsstufe durch Artefakte am Rand ihres Aussteuerbereichs befinden und daher keine durch die elektrische Herzaktivität verursachte Potenzialdifferenzen mehr gemessen werden können. In beiden Fällen ist die Varianz des EKG-Signals sehr gering. Daher wird dieses Kriterium herangezogen, um zu beurteilen, ob eine weitere Analyse des Signals sinnvoll ist. Fällt ein Kanal mehr als zehn Sekunden aus diesem Grund für die Analyse aus, wird ein Reset auf diesem Kanal durchgeführt, d.h. alle Schwellwerte etc. werden auf ihre Anfangswerte zurückgesetzt.

**Detektionszeitfenster:** Diese Zeitbedingung dient als Kontrolle dafür, wie viele der verwendeten EKG-Kanäle zeitgleich einen QRS-Komplex erkennen. Wird in einem Kanal ein QRS-Komplex erkannt, so werden alle QRS-Komplexe, die in den anderen Kanälen innerhalb eines Zeitfensters von 30 ms gefunden werden, als simultane Ereignisse gewertet. Diese Kanäle werden *getriggert* genannt, alle anderen gelten als *nicht getriggert*. Alternativ werden auch die Begriffe *triggered* und *non-triggered* verwendet.

**Channel Credibility:** Diese Maßnahme beurteilt die „Glaubwürdigkeit“ einer erfolgten QRS-Detektion. Dazu werden für verschiedene Parameter einzelne „Credibilities“ gebildet, die dann in die endgültige Channel Credibility eingehen. Die Parameter im Einzelnen sind

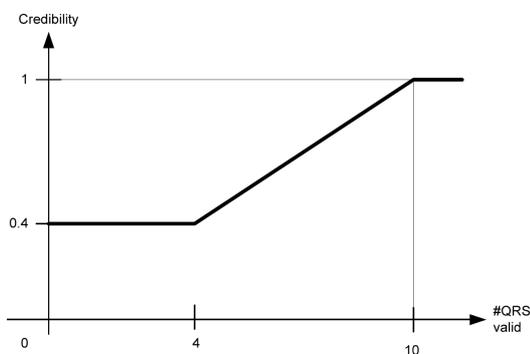
1. die Amplitude des MWI-Signals

2. das aktuelle RR-Intervall im Vergleich zum durchschnittlichen RR-Intervall
3. die Anzahl der zuletzt im aktuellen Kanal korrekt identifizierten QRS-Komplexe



(a) Verlauf der Credibility für das MWI-Signal

(b) Credibility-Funktion für das RR-Intervall



(c) Credibility-Funktion für die Anzahl valider QRS-Komplexe

**Abbildung 7.7:** Funktionen zur Ermittlung der einzelnen Credibilities für die verschiedenen Parameter. Diese bilden dann zusammen die gesamte Credibility für jeden Kanal.

Für das MWI-Signal wird das Verhältnis zwischen der aktuellen Peak-Amplitude des MWI-Signals und dem Durchschnitt der MWI-Maxima der letzten zehn QRS-Komplexe ( $MWI_{mean}$ ) gebildet und der Wert für die Credibility des MWI-Signals  $C_{MWI}$  mit Hilfe der Funktion nach Abbildung 7.7(a) bestimmt. Diese Funktion geht davon aus, dass die MWI-Amplitude relativ konstant bleibt. Die Wahrscheinlichkeit, dass größere MWI-Amplituden als der Durchschnitt QRS-Komplexe bedeuten, ist größer als bei Abweichungen des MWI-Signals nach unten. Daher gilt  $C_{MWI} = 1$  für  $0,9 \cdot MWI_{mean} \leq MWI_{act} \leq 2 \cdot MWI_{mean}$ . Dagegen nimmt  $C_{MWI}$  für Werte  $MWI_{act} < 0,9 \cdot MWI_{mean}$  linear ab, um falsch positive Detektion zu vermeiden. Elektrodenartefakte und andere Störungen im EKG-Signal können dagegen sehr hohe MWI-Amplituden erzeugen, für die durch die fallende Credibility für Werte größer als  $2 \cdot MWI_{mean}$  falsch positive Detektionen vermieden werden sollen.

Für die Auswertung des RR-Intervalls wird der Durchschnitt der letzten acht RR-Intervalle ( $RR_{mean}$ ) berechnet und das aktuelle RR-Intervall dazu ins Verhältnis gesetzt. Die Credibility  $C_{RR}$  wird dann mit Hilfe der in Abbildung 7.7(b) gezeigten Funktion

bestimmt. Über einen weiten Bereich von  $0,5 \cdot RR_{mean}$  bis  $1,5 \cdot RR_{mean}$  wird das aktuelle RR-Intervall voll akzeptiert. Für kleinere RR-Intervalle dagegen nimmt  $C_{RR}$  linear ab, um die Gefahr der Detektion von T-Wellen oder anderen Störungen als QRS-Komplexe zu verringern. Für RR-Intervalle größer als  $2 \cdot RR_{mean}$  dagegen wird ein konstanter Wert von  $C_{RR} = 0,5$  gehalten, um Kanälen mit Pausen in der Detektion den „Wiedereinstieg“ zu ermöglichen.

Die letzte Teil-Credibility betrachtet die Anzahl der letzten zehn im aktuellen Kanal gefundenen QRS-Kandidaten, die letztendlich auch als QRS-Komplexe klassifiziert wurden. Abbildung 7.7(c) zeigt den Verlauf dieser Credibility-Funktion. Ein Kanal, bei dem alle zehn Kandidaten auch QRS-Komplexe waren, erhält somit die höchstmögliche Glaubwürdigkeit  $C_{QRS} = 1$ . Der niedrigste Wert für  $C_{QRS}$  beträgt 0,4, um Kanäle, die auf Grund von Störungen oder aus anderen Gründen Fehldetektionen aufwiesen, nicht zu stark zu benachteiligen.

Die Gesamt-Credibility eines Kanals  $C_{ges}$  wird abschließend auf folgende Weise aus den einzelnen ermittelten Credibilities bestimmt:

$$C_{ges} = \frac{C_{MWI} + C_{RR} + C_{QRS}}{3} \quad (7.10)$$

Für die endgültige Entscheidung, ob ein QRS-Komplex vorliegt, werden die Credibilities aller getriggerten und nicht getriggerten Kanäle nach folgender Formel ausgewertet:

$$Decision = \frac{\sum_{i=0}^{N-1} C_{i,triggered}}{\sum_{i=0}^{N-1} C_{i,triggered} + \sum_{k=0}^{M-1} C_{k,non-triggered}} \cdot 100\% \quad (7.11)$$

Dabei bezeichnen  $N$  die Anzahl der getriggerten und  $M$  die Anzahl der nicht getriggerten Kanäle. Die Gesamtzahl der beurteilten Kanäle beträgt immer  $N + M$ . Für Werte  $Decision > 50\%$  ist die Detektion erfolgreich.

Ergebnisse der Mehrkanaldetektion mit Hilfe des modifizierten Pan/Tompkins-Algorithmus auf verschiedenen Datenbanken werden in Kapitel 7.7 vorgestellt.

## 7.5 Das MOBD-Verfahren

Dieses Verfahren basiert auf den Arbeiten von Wrublewski [WSB89] und Suppappola [SS90][SS91][SS94]. Es wurde im Rahmen dieser Arbeit modifiziert, in seiner Detektionsleistung verbessert und schließlich für die Mehrkanaldetektion erweitert ([Kun02], [Per05]).

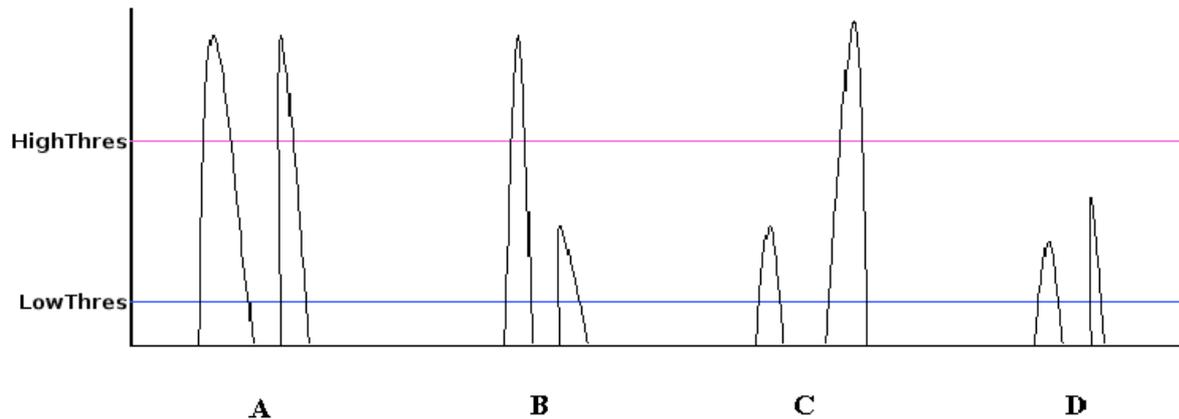
### 7.5.1 Grundlagen und Einkanaldetektion

Das MOBD-Verfahren basiert auf dem Prinzip, die Differenzen zwischen aufeinanderfolgenden Messwerten des EKG zu bilden und innerhalb eines gewissen Zeitfensters jeweils das Produkt dieser Differenzen zu betrachten (MOBD – Multiplication Of Backward Difference). Diese nicht-lineare Transformation wird jedoch mit der Nebenbedingung versehen, dass alle für die Multiplikation verwendeten Differenzen dasselbe Vorzeichen aufweisen müssen. Ist dies nicht der Fall wird das Ausgangssignal auf 0 gesetzt. Durch

diese Bedingung der Vorzeichenkonsistenz wird erreicht, dass das resultierende MOBD-Signal bis auf Flanken mit mindestens der Länge des verwendeten Zeitfensters 0 ist. Das Featuresignal dieses Verfahrens wird also wie folgt bestimmt:

$$MOBD(k) = \begin{cases} \prod_{i=0}^{N-1} D(k-i) & \text{wenn } \text{sgn}(D(k-i)) \text{ identisch } \forall i \in [0, N-1] \\ 0 & \text{sonst} \end{cases} \quad (7.12)$$

Hierbei ist  $N$  die Breite des MOBD-Fensters,  $D(k)$  die Differenz der EKG-Samples zu den Zeitpunkten  $k$  und  $k-1$ . Im Rahmen dieser Arbeit wurde  $N=4$  gewählt.



**Abbildung 7.8:** Mögliche Peak-Kombinationen des MOBD-Signals, die für die QRS-Detektion beurteilt werden müssen.

**Tabelle 7.2:** Gültigkeit der MOBD-Peak-Kombinationen im Bezug auf QRS-Detektion

Abb. 7.8	1. Peak	2. Peak	Zulässig
A	$>HighThres$	$>HighThres$	ja
B	$>HighThres$	$>LowThres$	ja
C	$>LowThres$	$>HighThres$	ja
D	$>LowThres$	$>LowThres$	nein

Das Kernkriterium für die Erkennung eines QRS-Komplexes ist, dass im MOBD-Signal zwei Peaks detektiert werden, von denen einer einen unteren Schwellwert ( $LowThres$ ) und der andere einen oberen Schwellwert ( $HighThres$ ) überschreiten muss. Diese Schwellwerte sind fest aneinander gekoppelt; es gilt stets:

$$LowThres = 0,2 \cdot HighThres \quad (7.13)$$

Diese Schwellwerte werden abhängig von der Signalamplitude bei der Detektion eines QRS-Komplexes angepasst. Der untere Schwellwert muss zwischen den Peaks wenigstens einmal unterschritten werden. Abbildung 7.8 zeigt die möglichen Kombinationen von Peaks und Tabelle 7.2 deren Zulässigkeit für die Detektion eines QRS-Komplexes.

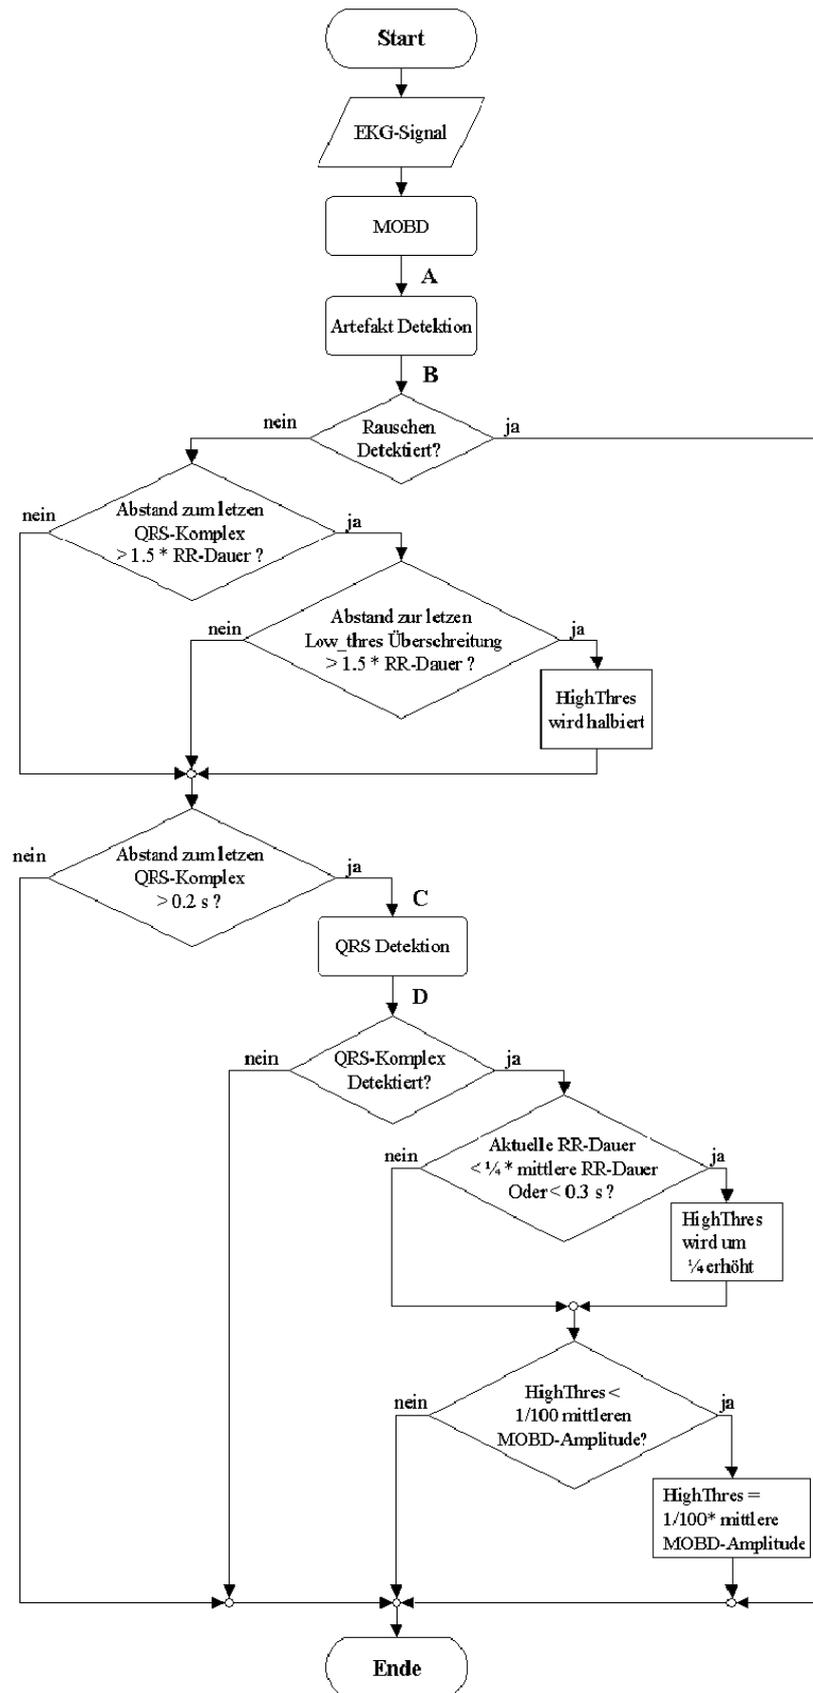


Abbildung 7.9: Überblick über den MOBD-Algorithmus.

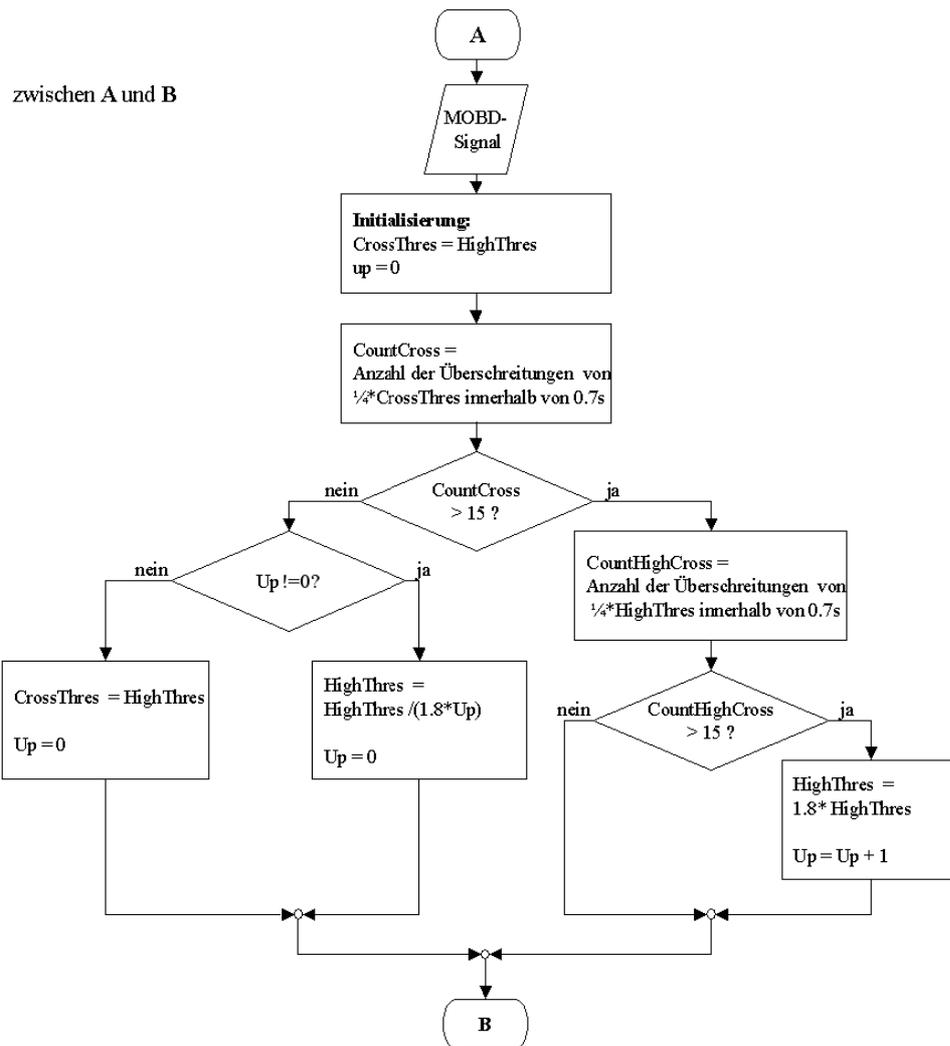
Abbildung 7.9 zeigt als Flussdiagramm einen Überblick über den gesamten Detektionsverlauf wie er für jedes Sample des EKG-Signals ausgeführt wird. Da die Maxima des MOBD-Signals in ihrer Ausprägung auch innerhalb eines Paares stark variieren können, ist es nötig, auf Veränderungen im Signal mit schneller Schwellwertanpassung zu reagieren. Wenn der Abstand zur letzten Überschreitung von *LowThres* größer ist als das 1,5-fache des Durchschnittes der letzten RR-Intervalle, wird davon ausgegangen, dass das Signal schwächer geworden ist, und die beiden Schwellwerte *LowThres* und *HighThres* werden halbiert. Als Einschränkung für *HighThres* gilt jedoch, dass dieser Schwellwert  $\frac{1}{100}$  der mittleren MOBD-Amplitude nicht unterschreiten darf. Diese mittlere Amplitude wird folgendermaßen gebildet:

$$MOBD_{mean}(k) = \frac{1}{10} \sum_{n=0}^9 MOBD_{max}(k-n) \quad (7.14)$$

Hierbei beschreibt  $k$  das aktuelle Paar von Peaks und  $MOBD_{max}$  das Maximum des MOBD-Signals für einen der letzten erkannten QRS-Komplexe. Für den Beginn der QRS-Detektion wird dieser Amplitudenwert auf einen empirisch ermittelten Standardwert gesetzt. Andererseits kann der Schwellwert auch nach oben angepasst werden: wenn ein QRS-Komplex detektiert wird, und der Abstand zur letzten R-Zacke geringer ist als  $\frac{1}{4}$  der mittleren RR-Dauer oder 300 ms, dann werden die beiden Schwellwerte um  $\frac{1}{4}$  erhöht.

Noch vor der eigentlichen QRS-Detektion wird eine Erkennung von Artefakten durchgeführt, deren Flussdiagramm in Abbildung 7.10 dargestellt ist. Hierfür wird ein weiterer Schwellwert *CrossThres* benötigt. Solange noch kein Artefakt detektiert wurde, hat dieser den gleichen Wert wie *HighThres*. Überschreitet das MOBD-Signal innerhalb von 700 ms mehr als 15mal ein Viertel von *CrossThres*, geht der Algorithmus von einem Artefakt aus und erhöht *HighThres* um den Faktor 1,8. *CrossThres* jedoch bleibt während des Artefaktes konstant. Der Wert von *HighThres* erhöht sich weiter, solange ein Viertel davon mehr als 15mal innerhalb von 700 ms überschritten wird. Das Ende des Artefaktes wird daran erkannt, dass ein Viertel *CrossThres* in dem genannten Zeitfenster weniger als 15mal überschritten wird, worauf dann *HighThres* wieder auf seinen Wert vor dem Artefakt zurückgesetzt wird, und die normale QRS-Detektion ihre Arbeit wieder aufnehmen kann. Diese schnelle Anpassung an Artefakte ist notwendig, um auftretende Störungen nicht als QRS-Komplex zu interpretieren. Zudem würde die normale Schwellwertanpassung dazu führen, dass nach dem Artefakt einige QRS-Komplexe verpasst würden, bis die Schwellwerte nach bemerktem Fehlen von Detektionen wieder herabgesetzt würden. Noch gravierendere Störungen werden über den Rauschschwellwert abgefangen: Wird das Zehnfache der mittleren MOBD-Amplitude innerhalb eines Fünftels der mittleren RR-Dauer mindestens zweimal überschritten, so wird von einem stark verrauschten Signal ausgegangen und die gesamte QRS-Detektion setzt für 200 ms aus.

Auf die Vorverarbeitung mit der Schwellwertanpassung und der Untersuchung auf Rauschen und Artefakte folgt die eigentliche QRS-Detektion, welche in der Übersicht in Abbildung 7.9 zwischen C und D zu finden ist, und deren Ablauf in Abb. 7.11 genauer dargestellt ist. Zuallererst wird überprüft, ob der letzte erkannte QRS-Komplex

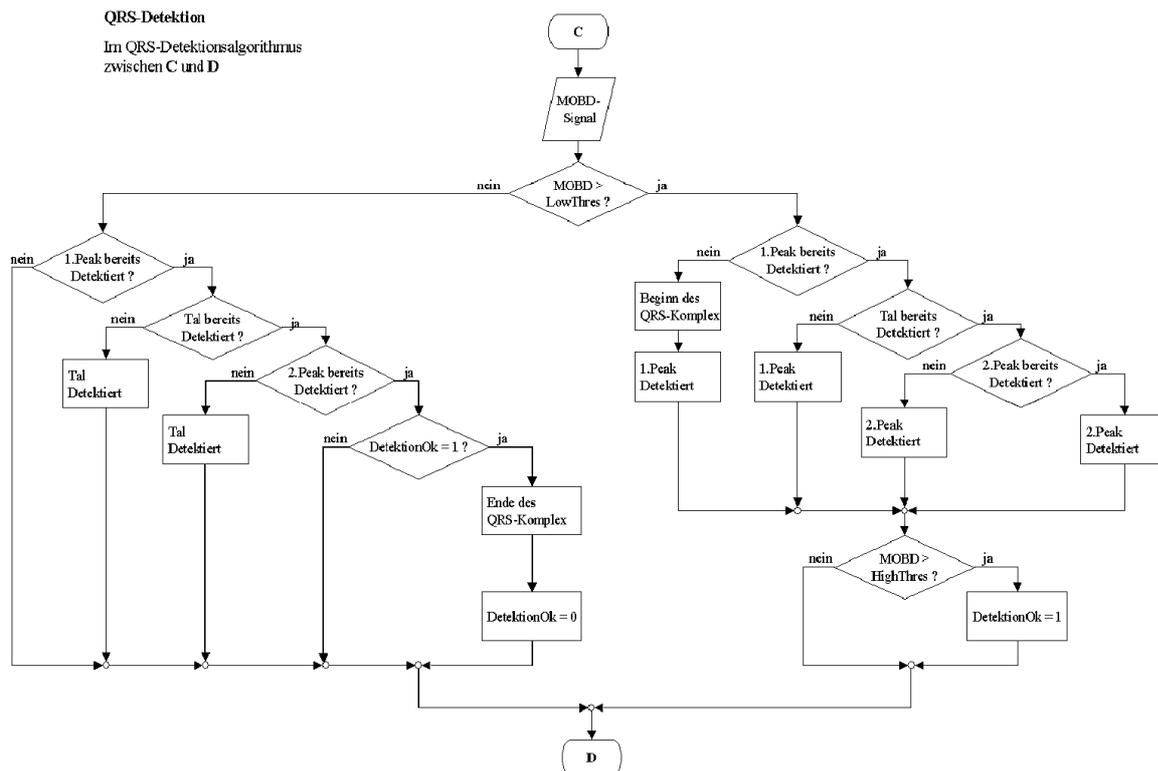


**Abbildung 7.10:** Anpassung an Artefakte (zwischen A und B, vgl. Abbildung 7.9).

weniger als 200ms zurückliegt, da in dieser Zeit wegen der absoluten Refraktärzeit der Herzmuskulatur kein QRS-Komplex auftreten kann. Weiterhin werden nur Samples untersucht, die den Schwellwert *LowThres* überschreiten. Ist dies der Fall, so überprüft der Algorithmus, in welcher Detektionsphase er sich gerade befindet: vor dem ersten Peak, vor dem zweiten, oder im zweiten Peak. Überschreitet der Wert des MOBD-Signals auch *HighThres*, so ist die erste Bedingung für einen QRS-Komplex erfüllt. Wenn das Sample *LowThres* nicht überschreitet, dann befindet sich der Algorithmus entweder vor einem QRS-Komplex, zwischen zwei Peaks (also im Tal) oder hat die Detektion von zwei Peaks gemäß der Kriterien beendet.

### 7.5.2 Das MOBD-Verfahren als Mehrkanaldetektor

Die Erweiterung des MOBD-Verfahrens für die Mehrkanaldetektion ist einfach gehalten: Bei erfolgreicher QRS-Detektion wird der Kanal, der als erstes den QRS-Komplex



**Abbildung 7.11:** QRS-Detektion des MOBD-Algorithmus (zwischen C und D, vgl. Abbildung 7.9)

detektiert hat, als Masterkanal ausgewählt. Für ein Zeitfenster von 500 ms wird jede weitere QRS-Detektion in diesem Kanal als QRS-Komplex akzeptiert. Nach diesem Zeitfenster wird derjenige Kanal zum neuen Master, der als erstes einen neuen QRS-Komplex detektiert. In der aktuellen Implementierung wird ein Kanal als Masterkanal bevorzugt. Für diesen verlängert sich das Intervall, in dem ausschließlich von diesem Kanal detektierte QRS-Komplexe akzeptiert werden auf 1000 ms. Erst danach ist ein Wechsel zu einem anderen Masterkanal möglich. Auf Grund der im Schnitt besseren Signalverhältnisse im ersten Kanal der untersuchten Datensätze wird dieser in der aktuellen Implementierung als bevorzugter Kanal gesetzt.

## 7.6 QRS-Detektion mit Wavelets

### 7.6.1 Grundlagen von Wavelets

Wavelets bieten die Möglichkeiten, sowohl lokale (Zeit-)Eigenschaften von Signalen zu untersuchen und gleichzeitig Aussagen über ihr Verhalten im Frequenzbereich machen zu können. Allgemein wird die kontinuierliche Wavelet-Transformierte eines Signals  $f(t)$  durch folgende Beziehung beschrieben:

$$Wf(u, s) = \int_{-\infty}^{+\infty} f(t) \frac{1}{\sqrt{s}} \psi^*\left(\frac{t-u}{s}\right) dt \quad (7.15)$$

$\psi$  ist dabei eine mittelwertfreie Funktion, d. h. es gilt:

$$\int_{-\infty}^{+\infty} \psi(t) dt = 0 \quad (7.16)$$

Meist besitzt  $\psi$  einen endlichen Support im Zeit- und Frequenzbereich, d.h. die Funktion ist nur auf einem endlichen Intervall ungleich Null und ist damit in der jeweiligen Domäne „gut lokalisierbar“. Die Wavelet-Transformierte  $Wf(u, s)$  einer Funktion  $f(t)$  entsteht durch ihre Korrelation mit einer um  $u$  translatierten und um den Faktor  $s$  dilatierten Version des Wavelets  $\psi$ .  $\psi_{0,0}$  wird Mother-Wavelet genannt.

Bei der dyadischen Wavelet-Transformation (WT) wird der Dilatationsparameter  $s$  mit Hilfe der Sequenz  $s_m = \{2^m\}$  diskretisiert. Für die meisten Aufgaben in der Wavelet-Signalverarbeitung muss auf Grund des Vorliegens des Signals zu diskreten Abtastzeitpunkten auch der Translationsparameter  $u$  diskretisiert werden. Aus Konventionsgründen wird dafür in der Literatur  $n$  anstelle von  $u$  verwendet. Für die Signalkompression bzw. -rekonstruktion wird meist die schnelle WT verwendet. Dabei wird das Ursprungssignal in einer sog. Analyse-Filterbank durch ein Hochpassfilter  $G$  und ein Tiefpassfilter  $H$  in zwei getrennte Bestandteile  $v$  und  $u$  („Details“ und „Approximation“) zerlegt. Die Filterfunktion des Tiefpassfilters  $H$  ist dabei mit einer sog. Skalierungsfunktion  $\varphi$  verknüpft, wobei gilt:

$$\varphi_{m+1,n} = \sum_{k \in \mathbb{Z}} h_{k-2n} \varphi_{m,k} \quad (7.17)$$

Die Waveletfunktion  $\psi$  ergibt sich aus der Skalierungsfunktion  $\varphi$  zusammen mit den Koeffizienten des Hochpassfilters  $G$  wie folgt:

$$\psi_{m+1,n} = \sum_{k \in \mathbb{Z}} g_{k-2n} \varphi_{m,k} \quad (7.18)$$

Zwischen den Berechnungsschritten für die einzelnen Skalen werden die Teilsignale  $u_{m+1,n} = \sum_{k \in \mathbb{Z}} h_{k-2n} u_{m,k}$  und  $v_{m+1,n} = \sum_{k \in \mathbb{Z}} g_{k-2n} v_{m,k}$  durch Downsampling dezimiert, indem jeder zweite Samplingwert weggelassen wird. Dadurch erscheinen die Skalierungs- bzw. Waveletfunktion im Vergleich zum Signal gespreizt. Auf diese Weise wird die Dilatation über die einzelnen Skalen auf sehr einfache Weise erreicht. Bei der Rekonstruktion werden umgekehrt bei jedem Schritt in einem Upsampling Nullen zwischen die Signalwerte eingefügt. Dadurch geht allerdings die Eigenschaft der Translationsinvarianz verloren, d.h. die Transformationen eines Signals und eines um  $x$  Abtastwerte phasenverschobenen, ansonsten aber identischen Signals unterscheiden sich in den einzelnen Abtastwerten. Bei erhaltener Translationsinvarianz würden die Signale nur phasenverschoben erscheinen.

Das in dieser Arbeit verwendete Verfahren nach dem „Algorithme á trous“ (vgl. [Mal01]) ist translationsinvariant und umgeht somit diese Schwierigkeit. Dies geschieht, indem nicht das Signal durch Downsampling gestaucht, sondern die Impulsantworten der Filterfunktionen durch das Einfügen von Nullen in den Filterkoeffizienten gespreizt werden. Damit erhöht sich allerdings auch der Signalverarbeitungsaufwand.

## 7.6.2 EKG-Signalverarbeitung mit Wavelets

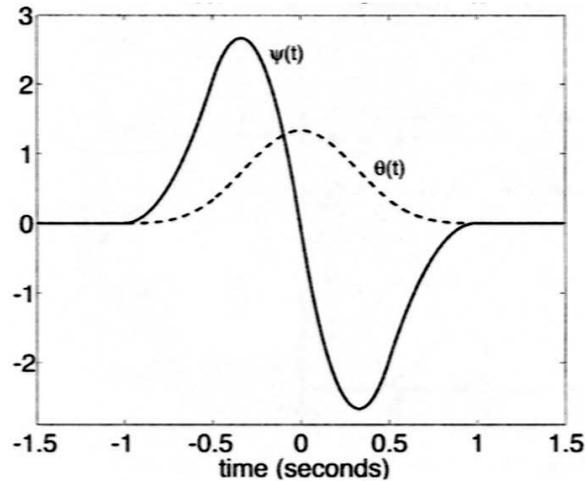
### Dyadische Wavelet-Transformation

Die in dieser Arbeit verwendeten Filterfunktionen gehen auf eine dyadische Wavelet-Transformation zurück, die in [LZT95] vorgestellt wurde. Dort wird definiert:

$$W_s f(x) = f(x) * \Psi_s(x) = \frac{1}{s} \int_{-\infty}^{\infty} f(t) \Psi\left(\frac{x-t}{s}\right) dt \quad (7.19)$$

Hier ist  $s$  der Skalierungsfaktor und hat die Werte  $s = 2^k$  mit  $k \in \mathbb{Z}$ , womit diese WT dyadisch ist.

Zum Auffinden der R-Zacke wird ein Differenzierungseffekt ausgenutzt. Dieser Effekt kommt zu Stande, da die Waveletfunktion die Ableitung einer Glättungsfunktion  $\Theta$  ist. Letztere wird vor der Ausführung der WT auf das Signal angewendet. Die Wavelettransformierte von  $f$  in einer festen Skala  $s$  ergibt sich bis auf einen skalenabhängigen Proportionalitätsfaktor als Ableitung der Funktion  $f$  nach deren Glättung mit  $\Theta$  in Skala  $s$ .



**Abbildung 7.12:** Waveletfunktion  $\Psi(t)$  und Glättungsfunktion  $\Theta(t)$  aus [MAO<sup>+</sup>04].

Li setzt ein quadratisches Spline-Wavelet ein (siehe Abbildung 7.12), dessen Fouriertransformierte

$$\hat{\Psi}(\omega) = j\omega \left(\frac{\sin \frac{\omega}{4}}{\frac{\omega}{4}}\right)^4 \quad (7.20)$$

lautet. Die Übertragungsfunktionen der zugehörigen Filter sind

$$H(\omega) = e^{j\frac{\omega}{2}} \left(\cos \frac{\omega}{2}\right)^3 \quad (7.21)$$

für das Tiefpassfilter, sowie

$$G(\omega) = 4j e^{j\frac{\omega}{2}} \left(\sin \frac{\omega}{2}\right) \quad (7.22)$$

für das Hochpassfilter.

Mit Hilfe der Filter läßt sich die WT für die einzelnen Skalen  $k$  folgendermaßen schreiben:

$$\begin{aligned}\hat{W}_{2^k} f(\omega) &= \hat{f}(\omega) \hat{\Psi}(2^k \omega) \\ \hat{W}_{2^1} f(\omega) &= G(\omega) \hat{f}(\omega) \hat{\Theta}(\omega) \\ \hat{W}_{2^2} f(\omega) &= G(2\omega) H(\omega) \hat{f}(\omega) \hat{\Theta}(\omega) \\ \hat{W}_{2^{k>2}} f(\omega) &= G(2^{k-1} \omega) H(2^{k-2} \omega) \cdots H(\omega) \hat{f}(\omega) \hat{\Theta}(\omega)\end{aligned}\quad (7.23)$$

wobei  $\Theta$  die Glättungsfunktion ist und  $\hat{f}(\omega) \hat{\Theta}(\omega)$  die diskrete Fouriertransformierte des diskretisierten EKG-Signals. Das bei der diskreten WT eingesetzte Downsampling wird ersetzt durch ein Spreizen der Filter mit  $2^{k-1}$  Nullen. Dies ist der vorgenannte „Algorithm à trous“.

Aus den oben genannten Gleichungen können die Filterkoeffizienten auf folgende Weise hergeleitet werden:

$$G(\omega) = 4j e^{\frac{j\omega}{2}} \left( \sin\left(\frac{\omega}{2}\right) \right) = 4j e^{\frac{j\omega}{2}} \cdot \frac{1}{2j} \left( e^{\frac{j\omega}{2}} - e^{-\frac{j\omega}{2}} \right) = 2 \cdot (e^{j\omega} - 1) \quad (7.24)$$

$$H(\omega) = e^{\frac{j\omega}{2}} \left( \cos\left(\frac{\omega}{2}\right) \right)^3 = e^{\frac{j\omega}{2}} \left( \frac{e^{\frac{j\omega}{2}} + e^{-\frac{j\omega}{2}}}{2} \right) = \frac{1}{8} (e^{j2\omega} + 3e^{j\omega} + 3 + e^{-j\omega}) \quad (7.25)$$

Die Substitution  $z = e^{j\omega}$  ergibt:

$$G(z) = 2(z - 1) = 2 \frac{1 - z^{-1}}{z^{-1}} \quad (7.26)$$

$$H(z) = \frac{1}{8} (z^2 + 3z + 3 + 3z^{-1}) = \frac{1 + 3z^{-1} + 3z^{-2} + z^{-3}}{8z^{-2}} \quad (7.27)$$

In kausaler Form ergeben sich die daraus die Filtergleichungen

$$y_g(n) = 2 \cdot (x(n) - x(n-1)) \quad (7.28)$$

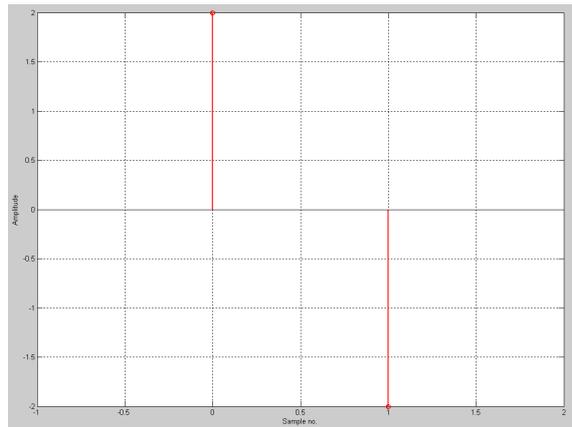
$$y_h(n) = \frac{1}{8} (x(n) + 3x(n-1) + 3x(n-2) + x(n-3)) \quad (7.29)$$

und damit die Filterkoeffizienten

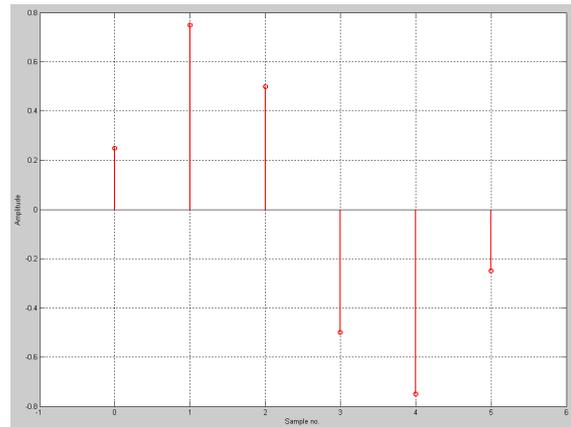
$$g_k = (2, -2) \quad (7.30)$$

$$h_k = \frac{1}{8} \cdot (1, 3, 3, 1) \quad (7.31)$$

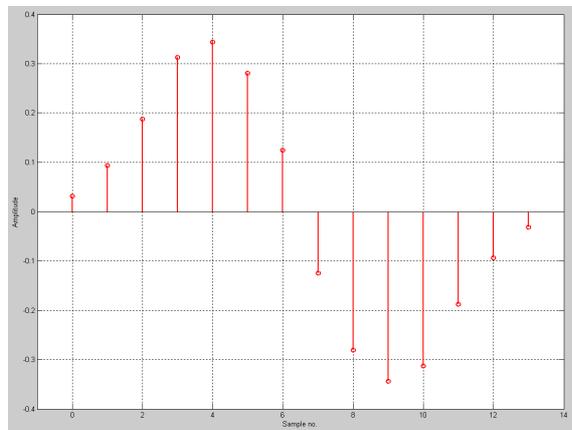
Durch Faltung im Zeitbereich ergeben sich für die einzelnen Skalen die in Gleichung 7.32 angegebenen Filterkoeffizienten. Gleichung 7.23 stellt denselben Vorgang als Multiplikation im Frequenzbereich dar. Mit diesen Filtern kann das EKG-Signal verarbeitet werden. Die Impulsantworten der FIR-Filter bilden die Wavelet-Funktion nach und haben den Mittelwert 0. Die negativen Koeffizienten sind punktsymmetrisch zu den vorangehenden positiven und daher bei den höheren Skalen aus Übersichtsgründen nicht vollständig angegeben.



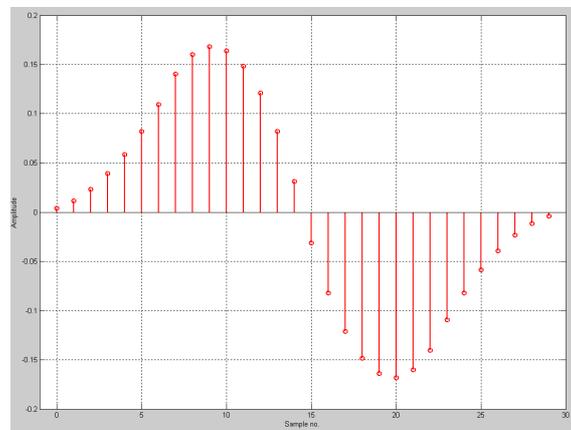
(a)



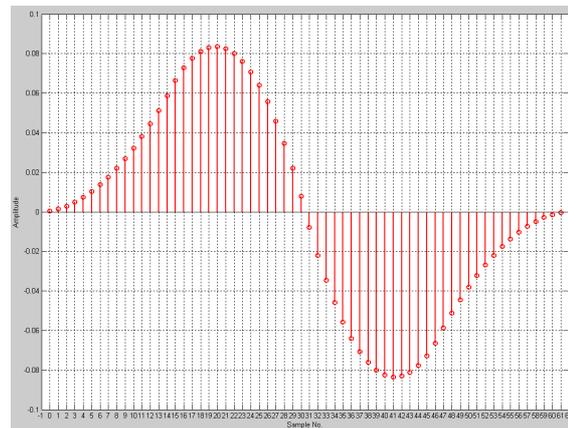
(b)



(c)



(d)



(e)

**Abbildung 7.13:** Impulsantworten der Li-Wavelet-Filter für die Skalen 1 (a) bis 5 (e) für eine Abtastrate von 250 Hz.

$$\begin{aligned}
l_1 &= (2, -2) \\
l_2 &= \frac{1}{4}(1, 3, 2, -2, -3, -1) \\
l_3 &= \frac{1}{32}(1, 3, 6, 10, 11, 9, 4, -4, \dots) \\
l_4 &= \frac{1}{256}(1, 3, 6, 10, 15, 21, 28, 36, 41, 43, 42, 38, 31, 21, 8, -8, \dots) \\
l_5 &= \frac{1}{2048}(1, 3, 6, 10, 15, 21, 28, 36, 45, 55, 66, 78, 91, 105, 120, 136, 149, 159, \\
&\quad 166, 170, 171, 169, 164, 156, 145, 131, 114, 94, 71, 45, 16, -16, \dots)
\end{aligned} \tag{7.32}$$

Abbildung 7.13 zeigt die Impulsantworten der aus den oben definierten Tief- und Hochpassfiltern zusammengesetzten Filter der ersten fünf Skalen und Abbildung 7.14 deren Frequenzgänge. Bei einer Abtastfrequenz von 250 Hz ergibt sich schließlich eine Frequenzaufteilung gemäß Tabelle 7.3.

**Tabelle 7.3:** 3-dB-Bandbreiten der Frequenzbänder aus [LZT95] für eine Abtastrate von 250 Hz.

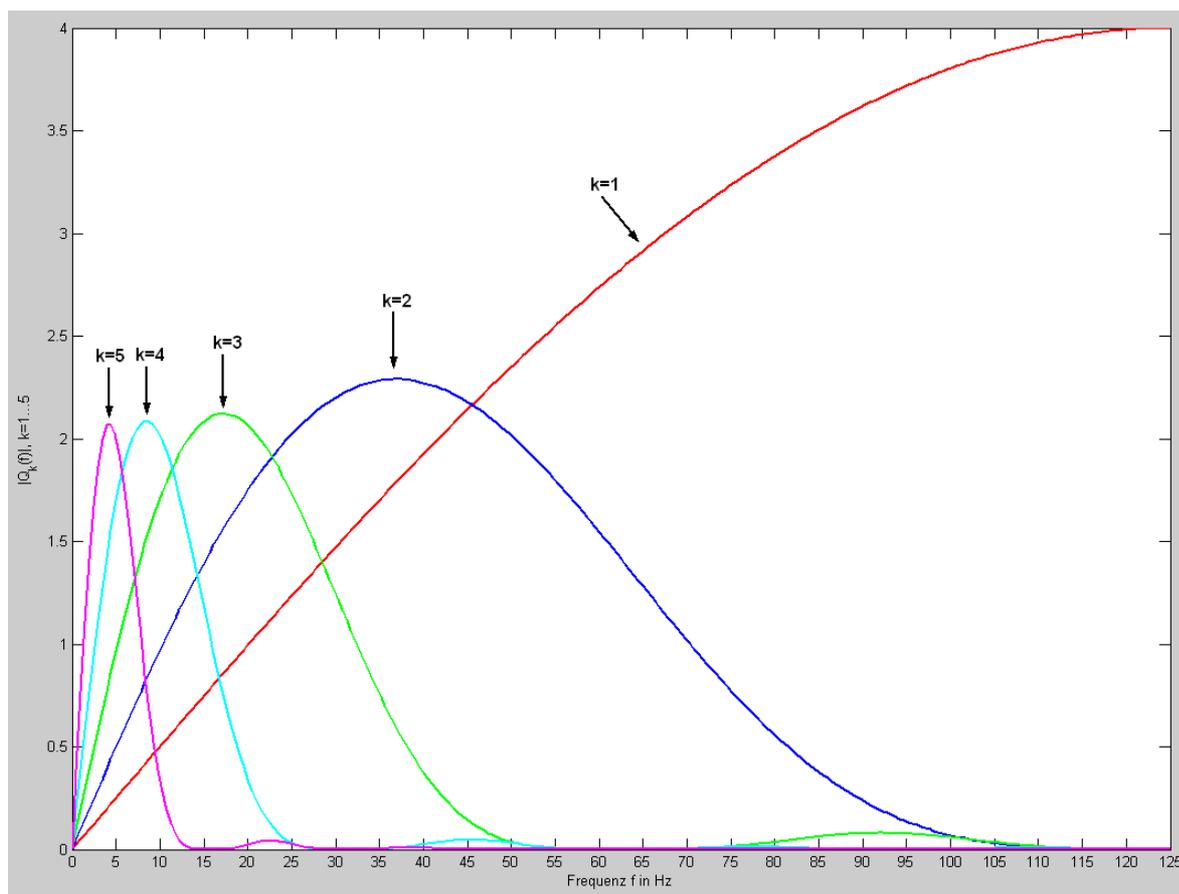
Skala	3-dB-Bandbreite (Hz)
1	62.5 - 125.0
2	18.0 - 58.5
3	8.0 - 27.0
4	4.0 - 13.5
5	2.0 - 6.5

Die Skalen besitzen die folgenden charakteristischen Merkmale:

- Skala 1 entsteht über ein reines Hochpassfilter. Es dient der Differenzierung des Signals, was bedeutet, dass hier die Gleichspannungsanteile des Signals herausgefiltert werden. Für Frequenzen bis ca. 50 Hz nähert dieses Filter den idealen Frequenzgang eines Differentiators sehr gut an, wie Abbildung 7.14 zeigt.
- Die weiteren Skalenfilter bestehen aus der Kombination eines Hochpass- und Tiefpassfilters nach Gleichung 7.23. Diese Bandpasscharakteristik zeigt sich auch in den Frequenzgängen in Abbildung 7.14. Deutlich erkennbar auch die Verschiebung des Durchlassbereichs zu kleineren Frequenzen für höhere Skalen.
- In den Skalen 3 und 4 hat der QRS-Komplex die höchsten Signalenergien, wobei in Skala 3 die maximalen Energiewerte erreicht werden.
- In Skala 5 treten P- und T-Wellen deutlicher als in den anderen Skalen hervor.

### Maximum-Minimum-Linien

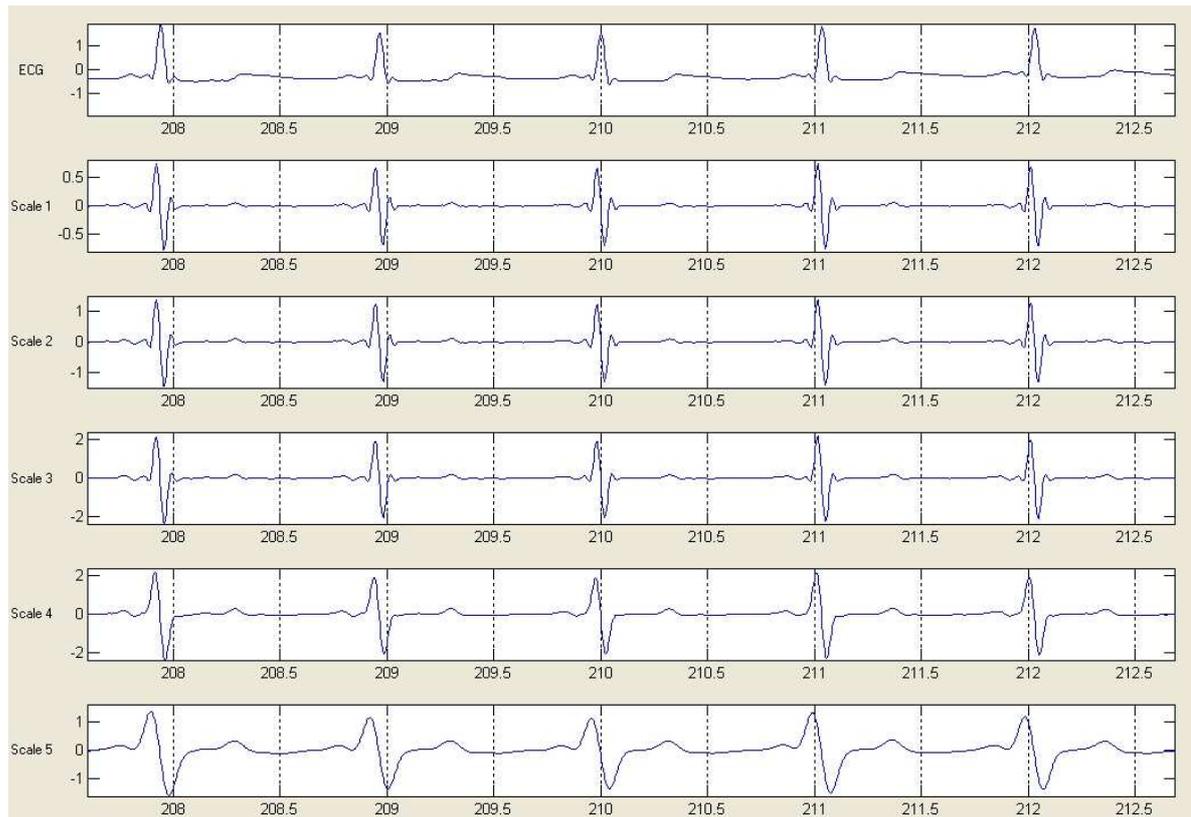
Bei der Transformation des EKG-Signals mit den Skalenfiltern entstehen bei ansteigenden Flanken Maxima in den Skalensignalen bzw. Minima bei fallenden Flanken.



**Abbildung 7.14:** Frequenzgänge der Li-WT in den Skalen 1 bis 5 bei einer Samplingrate von 250 Hz aus [LZT95]

Dadurch gehören zu jeder R-Zacke in den Skalen ein charakteristisches Paar aus einem Maximum und einem Minimum, wie aus Abbildung 7.15 ersichtlich wird. Der Nulldurchgang dieses Paares in einer Skala entspricht dem Peak der R-Zacke. Dabei ist zu beachten, dass durch die Tiefe der verwendeten Filter unterschiedlich große Phasenverschiebungen auftreten, die sich durch die symmetrische Impulsantwort der Filter aber sehr einfach korrigieren lassen. Können über die ersten vier Skalen hinweg Maxima bzw. Minima einander zugeordnet werden, bilden ihre Orte einen Vektor  $n^k$  mit  $k = 1 \dots 4$ , der als Maximum- bzw. Minimum-Linie (MML) bezeichnet wird. Ob ein Maximum/Minimum als solches gezählt werden darf, hängt von einem für jede Skala festzulegenden Schwellwert  $\epsilon$  ab, der überschritten werden muss. Ist in einer der Skalen  $2^1$  bis  $2^3$  kein Maximum/Minimum in der Nähe eines solchen aus höherer Skala zu finden, wird diese Stelle nicht als MML gezählt.

Kommt in der Nähe eines Maximums (Minimums) innerhalb eines beschränkten Intervalls kein Minimum (Maximum) vor, handelt es sich um eine isolierte MML, die zum Beispiel durch bestimmte Artefakte wie einen plötzlich auftretenden Signal-Offset verursacht worden sein kann. Andernfalls werden die beiden MML zu einem Paar zusammengefasst, dem so genannten Maximum-Minimum-Paar (MMP). Dieses MMP kann dann als Grundlage für die QRS-Detektion dienen.



**Abbildung 7.15:** Maximum-Minimum-Paare in den Skalen der WT, Nulldurchgang bei der Spitze der R-Zacke. Die Wavelet-Skalen sind gegenüber dem EKG phasenkorrigiert aufgetragen.

### Lipschitz-Exponent

Die Spitzen der R-Zacken sind näherungsweise Singularitäten des Signals. Unstetigkeitsstellen, nicht differenzierbare Stellen oder Dirac-Impulse sind Beispiele für Singularitäten, deren Art sich mit dem Lipschitz-Exponent  $\alpha_j$  berechnen lässt. Im vorliegenden Fall gibt  $\alpha$  an, wie stark sich die Amplitude der Wavelettransformierten des Signals an Extremstellen  $n_p^k$  zwischen zwei benachbarten Skalen verändert, wobei  $p$  ein Zählindex ist, mit dem zusammengehörende Extrema identifiziert werden können. Sei  $a_k(n_p^k) = |W_{2^k} f(n_p^k)|$ , dann berechnet sich  $\alpha_j$  zu

$$\alpha_j = \log_2 a_{k+1}(n_p^{k+1}) - \log_2 a_k(n_p^k). \quad (7.33)$$

Laut [LZT95] ergibt sich  $\alpha'$  zu

$$\alpha' = \frac{\alpha_1 + \alpha_2}{2}. \quad (7.34)$$

Für R-Zacken ist  $\alpha'$  normalerweise größer als Null. Nimmt  $\alpha'$  plötzlich wesentlich ab, handelt es sich bei der vorliegenden Singularität nicht um eine R-Zacke, sondern um Rauschen oder Störungen. Auch dieser Parameter kann für die QRS-Detektion verwendet werden.

### 7.6.3 Implementierung der waveletbasierten QRS-Detektion

Bei einer Nachimplementierung des in [LZT95] in dem in Kapitel 7.3.1 beschriebenen Simulink-Framework konnten die in der Literatur genannten Ergebnisse zunächst nicht nachvollzogen werden (siehe Kapitel 7.7). Ein Grund dafür ist in den rigiden heuristischen Regeln zu suchen, die für die Detektion verwendet werden und die bei untypischen QRS-Morphologien (beispielsweise QrS oder RsR') zu Detektionsproblemen führen [WSMG03]. Aus diesem Grund wurde das Verfahren dahingehend modifiziert, dass die QRS-Detektion mit Hilfe des mit der NFS-Methode aus Kapitel 6.5.2 optimierten Fuzzy-Systems stattfindet. Beginnend mit der Identifikation der Maximum-Minimum-Paare, über die Untersuchung möglicher Extraktionsparameter und deren Klassifikation bis hin zur Vorstellung weiterer heuristischer Regeln zur abschließenden Verbesserung der Detektionsgüte werden in den folgenden Abschnitten die konkreten Implementierungsschritte für diese modifizierte waveletbasierte QRS-Detektion vorgestellt.

#### Vorbereitende Signalverarbeitung

Die Verarbeitung der Skalensignale  $W_{2^k}f$  erfolgt in Signalblöcken von zwei Sekunden Länge, wobei sich aufeinander folgende Blöcke um 250 ms überlappen, um durch die Phasenverschiebung der Skalenfilter gegeneinander verschobene Maxima und Minima einander zuordnen zu können. Für jeden dieser Blöcke mit den Signalwerten  $X_k$  wird zunächst der Mittelwert  $\mu_{X_k} = E(X_k)$  und die Standardabweichung  $\sigma_{X_k} = E((X_k - \mu_{X_k})^2)$  für jede Skala gebildet. Durch zweimalige Differenzierung des Skalensignals werden die Maxima und Minima in jeder Skala bestimmt. Für die weitere Betrachtung werden nur solche Extrema berücksichtigt, deren Differenz zum Mittelwert über einem Schwellwert liegt, um die Anzahl der zu betrachtenden Extrema zu reduzieren. Empirische Untersuchungen mit Datensätzen der MITDB haben gezeigt, dass ein Schwellwert  $q_k = 0,3 \cdot \sigma_{X_k}$  einen guten Kompromiss zwischen Empfindlichkeit und Reduktion darstellt.

#### Identifizierung der Maximum-Minimum-Paare

Die Bildung der MMPs wurde bereits skizziert, daher werden in diesem Abschnitt nur noch die für die Bildung verwendeten Parameter und Bedingungen vorgestellt.

**Bildung der MMLs:** Ausgehend von den in Skala  $k = 4$  gefundenen Extrema werden in den „kleineren“ Skalen  $k = 1, 2, 3$  die zugehörigen Extrema gleicher Polarität in einer Umgebung von 40 ms gesucht. Sollten mehrere Extrema in Frage kommen, so wird das dem Referenzextremum nächstgelegene ausgewählt, außer ein anderes Extremum erfüllt die Bedingung  $|W_{2^k}f(n_{p_1}^k)| > 1,2 \cdot |W_{2^k}f(n_{p_2}^k)|$  ( $n_{p_1}^k$  und  $n_{p_2}^k$  geben die Orte der beiden zu vergleichenden Extrema in der Skala  $k$  an). Auf diese Weise wird sukzessiv die gesamte MML gebildet. Kann in einer Skala kein passendes Extremum gefunden werden, werden die Extrema in den anderen Skalen ebenfalls verworfen.

**Bildung der MMPs:** Grundsätzlich werden benachbarte MMLs zu MMPs zusammengefasst, wobei immer eine MML Maxima beinhalten muss, die andere Minima. Paarungen von MMLs gleicher Polarität sind nicht erlaubt. Um auch hier die Anzahl

der zu analysierenden MMPs möglichst gering zu halten, werden nur solche MMPs berücksichtigt, deren Maxima und Minima in keiner der Skalen  $k = 2, 3, 4$  weiter als 200 ms voneinander entfernt sind. Die verbleibenden MMPs gelten als potenzielle QRS-Komplexe und werden weiter untersucht.

Das ursprüngliche Verfahren nach [LZT95] wertet die detektierten MMPs mit Hilfe eines adaptiven Schwellwerts, dem Lipschitz-Exponenten, einer Refraktärzeit nach detektierten QRS-Komplexen und einem Search-Back-Verfahren aus. Dieses Vorgehen wurde in der Matlab-Simulink-Implementierung des Verfahrens verwendet, deren Ergebnisse auf der MIT Datenbank in Kapitel 7.7 vorgestellt werden. Die weiteren Abschnitte beschreiben die Weiterentwicklung des Verfahrens.

## Parameterextraktion

Nach Bildung der MMPs können verschiedene Parameter aus den Skalensignalen extrahiert werden, die für die Entscheidung, ob das MMP einen QRS-Komplex repräsentiert, herangezogen werden können. Bei der QRS-Detektion werden nur die Skalen  $k = 1, \dots, 4$  für die Parameterextraktion verwendet. Im Rahmen dieser Arbeit wurden folgende Parameter genauer untersucht:

- Verhältnis zwischen der Betragsamplitude des aktuell betrachteten Extremums und einem skalen- und polaritätsabhängigen, adaptiven Schwellwert. Die Schwellwerte für die Maxima und Minima in den einzelnen Skalen werden auf Grundlage des Betrags des Amplitudenmittelwerts der letzten fünf Maxima bzw. Minima gebildet, die als QRS-Komplex identifiziert wurden. Die so extrahierten Parameter tragen den Namen  $Max2ThresMax_k$  und  $Min2ThresMin_k$ . Bei QRS-Komplexen sollten diese Werte groß sein, für Rauschen oder P- und T-Wellen dagegen klein.
- Zeitliche Distanz  $AbsDist_k$  zwischen Maximum und Minimum eines MMPs innerhalb einer Skala. Für QRS-Komplexe sollten diese Werte klein sein, da Maxima und Minima eines MMPs direkt benachbart liegen, bei Störsignalen dagegen eher groß.
- Abschätzung des Lipschitz-Koeffizienten. Dabei werden zunächst für die Maxima und die Minima getrennt Werte für  $\alpha'_{max}$  und  $\alpha'_{min}$  bestimmt, wie dies in Kapitel 7.6.2 bereits beschrieben wurde. Der endgültige Wert für  $\alpha'$  wird dann als Mittelwert aus  $\alpha'_{max}$  und  $\alpha'_{min}$  berechnet:

$$\alpha' = \frac{\alpha'_{max} + \alpha'_{min}}{2} \quad (7.35)$$

Im Weiteren wird dieser Parameter auch als *Alpha'* referenziert. Für QRS-Komplexe sollte dieser Parameter tendenziell große Werte annehmen.

- Aus den Werten  $Max2ThresMax_k$  und  $Min2ThresMin_k$  werden skalenspezifische Durchschnittswerte gebildet. Diese tragen den Namen  $MeanPairAmpl_k$ . Auch hier sollte der Parameterwert für QRS-Komplexe große Werte annehmen, während für den Großteil von Signalstörungen kleine Werte zu erwarten sind.

- Verhältnis zwischen  $Max2ThresMax_k$  und  $Min2ThresMin_k$  innerhalb einer Skala für ein MMP. Für QRS-Komplexe sollte dieses Verhältnis ca. 1 betragen, für andere MMPs deutlich davon abweichen. Dieser Parameter wird im Weiteren  $Max2MinRatio_k$  genannt.
- Bei den MMPs, die QRS-Komplexe repräsentieren, sind Maxima und Minima in den einzelnen Skalen meist durch eine steile Flanke im Wavelet-Signal verbunden. Um die Steilheit dieser Flanke als Parameter zu nutzen und dabei unabhängig von wechselnden Signalamplituden zu sein wird für die so genannte  $SlopeSteepness_k$  folgende Formel zur Berechnung genutzt:

$$SlopeSteepness_k = \frac{Max2ThresMax_k + Min2ThresMax_k}{AbsDist_k} \quad (7.36)$$

- Summe der Fläche unterhalb der Maxima und Minima eines MMPs. Dazu wird mit Hilfe der Nulldurchgangspunkte vor und nach einem Extremum, sowie dem Extremum selbst eine triangulare Approximation des Waveletsignals bestimmt, die Fläche dieses Dreiecks berechnet und schließlich für das Maximum und Minimum einer Skala innerhalb eines MMPs summiert. Dieser Parameter  $MaxMinArea_k$  sollte für QRS-Komplexe tendenziell große Werte annehmen.

### Klassifikation der Parametervektoren

Die oben beschriebenen Parameter wurden gemäß Tabelle 7.4 zu verschiedenen Parametersets zusammengefasst. Die Parameterextraktion wurde in Matlab implementiert. Dabei wurde jedem durch die Referenznotation gegebenen QRS-Komplex das in einem Zeitfenster von  $\pm 100$  ms liegende MMP zugewiesen. Oft kommen mehrere MMPs in Frage. In diesem Fall wird das MMP ausgewählt, dessen MMP in Skala 3 die größte Betragsamplitude besitzt und dessen Nulldurchgang am nächsten zur Referenznotation liegt. Für diese Parametersets wurden unterschiedliche Regeln definiert, an Hand derer die Merkmalsfunktionen eines Fuzzy-Systems mit der in [Som02] beschriebenen Methode trainiert wurden. Die Ergebnisse dieses Trainings zeigt Tabelle 7.5. Als Trainingsset wurden folgende Datensätze der MITDB verwendet:

- Kanal 1 in voller Länge für die Datensätze 100, 103, 106, 115, 200 und 223
- Kanal 2 in voller Länge für die Datensätze 114 und 228
- Kanal 1 und 2 in voller Länge für Datensatz 233
- Teilsignale aus folgenden Datensätzen:
  - 116 (Kanal 1 bis 22:03 Minuten)
  - 200 (Kanal 2 ab 17:02 Minuten)
  - 208 (Kanal 1 bis 19:54 Minuten)

Für dieses Trainingsset wurden Datensätze ausgewählt, die viele verschiedene QRS-Morphologien aufweisen, um das Training möglichst universell anzulegen. Der Hauptaugenmerk lag auf einer möglichst großen Anzahl von ventrikulären ektopischen Schlägen.



Schrittmacherinduzierte Schläge mit ihrer oft stark veränderten Morphologie und ihrer großen Breite wurden ausgeschlossen, da die verwendeten Datenbanken keine separate Notation des Schrittmacherimpulses bereitstellen, so dass diese bei der Erstellung der Referenzdaten hätten berücksichtigt werden können. Eine Verwendung dieser Datensätze hätte darum das Training verfälschen können. Mit den in Kapitel 5.4 angesprochenen Hardwaredetektoren für Schrittmacherspikes kann dieses Problem aber später einfach behoben werden. Alle Datensätze weisen ein gutes Signal-zu-Rausch-Verhältnis auf und sind frei von größeren Artefakten, um das Training nicht zu erschweren.

**Tabelle 7.5:** Ergebnisse des Trainings für die verschiedenen Parametersets. SE steht für Sensitivität, PP für positive Prädiktivität. Zur Erklärung dieser Begriffe siehe Anhang A.1.

Parameterset	SE [%]	PP [%]
1 (5 Regeln)	96,54	91,61
1 (2 Regeln)	96,58	92,42
2 (2 Regeln)	85,51	89,88
3 (2 Regeln)	95,95	72,10
4 (4 Regeln)	96,07	61,25
4 (2 Regeln)	94,07	67,67
5 (5 Regeln)	92,16	75,07
6 (5 Regeln)	94,79	88,95
7 (2 Regeln)	98,00	94,08
8 (2 Regeln)	96,91	93,10
9 (2 Regeln)	99,08	93,10

Auf Grund der Ergebnisse des Trainings wurde das Parameterset 9 für die weitere Implementierung des QRS-Detektors verwendet. Für das einfache Regelwerk mit nur zwei Regeln nach Tabelle 7.6 war festzustellen, dass ein Großteil der falsch positiven Klassifikationen (FP) dadurch zustande kamen, dass ein QRS-Komplex nicht zu zwei großen Peaks in den Wavelet-Skalen führt, sondern dass starke Unterschiede in der Amplitude vorhanden sind. Dadurch sind die FP in unmittelbarer Nähe zu einem QRS-Komplex lokalisiert, ohne dass sie bei der Referenzbildung berücksichtigt werden könnten. Aus diesem Grund können die Ergebnisse des Trainings insbesondere in Hinblick auf die positive Prädiktivität nur bedingt Aufschluss geben. Wichtiger ist daher, dass die Sensitivität des Verfahrens möglichst hoch ist.

Da auf Grund des oben beschriebenen Phänomens die Beschreibung für die QRS-Detektion als zu pauschal erschien, wurde nach mehreren Versuchen ein weiteres Regelwerk mit sechs Regeln erstellt, bei dem darüber hinaus für die Parameter  $Max2Thres$ ,  $Min2Thres$  und  $AbsDist_k$  drei Zugehörigkeitsfunktionen zur Beschreibung dienen. Dieses Regelwerk ist in Tabelle 7.7 wiedergegeben.

Diese Regelbasis wurde ebenfalls mit dem Verfahren nach [Som02] trainiert. Bei Tests mit Datensätzen der MITDB zeigte sich aber, dass bei einigen QRS-Morphologien wie VES oder Schenkelblockbildern, die sich durch eine große Breite auszeichnen, die Merkmalsfunktionen für die Parameter  $AbsDist_k$  durch das Training auf zu niedrige Werte hin optimiert wurden. Nach einer manuellen Korrektur konnten schließlich auf den

**Tabelle 7.6:** Regelbasis zur QRS-Detektion mit zwei Regeln

**Regel1:** If     Max2ThresMax<sub>2</sub> is *large* and  
                   Max2ThresMax<sub>3</sub> is *large* and  
                   Max2ThresMax<sub>4</sub> is *large* and  
                   Min2ThresMin<sub>2</sub> is *large* and  
                   Min2ThresMin<sub>3</sub> is *large* and  
                   Min2ThresMin<sub>4</sub> is *large* and  
                   AbsDist<sub>2</sub>      is *small* and  
                   AbsDist<sub>3</sub>      is *small* and  
                   AbsDist<sub>4</sub>      is *small* and  
                    $\alpha'$           is *large*  
           then QRS

**Regel2:** If     Max2ThresMax<sub>2</sub> is *small* and  
                   Max2ThresMax<sub>3</sub> is *small* and  
                   Max2ThresMax<sub>4</sub> is *small* and  
                   Min2ThresMin<sub>2</sub> is *small* and  
                   Min2ThresMin<sub>3</sub> is *small* and  
                   Min2ThresMin<sub>4</sub> is *small* and  
                   AbsDist<sub>2</sub>      is *large* and  
                   AbsDist<sub>3</sub>      is *large* and  
                   AbsDist<sub>4</sub>      is *large* and  
                    $\alpha'$           is *small*  
           then no QRS

Standard-Datenbanken die im Kapitel 7.7 gezeigten Ergebnisse für die beiden Regelbasen erreicht werden.

### Weitere Detektionsregeln

Beim Einsatz der im vorhergehenden Abschnitt vorgestellten Fuzzy-Klassifikation ohne weitere Maßnahmen kommt es zu vielen falsch positiven Detektionen. Um die positive Prädiktivität zu erhöhen, wurden daher noch einige weitere Regeln definiert, die durch zusätzliche Kontextinformation eine zuverlässigere Detektion ermöglichen. Hier wurde besonders auf den Einsatz des Detektors mit mehreren EKG-Kanälen geachtet. Weiterhin wurden verschiedene Maßnahmen getroffen, mit denen die Parameterextraktion auf die aktuellen Signalverhältnisse angepasst werden kann.

1. Liegt die Amplitudenbandbreite des EKG-Signals im betrachteten Abschnitt unter  $300 \mu\text{V}$ , so wird der Abschnitt nicht weiter betrachtet, da das Signal keine verlässliche Detektion zulässt.
2. Liegt der letzte detektierte QRS-Komplex bereits mehr als das 1,5-fache des aktuellen durchschnittlichen RR-Intervalls zurück, so werden die Amplitudenschwelle in den Skalen auf das 0,8-fache des alten Werts reduziert. Allerdings muss die letzte Reduktion mindestens 500 ms zurückliegen und darf maximal fünfmal

**Tabelle 7.7:** Regelbasis mit sechs Regeln zur QRS-Detektion. Mit den Abkürzungen S,M und L werden die Zugehörigkeitsfunktionen (ZF) der Parameter beschrieben (S: small, M: medium, L: large).

	ZF	Regel 1	Regel 2	Regel 3	Regel 4	Regel 5	Regel 6
Max2ThresMax <sub>2</sub>	s					x	
	m		x	x			
	l	x			x		
Max2ThresMax <sub>3</sub>	s					x	
	m		x	x			
	l	x			x		
Max2ThresMax <sub>4</sub>	s					x	
	m		x	x			
	l	x			x		
Min2ThresMin <sub>2</sub>	s					x	
	m		x	x			
	l	x			x		
Min2ThresMin <sub>3</sub>	s					x	
	m		x	x			
	l	x			x		
Min2ThresMin <sub>4</sub>	s					x	
	m		x	x			
	l	x			x		
AbsDist <sub>2</sub>	s	x	x				
	m			x	x		
	l						x
AbsDist <sub>3</sub>	s	x	x				
	m			x	x		
	l						x
AbsDist <sub>4</sub>	s	x	x				
	m			x	x		
	l						x
$\alpha'$	s					x	
	l	x	x	x	x		
Ergebnis		QRS	QRS	QRS	QRS	kein QRS	kein QRS

hintereinander erfolgen. Ansonsten werden die Schwellwerte konstant gehalten. Auf diese Weise kann eine schrittweise Anpassung an geringere Signalamplituden erfolgen.

3. Die Detektion von QRS-Kandidaten mit Hilfe der extrahierten Parameter und des Fuzzy-Systems erfolgt für jeden Kanal separat. Über alle Kanäle hinweg werden Gruppen von Kandidaten gebildet, die in einem Zeitbereich von 200 ms beieinander liegen. Sind innerhalb dieses Zeitfensters zwei Kandidaten weiter als 80 ms voneinander entfernt, so werden daraus noch einmal Subgruppen gebildet und nur die erste davon weiter betrachtet. Die Lokalisation der Kandidaten wird durch den Nulldurchgang zwischen Maximum und Minimum des MMPs für die Skala  $k = 1$  festgelegt. Bei den verbleibenden Kandidaten muss von mehr als der Hälfte der betrachteten Kanäle (bei zwei Kanälen zumindest von einem Kanal) ein QRS-Kandidat in der Gruppe verblieben sein.
4. Die letzte Maßnahme betrifft die Abgrenzung von QRS-Komplexen gegenüber hohen, spitzen P- und T-Wellen. Hier werden nacheinander folgende Kriterien geprüft:
  - Liegen zwischen dem letzten detektierten QRS-Komplex und dem aktuellen QRS-Kandidaten mehr als 360 ms, so wird dieser als QRS-Komplex detektiert.
  - Liegt der letzte QRS-Komplex zwischen 250 und 360 ms zurück und liegt die Distanz unterhalb des 0,4-fachen durchschnittlichen RR-Intervalls, so liegen sie zu dicht zusammen. In diesem Fall wird der QRS-Kandidat nur dann als neuer QRS-Komplex akzeptiert und der alte verworfen, wenn seine maximale Regelaktivierung des Fuzzy-Systems die des vorherigen QRS-Komplexes übersteigt. Damit wird bei zu dicht aufeinanderfolgenden QRS-Komplexen nur der wahrscheinlichere behalten. Dabei wird das Zeitfenster für die Entscheidung nicht rigide gehalten, sondern kann an die aktuelle Herzrate adaptiert werden, was v.a. in tachykarden Abschnitten die Sensitivität des Verfahrens erhöht.
  - Unterschreitet die Distanz allerdings 250 ms, so findet sofort eine Prüfung statt, welcher der beiden Konkurrenten wahrscheinlicher einen QRS-Komplex repräsentiert. Damit wird die maximale Herzrate des Verfahrens auf 240 bpm festgelegt, was aber für den angestrebten Einsatzbereich ausreichend ist.

## 7.7 Ergebnisse der QRS-Detektion

### 7.7.1 Ergebnisse der Implementierungen im Simulink-Framework

Für eine erste Erprobung der Verfahren und zur einfachen Beobachtung ihres Verhaltens zur Laufzeit wurden alle drei Verfahren zunächst als Einkanalverfahren in der in Kapitel 7.3.1 vorgestellten Matlab-Simulink-Umgebung implementiert. Die Samplingfrequenz der EKG-Daten wurden für das Pan/Tompkins- und das Li-Wavelet-Verfahren auf 200 Hz bzw. 250 Hz korrigiert, das MOBD-Verfahren arbeitete mit der originalen

Abtastrate (im Fall der MITDB 360 Hz). Die Ergebnisse dieser Implementierung auf der MITDB zeigt Tabelle 7.8. Beim Pan/Tompkins-Verfahren und noch stärker beim Li-Wavelet-Verfahren konnten die in der Literatur angegebenen Detektionsergebnisse nicht reproduziert werden. Für die Original-Implementierung des MOBD-Verfahrens lagen keine entsprechenden Vergleichsdaten vor. Die beim Pan/Tompkins-Algorithmus vorgenommenen Modifikationen blieben zumindest bei der MITDB ohne erkennbare Wirkung. Leider erzeugt die Simulink-Implementierung einen so großen Overhead, dass die Simulationen nur mit ca. 2-4facher Geschwindigkeit gegenüber Echtzeit läuft. Trotz der vielfältigen Möglichkeiten, die eine solche Implementierung bietet, wurde ihre Weiterentwicklung zu Gunsten einer reinen Matlab-Entwicklung bzw. einer Java-Implementierung unter Nutzung des TeDiaNet-Interfaces eingestellt.

**Tabelle 7.8:** Ergebnisse der Simulink-Implementierung für die drei QRS-Detektionsverfahren auf den beiden Kanälen der MITDB

	Kanal 1		Kanal 2	
	SE[%]	PP[%]	SE[%]	PP[%]
Pan/Tompkins Original	99,07	98,55	92,93	95,95
Pan/Tompkins modifiziert	99,07	98,55	92,93	95,95
MOBD	98,85	99,73	94,77	98,07
Li-Wavelets	98,07	94,18	93,84	91,08

### 7.7.2 Ergebnisse der Mehrkanaldetektoren

Ausgehend von den vorgenannten Versionen wurden alle drei QRS-Detektoren wie in den vorangegangenen Kapiteln beschrieben für den Mehrkanaleinsatz weiterentwickelt.

Das MOBD- und modifizierte Pan/Tompkins-Verfahren wurden in Java neu implementiert, für die Mehrkanaldetektion erweitert und über das TeDiaNet-Interface in das EKG-Langzeit-Diagnosesystem CARDIOLIGHT der Firma Medset [Med06] eingebunden. In dieses wurden die Datensätze der MITDB, der AHA Database (AHADB, siehe Anhang B.3.2), der European ST-T Database (EDB, siehe Anhang B.3.3) und der MIT Noise Stress Database (NSTDB, siehe Anhang B.3.5) importiert. Durch den Import standen die Daten nur noch in einer Abtastrate von 200 Hz zur Verfügung. Die Analyse erfolgte in CARDIOLIGHT und die resultierenden Schlagnotationen wurden in das binäre WFDB-Format exportiert und anschließend mit der WFDB-Applikation bxb mit der Referenznotation verglichen.

Das mehrkanalfähige waveletbasierte Verfahren wurde auf Grund seiner Komplexität unter Matlab implementiert und auf den Datensätzen der Standard-Datenbanken mit einer Abtastrate von 200 Hz und 250 Hz und Fuzzy-Systemen mit zwei und sechs Regeln getestet. Für die Verarbeitung der EKG-Datensätze mit einer Abtastrate von 200 Hz wurden die Impulsantworten der Skalenfilter mit der Zielfrequenz neu abgetastet. Die daraus resultierenden Koeffizienten der Filter und ihre Impulsantworten sind in Anhang C zu finden. Die detaillierten Ergebnisse sind in Anhang E aufgelistet. Datensätze

mit schrittmacherinduzierten Schlägen wurden bei der Analyse ausgeschlossen. Für die MITDB sind dies die Datensätze 102, 104, 107 und 217, für die AHADB die Datensätze 2202 und 8205. Die EDB enthält keine Datensätze mit schrittmacherinduzierten Schlägen.

**Tabelle 7.9:** Ergebnisse für die QRS-Detektion der drei Verfahren auf den Standard-Datenbanken

Algorithmus	MITDB		AHADB		EDB	
	SE[%]	PP[%]	SE[%]	PP[%]	SE[%]	PP[%]
Pan/Tompkins	99,20	99,75	99,10	98,94	98,61	99,81
MOBD	98,92	99,21	98,39	96,96	99,08	98,92
Li-Wavelets (2 Regeln, 200 Hz)	99,84	98,57	99,75	96,55	99,89	98,27
Li-Wavelets (6 Regeln, 200 Hz)	99,86	99,36	99,81	99,60	99,89	99,51
Li-Wavelets (2 Regeln, 250 Hz)	99,82	97,70	99,76	97,90	99,88	98,43
Li-Wavelets (6 Regeln, 250 Hz)	99,87	99,12	99,81	99,19	99,89	99,37

Neben der Gesamtdetektionsleistung muss auch die Sensitivität der Verfahren für die Detektion von ventrikulären Schlägen beurteilt werden. Diese kommen nur relativ selten vor und wirken sich daher in der Gesamtstatistik nicht sehr stark aus. Als wichtige pathologische Ereignisse sollten sie aber mit großer Zuverlässigkeit als QRS-Komplexe detektiert werden, um ihre weitere Klassifikation zu ermöglichen. Tabelle 7.10 zeigt diese Werte für die einzelnen Verfahren.

Eine weitere wichtige Rolle spielt die Detektionsleistung bei verrauschten EKG-Signalen. Die Verfahren wurden dafür mit Datensätzen der NSTDB getestet. Da diese Datensätze jedoch wechselweise aus gestörten und ungestörten Signalen bestehen, sind die globalen Ergebnisse für die einzelnen Datensätze nur bedingt nutzbar. Tabelle 7.11 zeigt die Gesamtergebnisse der Verfahren auf der Datenbank, in Anhang E sind die Ergebnisse für die einzelnen Datensätze aufgeführt.

## 7.8 Beurteilung der Verfahren

### 7.8.1 Detektionsgüte

Bei der Implementierung der drei Verfahren im Simulink-Framework konnten für das Pan/Tompkins-Verfahren und die waveletbasierte Detektion die Ergebnisse aus der Literatur nicht reproduziert werden. Für das MOBD-Verfahren lagen keine belastbaren

**Tabelle 7.10:** Sensitivität der Detektionsverfahren für die Detektion von ventrikulären Schlägen auf den Standard-Datenbanken.

Algorithmus	MITDB SE(V)[%]	AHADB SE(V)[%]	EDB SE(V)[%]
Pan/Tompkins	95,00	91,80	94,03
MOBD	97,63	96,15	96,16
Li-Wavelets (2 Regeln, 200 Hz)	99,64	98,07	98,77
Li-Wavelets (6 Regeln, 200 Hz)	99,63	98,36	98,81
Li-Wavelets (2 Regeln, 250 Hz)	99,64	98,37	97,97
Li-Wavelets (6 Regeln, 250 Hz)	99,64	98,42	98,26

**Tabelle 7.11:** Detektionsergebnisse auf der MIT NSTDB.

Algorithmus	SE[%]	PP[%]
Pan/Tompkins	93,78	81,83
MOBD	86,63	77,10
Li-Wavelets (2 Regeln, 200 Hz)	95,59	75,73
Li-Wavelets (6 Regeln, 200 Hz)	96,58	78,97
Li-Wavelets (2 Regeln, 250 Hz)	95,52	74,77
Li-Wavelets (6 Regeln, 250 Hz)	96,52	78,04

Vergleichsdaten vor. In allen drei Fällen konnten in der Weiterentwicklung jedoch deutliche Verbesserungen erreicht werden.

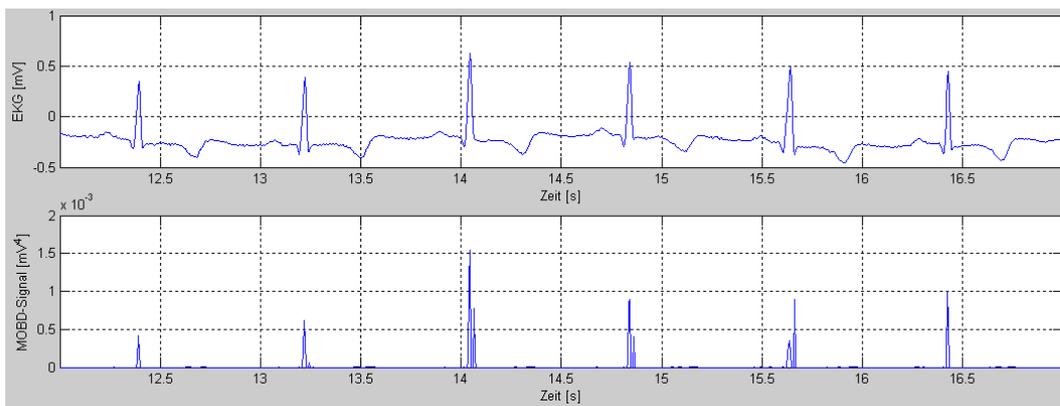
Generell ist beim Vergleich der gewonnenen Daten mit denen aus der Literatur zu beachten, dass die meisten Verfahren nur als Einkanal-detektoren arbeiten und in der Literatur meist auf dem ersten Kanal der MITDB getestet wurden. Für diese Datenbank weist der erste Kanal jedoch deutlich bessere Signalverhältnisse als der zweite auf. Dies ist in Tabelle 7.8 deutlich erkennbar. Kleinere Änderungen der statistischen Kennwerte können auch dadurch entstehen, dass bei vielen der in Tabelle 7.1 aufgeführten Verfahren die Datensätze in ihrer vollen Länge benutzt wurden, anstatt wie von den Standards (siehe Anhang A.2) vorgeschrieben, die ersten fünf Minuten zu ignorieren. Da diese Anfangsminuten als „Lernphase“ für den Algorithmus gedacht sind, sind die Signalverhältnisse in diesen Abschnitten normalerweise sehr gut. Damit erhöht sich die Detektionsgüte tendenziell, da sich die höhere Anzahl korrekt detektierter Schläge gegenüber etwaigen neuen Fehldetektionen stärker auswirkt.

Beim Vergleich der Ergebnisse aus Tabelle 7.9 mit den Literaturwerten aus Tabelle 7.1 erreicht das waveletbasierte Verfahren mit sechs Detektionsregeln vergleichbare Sensitivitäten und positive Prädiktivitäten. Dabei schneidet die 200 Hz-Variante nochmals deutlich besser bei der Vermeidung von falsch positiven Detektionen ab.

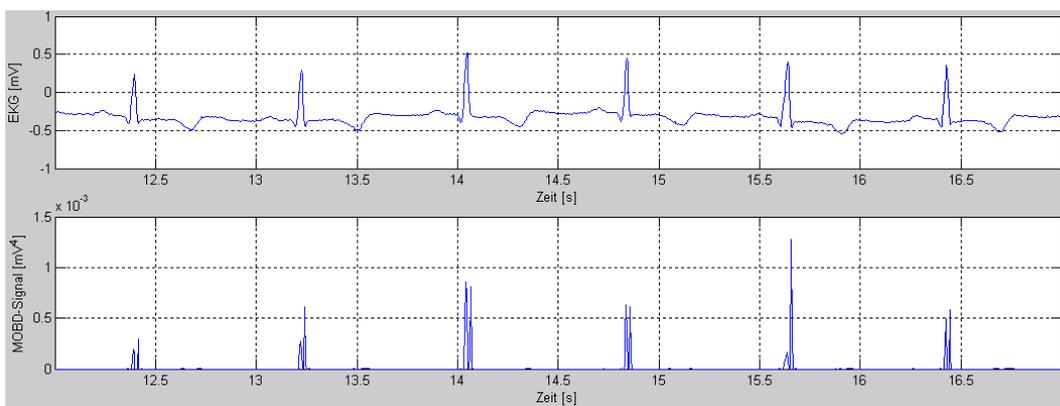
Die modifizierte Implementierung des Pan/Tompkins-Verfahrens kommt in der Multi-Kanal-Variante nicht ganz an die Ergebnisse aus der Literatur heran. Die Sensitivität auf der MITDB fällt im Vergleich zu den Werten aus [PT85] und [Ham02] ab, die Unterschiede in der positiven Prädiktivität sind zu gering, als dass sie als statistisch relevant bezeichnet werden können, v.a. wenn man die etwas andere Testmethode in [PT85] betrachtet, bei der der gesamte Datensatz evaluiert wurde.

Das MOBD-Verfahren fällt im Vergleich zu den beiden anderen Detektionsverfahren deutlich ab. Die schlechteren Werte für die Sensitivität sind zum Teil auf das Resampling der Daten auf 200 Hz beim Import der Daten in das CARDIOLIGHT-Modul zurückzuführen. Durch die größeren Abtastintervalle kann es geschehen, dass die Flankenzüge im Signal nicht mehr genügend Samples umfassen, um einen Ausschlag im Featuresignal des Verfahrens zu ergeben. Damit erscheint typischerweise nur für eine der beiden Flanken ein Peak im Signal, so dass die Detektion versagt. Abbildung 7.16 zeigt diesen Sachverhalt: Bei der niedrigeren Abtastrate verschwindet einer der beiden Peaks im MOBD-Featuresignal. Das bedingungslose Akzeptieren von QRS-Detektionen in den einzelnen Kanälen ohne weitere Überprüfung, ob ein QRS-Komplex auch in den anderen Kanälen detektiert wurde, hat die höhere Anzahl von falsch positiven Detektionen zur Folge. Ein weiteres Problem ist die fehlende Refraktärzeit, die zu Problemen mit falsch positiven Detektion auf T-Wellen führt. Andererseits erzielt das MOBD-Verfahren bei den früh einfallenden R-on-T-Schlägen im Datensatz 5201 der AHADB die höchste Detektionsrate (siehe Anhang E).

Insgesamt schneidet das waveletbasierte Verfahren mit sechs Regeln deutlich am besten im Vergleich der standardkonform evaluierten Verfahren ab und erzielt Werte, die mit denen in der Literatur vergleichbar sind. Dennoch ist festzustellen, dass bei einigen wenigen Datensätzen die Analysequalität noch stark verbessert werden könnte. Ein Beispiel dafür ist der bereits erwähnte Datensatz 5201 der AHADB, bei dem viele R-on-T-Schläge nicht detektiert werden, da sie sich noch innerhalb der Refraktärzeit des Algorithmus befinden. Ein anderes Beispiel ist der Datensatz 203 der MITDB, bei dem



(a)



(b)

**Abbildung 7.16:** MOBD-Featuresignale bei 200 Hz und 250 Hz Abtastrate. Oben bei einer Abtastrate von 200 Hz, unten derselbe Signalausschnitt mit 250 Hz abgetastet. Deutlich erkennbar ist das Verschwinden des einen Peaks im MOBD-Signal für den ersten und letzten QRS-Komplex bei der niedrigeren Abtastrate.

grob-schlächtiges atriales Flimmern zu vielen falsch positiven Detektionen führt.

Für die Detektionssensitivität für ventrikuläre ektope Schläge können aus der Literatur keine Vergleichsdaten gewonnen werden, da dies für die QRS-Detektoren nicht getrennt aufgeschlüsselt wird. Bei den Klassifikationsverfahren (siehe dazu Kapitel 8) lässt sich diese Information aus den gegebenen Werten für die Sensitivität und positive Prädiktivität nicht mehr gewinnen. Trotzdem erscheint dieser Wert wichtig, um beurteilen zu können, wie gut der QRS-Detektor mit verschiedenen QRS-Morphologien umgehen kann und die Obergrenze für die erreichbare Sensitivität festlegt. Auch in dieser Disziplin erreicht nur das waveletbasierte Verfahren Werte, die für einen späteren Einsatz akzeptabel erscheinen.

Andererseits ist die Rauschempfindlichkeit dieses Verfahrens relativ groß. Während die Sensitivität selbst in den am stärksten verrauschten Datensätzen noch über 86% beträgt, steigt die Anzahl der falsch positiven Detektionen sehr stark an. Wie gut die Ergebnisse in den verrauschten Datenabschnitten allerdings wirklich sind, lässt sich mit dem Standardtest `bx` nicht feststellen, da nur die Hälfte der Daten tatsächlich verrauscht ist. Es ist also davon auszugehen, dass die Detektionsgüte in den verrausch-

ten Abschnitten noch deutlich geringer ist. Das modifizierte Pan/Tompkins-Verfahren erreicht beim Test auf der NSTDB die höchsten Werte in der positiven Prädiktivität, allerdings ist die Sensitivität im Vergleich zum Wavelet-Verfahren geringer. Das MOBD-Verfahren erzielt bei diesen statistischen Kennzahlen die schlechtesten Ergebnisse.

## 7.8.2 Rechenaufwand, mobile Einsatzfähigkeit und Portierung auf ein Mobilsystem

Ein direkter Vergleich der Kosten der einzelnen Verfahren ist durch die unterschiedlichen Implementierungen nicht möglich. Es kann jedoch konstatiert werden, dass der Aufwand des Wavelet-Verfahrens deutlich höher als der der beiden anderen Verfahren ist. Dies ist vor allem in der aufwendigen Datenvorverarbeitung (Signalfilterung, Bildung der Maximum-Minimum-Paare) und der Fuzzy-Klassifikation begründet, während die anderen Prozessschritte (Parameterextraktion und weitere Detektionsregeln) sehr wenig Aufwand bedeuten. Dennoch kann davon ausgegangen werden, dass eine mobile Applikation dieses Verfahrens auf entsprechender Hardware ebenfalls möglich ist. Vorzugsweise sollte eine solche Implementierung auf einem digitalen Signalprozessor erfolgen.

**Tabelle 7.12:** Durchschnittliche Analysedauern in Sekunden für Datensätze unterschiedlicher Größe im CARDIOLIGHT-Modul von PADSYS der Firma Medset für das MOBD- und das Pan/Tompkins-Verfahren.

Datensatz	Analysedauer [s]	
	MOBD	Tompkins
MITDB/AHADB ( 30 Min.)	2,98	2,98
PADSY-Demo ( 24h)	106,8	121,5

Für die beiden anderen Verfahren können Laufzeitvergleiche für die Offline-Analyse und eine Implementierung auf einem Embedded System gemacht werden. Dazu wurde die Analysedauer für Datensätze unterschiedlicher Größe mit dem PADSYS-System gemessen. Tabelle 7.12 zeigt diese Analysedauern für die QRS-Detektion. Beide Verfahren wurden für diese Arbeit in UML modelliert und mit Hilfe des am Institut für Technik der Informationsverarbeitung (ITIV) der Universität Karlsruhe [Ins06b] entwickelten Modell-Transformationswerkzeugs GeneralStore ([Ins06a], [RGMG03]) von Java nach C portiert und auf dem ARM-basierten Prozessor ADuC7026 der Firma Analog Devices implementiert ([Zho05]). Diese Hardwareplattform wird gegenwärtig als universelle Plattform zur Erfassung von Messsignalen für mobile medizinische Anwendungen am ITIV bzw. im Forschungsbereich Medizinische Informationstechnik (MIT) am FZI Forschungszentrum Informatik Karlsruhe [FZI06] aufgebaut. Innerhalb der mit der IDE mitgelieferten Simulationswerkzeuge wurde die Prozessorlast der einzelnen Verfahren für typische Anwendungsszenarien (Abtastrate 200 Hz, 2 EKG-Kanäle, Prozessortakt 22,5 MHz) bestimmt. Diese betrug für das MOBD-Verfahren ca. 11%, für das Pan/Tompkins-Verfahren ca. 20%. Interpoliert man aus den Angaben für die Stromaufnahme aus dem Datenblatt [Ana06] des Prozessors, dann ergibt sich eine ungefähre

Stromaufnahme von 25 mA bei einem Prozessortakt von 22,5 MHz. Die Leistungsaufnahme unter Volllast beträgt dann also

$$P = U \cdot I = 3,3V \cdot 25mA \approx 82,5mW \quad (7.37)$$

Geht man von einer Spannungsversorgung mit zwei AA-Akkus (Zellenspannung 1,2 V, Kapazität 2000 mAh) und einem Anteil des Prozessors an der Gesamtleistung des Systems von 40% aus, so ergibt sich als Systemlaufzeit unter Volllast

$$t = \frac{E}{P} = \frac{2 \cdot 1,2V \cdot 2000mAh}{82,5mW} \approx 23,3h \quad (7.38)$$

Damit ist eine Implementierung des MOBD- oder Pan/Tompkins-Verfahrens auf dieser mobilen Plattform unter der Randbedingung, dass die Mindestlaufzeit des Systems 24 Stunden betragen soll, auf jeden Fall möglich. Auch die Erfassung und Verarbeitung anderer Messgrößen außer dem EKG, sowie die Kommunikation z.B. über Bluetooth<sup>®</sup> ist möglich. Geht man von einer durchschnittlichen Prozessorlast von 60% (QRS-Detektion und -Klassifikation und andere Prozesse wie z.B. die Kommunikation, sowie der Overhead durch das Betriebssystem) aus, so beträgt die Betriebsdauer des Systems mehr als 38 Stunden. Eine Implementierung des waveletbasierten Verfahrens wird die Prozessorlast deutlich erhöhen und damit in jedem Fall die Verwendung weiterer Sensorik einschränken.

Die Modellierung und die automatische Code-Generierung mit GeneralStore erlauben die weitestgehende Konsistenz der Verfahren in den verschiedenen Implementierungsvarianten. Dies hat den Vorteil, dass statt mehrerer paralleler Entwicklungszweige nur eine Version des Verfahrens gepflegt werden muss. Dies geht allerdings mit Einschränkungen hinsichtlich Codegröße und -effizienz auf der mobilen Plattform einher.



# 8 Klassifikation von QRS-Komplexen

Dieses Kapitel gibt zunächst eine Übersicht über die für das Training und die Validierung verwendete Datenbasis. Im Anschluss werden in der Literatur beschriebene Verfahren zur Klassifikation von QRS-Komplexen erläutert, bevor die einzelnen in dieser Arbeit für die Schlagklassifikation herangezogenen Parameter beschrieben werden. Das Vorgehen bei der Regeldefinition für die verwendeten Fuzzy-Klassifikationssysteme wird in Kapitel 8.6 vorgestellt. Die Differenzierung von Schlägen supraventrikulären und ventrikulären Ursprungs als die wichtigste Schlagunterscheidung wird in Kapitel 8.7 beschrieben. Die Vorstellung der erzielten Ergebnisse und eine Beurteilung der Schlagklassifikation bilden den Abschluss dieses Kapitels.

## 8.1 Quantitative Analyse der Datenbasis

Für das Training und die Validierung der Schlagklassifikation wurden dieselben Datenbanken wie für die Schlagdetektion herangezogen. Gemäß den drei maßgeblichen Standards wurden die detaillierteren Schlagklassifikationen nach der WFDB-Konvention (siehe Anhang B.2.3) zu folgenden Schlagklassen zusammengefasst:

- Normal (N) mit den WFDB-Annotationen N, e, j, n, Q, und ?
- Supraventrikuläre vorzeitige Schläge (SVPB) mit den WFDB-Annotationen A, a, J, S
- Schrittmacherinduzierte Schläge (Paced) mit den WFDB-Annotationen / und f
- Fusionsschläge (Fusion) mit der WFDB-Annotation F
- Vorzeitige ventrikuläre Schläge (PVC) mit den WFDB-Annotationen V, r, E und !
- Zusätzlich wurde noch eine Klasse mit Schenkelblockannotationen (Block) mit den WFDB-Annotationen L, R und B geschaffen.

Die Tabellen 8.1 und 8.2 zeigen eine Übersicht darüber, wie oft die einzelnen Schlagklassen in den drei Standard-Datenbanken MITDB, AHADB und EDB auftreten.

Im Rahmen dieser Arbeit und für den späteren Einsatz ist die Detektion von ventrikulären ektopen Schlägen, also der Klasse PVC von besonderem Interesse. Die untersuchten Parameter und Methoden zur Schlagklassifikation konzentrieren sich daher in der Folge auf diesen Anwendungsfall. Auf Grund der teilweise sehr kleinen Kollektive für die anderen Schlagklassen ist es schwierig, keine zu sehr auf die vorhandenen Daten optimierten Fuzzy-Inferenzsysteme zu erstellen.

**Tabelle 8.1:** Übersicht über das Auftreten der einzelnen Schlagklassen in den Standard-Datenbanken

Schlagklasse	Datenbank			Gesamt
	MITDB	AHADB	EDB	
# QRS	109964	181564	790565	1082093
# Normal	75332	161097	784649	1021078
# SVPB	2779	0	1095	3874
# Paced	8010	3142	0	11152
# Fusion	803	829	354	1986
# PVC	7707	16496	4467	28670
# Block	15333	0	0	15333

**Tabelle 8.2:** Übersicht über die prozentualen Anteil der Schlagklassen in den Standard-Datenbanken

Schlagklasse	Datenbank		
	MITDB	AHADB	EDB
Normal [%]	68,51	88,73	99,25
SVPB [%]	2,53	0,00	0,14
Paced [%]	7,28	1,73	0,00
Fusion [%]	0,73	0,46	0,04
PVC [%]	7,01	9,09	0,57
Block [%]	13,94	0,00	0,00

## 8.2 Übersicht über QRS-Klassifikationsverfahren

Dieses Kapitel soll einen Überblick über die für die QRS-Schlagklassifikation verwendeten Verfahren geben. Für eine bessere Übersichtlichkeit werden diese nach ihrer grundsätzlichen Vorgehensweise eingeteilt und es werden nur relativ neue Verfahren beschrieben.

**Heuristische Klassifikationsverfahren** Basierend auf der bekannten Pan/Tompkins Schlagdetektion werden in [Ham02] morphologische Parameter aus dem EKG extrahiert. Aus bereits klassifizierten Schlägen wird ein Template für den aktuell dominierenden Schlag generiert. Mit diesem wird der aktuelle Schlag nach bestimmten Kriterien verglichen und einer der drei Klassen **NORMAL**, **PVC** und **UNKNOWN** zugeordnet. Das Verfahren erreicht laut [Ham02] eine Sensitivität  $SE(V)$  für PVC von 93,38% und eine positive Prädiktivität  $PP(V) = 96,69\%$  auf der MITDB, sowie  $SE(V) = 93,43\%$  und  $PP(V) = 97,92\%$  auf der AHADB.

In [DS04] wird ein weiteres heuristisches Verfahren vorgestellt, das die Klassifikation von normalen und ventrikulären ektopten Schlägen für ein Einkanal-EKG beschreibt. Aus dem bandpassgefilterten EKG werden QRS-Kandidaten detektiert und durch den Algorithmus in insgesamt fünf Zweigen abgeprüft. Es werden jedoch keine Angaben darüber gemacht, wie gut normale und ektope Schläge voneinander unterschieden werden können.

Ein einfacher heuristischer Regelbaum wird in [GSK02] präsentiert. Für ein EKG-Segment um die detektierten QRS-Komplexe herum werden die Koeffizienten eines autoregressiven Modells mit Ordnung  $p = 4$  bestimmt und gemäß der hinterlegten Regeln mit verschiedenen Referenzwerten verglichen. Dadurch ist die Einteilung in verschiedene Schlag- bzw. Rhythmusklassen möglich. Für einen kleinen Teil der MITDB werden folgende Werte für die Detektion von PVC erzielt:  $SE(V) = 94,8\%$  und Spezifität  $Sp(V) = 96,8\%$ .

Rodríguez et al. [RGnI05] untersuchten verschiedene Tools für maschinelles Lernen für die Schlag- und Rhythmusklassifikation. Die besten Resultate wurden mit einem Entscheidungsbaumverfahren erzielt. Auf Grund der Konfusionsmatrix kann eine  $SE(V) = 88,91\%$  und eine  $PP(V) = 92,56\%$  für die in Kapitel 8.1 angegebenen Klassen für Normal- und PVC-Schläge bestimmt werden.

**Statistische Klassifikationsverfahren** Millet et al. stellten 1997 eine Methode zur Berechnung einer diskriminierenden Funktion basierend auf einer logistischen Rekursion für die Bestimmung der Parameterkoeffizienten vor [MPJ<sup>+</sup>97]. Optimiert wurde das Verfahren für zwei verschiedene Funktionen mit fünf und drei Parametern auf 600 Normal- und 600 ektopen Schlägen aus sieben Datensätzen der MITDB. Getestet wurden sie auf den beiden Datensätzen 100 und 200 derselben Datenbank (jeweils Kanal 1). Die Sensitivität für Normalschläge wird mit  $SE_1(N) = 94,6\%$  für die erste Funktion und mit  $SE_2(N) = 98\%$  für die zweite Funktion angegeben. Die im Artikel als „Spezifität“ angegebene Sensitivität für ventrikuläre Schläge beträgt  $SE_1(V) = 97,3\%$  und  $SE_2(V) = 98\%$ .

Einen sehr ähnlichen Ansatz veröffentlichten Jekova et al. im Jahr 2004 [JBC04]. Im Gegensatz zu den wenigen Parametern in [MPJ<sup>+</sup>97] wurden hier jedoch 22 verschiedene Parameter für die Bestimmung der Diskriminationsfunktionen verwendet. Auf der MITDB wurden 97,3% der Normalschläge und 93,3% der ektopen Schläge korrekt klassifiziert.

Statistische Verteilungen physiologischer Parameter sind mit herkömmlichen statistischen Methoden wie ihrer Näherung als Gauss'sche Normalverteilung normalerweise nicht zu beschreiben. Eine Methode, unbekannte Parametervektoren in einem  $N$ -dimensionalen Parameterraum über eine lokale deskriptive Statistik zu klassifizieren, ist die Methode der  $k$  nächsten Nachbarn [Sal99]. Dazu wird versucht, lokale Cluster von Parametervektoren derselben Klasse zu bilden und durch einen repräsentativen Vektor zu beschreiben. Christov et al. [CJB05] verwenden diese Methode für die Detektion ektoper Schläge und erstellen ein globales Referenzset von Klassifikationsvektoren auf der MITDB sowie auf Basis der einzelnen Datensätze lokale Referenzsätze an Hand der ersten 37 Schläge. Mit dem globalen Referenzsatz konnten Werte von  $SE(N) = 80,9\%$  und  $SE(V) = 75,4\%$  auf der MITDB erzielt werden. Bei Verwendung der lokalen Vektoren konnten diese Werte deutlich gesteigert werden, so dass sich  $SE(N) = 96,9\%$  und  $SE(V) = SP(N) = 96,7\%$  auf allen Datensätzen der MITDB ergaben.

**Klassifikation mit Neuronalen Netzen** Hu et al. veröffentlichten 1997 einen Ansatz zur Erkennung von ektopen ventrikulären Schlägen, der auf der Kombination von zwei verschiedenen Klassifikatoren beruht [HPT97]: einem globalen (GE) und lokalen Ex-

perten (LE). Die beiden Klassifikatoren wurden mit Daten aus der ersten Gruppe der MITDB (Datensätze 100–124) mit Hilfe von Self-Organizing Maps (SOM) und zwei Algorithmen aus der Gruppe der Learning Vector Quantization (LVQ) Algorithmen trainiert. Der Test auf der zweiten Gruppe von Datensätzen in der MITDB (200–234 unter Ausschluss von 217 wegen schrittmacherinduzierter Schläge) ergab Werte von  $SE(V) = 82,6\%$  und  $PP(V) = 77,7\%$ .

Die Klassifikation von QRS-Komplexen mit Hidden Markov Modellen (HMM) wird in [CC98] vorgestellt. Für jede Schlagklasse werden ein oder mehrere HMM trainiert. Beim Test auf zehn Datensätzen der AHADB (2201–2210) wurde eine Sensitivität für ektope Schläge von 65,6% und für Normalschläge von 94,2% erzielt. Über die Spezifität oder positive Prädiktivität des Verfahrens können keine Aussagen an Hand der gegebenen Daten getroffen werden.

Den Einsatz einer nicht-linearen Hauptkomponentenanalyse in Kombination mit einem 3-lagigen Feedforward-Netz demonstriert [MSD<sup>+</sup>98]. Im Test auf den Datensätzen 103 und 111 wurden eine Sensitivität von 100% (103) bzw. 91% (111) und eine Spezifität von 100% (103) bzw. 82% (111) für die Detektion von ventrikulären Schlägen erzielt.

In [LCG<sup>+</sup>00] werden die QRS-Komplexe in eine Linearkombination von Hermite-Polynomen zerlegt. Die daraus gewonnenen Koeffizienten werden zur Repräsentation der QRS-Komplexe benutzt und mit einem selbstorganisierenden Neuronalen Netz überwacht in 25 verschiedene Gruppen klassifiziert. Diese Cluster werden auf Grundlage der in ihnen dominierenden Schläge 16 verschiedenen Schlagklassen zugeordnet. Mit der angegebenen Konfusionsmatrix lassen sich folgende Werte für die Datensätze der MITDB berechnen, wenn man die Gruppierungen aus Kapitel 8.1 zugrundelegt:  $SE(N) = 99,8\%$ ,  $PP(N) = 98,9\%$ ,  $SE(V) = 95,3\%$  und  $PP(V) = 97,9\%$ .

Mit identischen Parametern wie in [CJB05] wird in [CB04] für die Unterscheidung von normalen und ventrikulären Schlägen gearbeitet: Insgesamt 26 verschiedene Parameter wurden einzeln, in Gruppen oder alle gemeinsam mit Hilfe eines dreilagigen Netzes mit  $N$  (Anzahl der betrachteten Parameter) Eingangsknoten, fünf Knoten in der Zwischenschicht und einem Ausgangsneuron evaluiert. Als Trainingsverfahren für das Netz werden der Levenberg-Marquardt-Algorithmus und das Bayesian Framework der Matlab Neuronale Netze Toolbox [Mat05] benutzt. Als Ergebnisse auf der MITDB ergeben sich in [CB04] eine  $SE(N) = 99,7\%$  und  $SE(V) = SP(N) = 98,5\%$ , wenn alle Parameter und beide Kanäle benutzt werden.

Herrero et al. benutzen ein dreilagiges Neuronales Netz mit einem Backpropagation-Lernverfahren für die Klassifikation [HGCE05]. Insgesamt werden bis zu 48 verschiedene Parameter für die Klassifikation in die zwei Klassen Normal und PVC verwendet, die aus einem Matching-Pursuit-Verfahren und einer Hauptkomponentenanalyse stammen. Auf Datensätzen der MITDB soll so eine Genauigkeit von 99,8% für die Normalschläge und von 97,9% für die ventrikulären Schläge erreicht werden.

**(Neuro-)Fuzzy basierte Klassifikationsverfahren** In [WTA97] wird ein Fuzzy-Klassifikationssystem vorgestellt, das mit neun Parametern und 15 Regeln eine Identifikation von ventrikulären ektope Schlägen auf der MITDB leistet. Die Sensitivität wird mit 81,34% und die positive Prädiktivität mit 80,64% angegeben. Der Test wurde augenscheinlich standardkonform durchgeführt.

Kundu et al. beschreiben ein mehrstufiges Fuzzy-System mit insgesamt 18 Regeln, die in verschiedene Gruppen eingeteilt sind, um von einer Grob- zu einer Feinklassifikation zu kommen [KNB98]. Die Zugehörigkeitsfunktionen der Fuzzy-Variablen können verallgemeinert („dilatiert“) oder spezialisiert („konzentriert“) werden, so dass weitere Regelmodifikationen möglich sind. Das Verfahren wurde auf einer nicht zugänglichen Datenbank mit nur 18 EKGs getestet, es werden keine Angaben über Sensitivität oder positive Prädiktivität gemacht.

Ein Fuzzy-System mit glockenförmigen Zugehörigkeitsfunktionen wird in [XTRA98] vorgestellt. Dieses ist auf die Erkennung von ischämischen Myokardinfarkten an Hand von Merkmalen spezialisiert, die aus der ST-Strecke im EKG extrahiert wurden. Der Systemaufbau ähnelt dem in Kapitel 6.5 beschriebenen Fuzzy-Perceptron. Das Training erfolgt über einen Least-Square-Ansatz, bei dem der Gesamtfehler über eine zeitabhängige Lernrate durch das Netz zurückpropagiert wird und in der Folge die Zugehörigkeitsfunktionen angepasst werden. Das System erreicht eine sehr hohe Spezifität (99%) bei der Erkennung von Infarkten, aber nur eine recht geringe Sensitivität (54%) beim Test auf einer speziellen Datenbank. Obwohl es in dieser Veröffentlichung nicht um eine Klassifikation von Einzelschlägen geht, soll sie an dieser Stelle aufgeführt sein, da das prinzipielle Vorgehen dem in der vorliegenden Arbeit ähnelt.

Zong [ZJ98] extrahiert aus dem EKG insgesamt 14 Parameter für jeden QRS-Komplex, darunter z.B. auch, ob eine P-Welle detektiert wurde oder nicht. Die Parameter werden durch nicht-lineare Zugehörigkeitsfunktionen fuzzifiziert, wobei nur zwei Zugehörigkeitsfunktionen pro Variable spezifiziert werden können. Diese können jedoch durch Quadrierung in ihrer Selektivität verstärkt werden. Auf der MIT-Datenbank wird auf diese Weise eine Sensitivität von 92,27% und eine positive Prädiktivität von 63,01% für ventrikuläre Schläge erreicht.

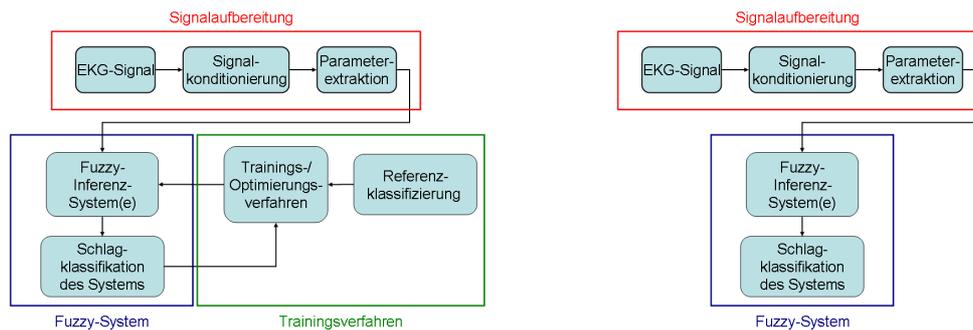
In [OL00] werden die Merkmale für die Klassifikation nicht direkt aus dem EKG gewonnen, sondern aus Kumulanten zweiter bis vierter Ordnung der QRS-Komplexe. Als Klassifizierer wird ein unscharfes selbstorganisierendes Neuronales Netz verwendet, das mit dem Gustafson-Kessel(GK)-Verfahren trainiert wurde. Diese Arbeiten werden in [OL01] fortgesetzt und um ein Multilayer-Perceptron-Netz (MLP) für die endgültige Klassifizierung ergänzt. Aus fünfzehn Datensätzen der MITDB wurde ein Trainings- und Testset generiert, die insgesamt sieben Schlagklassen umfassten. Für das Testset wurde eine Genauigkeit von ca. 96% in der Klassifikation erreicht. Nicht alle Schläge aus den fünfzehn Datensätzen wurden dabei berücksichtigt. Für ventrikuläre Schläge ergibt sich für das Testset (700 Schläge) eine Sensitivität von 96,6%.

Dasselbe Autorenpaar extrahiert in [LOS03] Koeffizienten von Hermite-Polynomen aus dem QRS-Komplex, die im Anschluss mit einem Neuro-Fuzzy-System vom Sugeno-Typ klassifiziert werden. Der Nachteil dieses Systems ist, dass normalerweise eine sehr große Regelbasis für die Abbildung der Eingangsvektoren auf die Ausgangsklassen notwendig ist. Dies wird in dieser Veröffentlichung wie schon in den vorgenannten durch Anwendung des GK-Verfahrens für die Clusterung der Eingangsdaten umgangen. Als Genauigkeit der Klassifikation von sieben verschiedenen Schlagklassen auf einem Testset von 3668 Schlägen aus der MITDB wird ein Wert von über 96% angegeben, wobei der Anteil der Fehlklassifikationen für die einzelnen Klassen zwischen 1 und 11% variiert.

Ein weiterer sehr ähnlicher Ansatz wird in [Eng04] präsentiert: Als Parameter werden normalisierte Varianzen einer DWT mit einem Daubechies-Wavelet db5, ein Kumulant

dritter Ordnung aus [OL01] und die Koeffizienten eines AR-Modells zweiter Ordnung verwendet. Die Eingangsdaten werden dann mit einem hybriden Neuro-Fuzzy-System analysiert. Die Testergebnisse auf 400 Datenvektoren ergeben eine Genauigkeit von 98% für vier Schlagklassen (Normal, Paced, PVC, Block).

### 8.3 Vorgehen bei der Entwicklung der Schlagklassifikation



(a) Training und Optimierung der Schlagklassifikation (b) Einsatz des fertig trainierten Klassifikationssystems

**Abbildung 8.1:** Illustration des Entwicklungsablaufs für die Schlagklassifikation.

Das grundsätzliche Vorgehen bei der Entwicklung der Schlagklassifikation wird in Abbildung 8.1 illustriert. Zunächst werden aus dem EKG durch geeignete Vorverarbeitung verschiedene Parameter extrahiert, die in der Folge durch verschiedene Fuzzy-Inferenz-Systeme klassifiziert werden. Die Ergebnisse dieser Klassifikation werden vom Trainings- bzw. Optimierungsverfahren mit der Referenznotation verglichen und die Zugehörigkeitsfunktionen entsprechend angepasst. Je nach eingesetztem Verfahren (z.B. NEFCLASS-J) ist auch die automatische Erstellung und Änderung der Regelbasis möglich. Für die beiden anderen in Kapitel 6.5 vorgestellten Verfahren ist die Regelbasis fix vorgegeben. Für ein Ursprungskollektiv können mehrere Fuzzy-Inferenz-Systeme (FIS) optimiert werden, denen unter Umständen nur Teilmengen des Kollektivs oder unterschiedliche Parameterkombinationen zugeführt werden können. Für die Kombination verschiedener FIS kommen die Topologien aus Abbildung 6.4 oder Mischformen daraus in Betracht. Nach Abschluss der Optimierung werden nur die gewonnenen FIS weiterbenutzt. Zusätzlich können ähnlich wie bei der QRS-Detektion heuristische Regeln die Klassifikation unterstützen bzw. die Klassifikation auf den einzelnen Kanälen miteinander verknüpfen.

Im Vorfeld wurden auch noch andere Ansätze für die Klassifikation evaluiert. Dazu gehörten zum einen die Analyse mit Entscheidungsbäumen, die nach dem ID3- oder Quinlan-Verfahren gewonnen wurden, zum anderen ein Multilayer-Perceptron-Netz ([Haa05a]). Für die Klassifikation mit Entscheidungsbäumen wurde die freie Software

**Tabelle 8.3:** Ergebnisse für Training und Validierung von ersten Implementierungen der Schlagklassifikation für das ID3-Verfahren und ein Neuronales Netz (NN) im JavaNNS für die Parameter MWI-Amplitude, die RR-Intervalle zum Vorgänger und Nachfolger und die QRS-Breite.

		Training		Validierung	
# N(ormal)		3621		726373	
# PVC		3173		5477	
		SE[%]	PP [%]	SE[%]	PP [%]
NN (JavaNNS)	N	97,5	97,8	96,9	99,9
	PVC	97,5	97,1	97,9	19,4
ID3 (Tanagra)	N	95,7	94,2	95,4	99,9
	PVC	93,3	95,0	93,2	13,3

Tanagra [Rak05], für die Anwendung des Neuronalen Netzes die Java-Implementierung des Stuttgarter Neuronale Netze Simulator JavaNNS [Wil06]) verwendet. Für Training und Validierung wurden in diesem Fall getrennte Datensätze aus der Datenbasis des TeDiaNet-Projektpartners Medset benutzt. Als Schlagklassen wurden Normalschläge und PVC gewählt. Falls für das Training nur kleine oder gleichverteilte Kollektive verwendet werden können, wurden alle PVC-Vektoren aus den Trainingsdaten übernommen, von den Normalschlägen nur jeder  $n$ -te, wobei sich  $n$  aus dem Verhältnis der Kollektivgrößen von Normal und PVC ergibt. Die Ergebnisse für eine Parameterkombination auf Grundlage des Pan/Tompkins-Verfahrens zeigt Tabelle 8.3. Die Klassifikation mit Entscheidungsbäumen zeigte besonders Schwächen beim Training mit großen, ungleich verteilten Kollektiven, da für mehrere Parameterkombinationen alle Merkmalsvektoren der häufiger auftretenden Klasse Normal zugeordnet wurden. Außerdem war ein sehr starkes Overfitting des Klassifikationsverfahrens auf das Trainingskollektiv zu beobachten, was generell zu einer deutlichen Reduzierung der positiven Prädiktivität bei der Validierung führte. Beim Einsatz von JavaNNS muss das Training mit etwa gleich großen Kollektiven für die Ergebnisklassen stattfinden, was eine Vorauswahl der Parametervektoren notwendig macht. Auch hier ist ein Overfitting des Klassifikationsystems zu beobachten: Bei der Validierung nimmt die positive Prädiktivität für PVC deutlich ab. Dies liegt daran, dass die Varianz der Normalschläge durch die Auswahl stark eingeschränkt ist und nur noch einen Teil der Signalvielfalt repräsentiert.

Schwerer als die Probleme bei der Validierung wiegt jedoch, dass die Implementierungen keine ausreichenden Möglichkeiten bieten, um fehlklassifizierte Vektoren zu isolieren. Damit ist es nicht möglich, die verantwortlichen Parameterwerte zu identifizieren und durch gezielten Export der Vektoren das Design eventueller weiterer Klassifikationsstufen zu ermöglichen. Diese Mängel führten dazu, dass diese Verfahren im weiteren Entwicklungsverlauf nicht mehr berücksichtigt wurden und stattdessen die Nutzung bzw. (Weiter-)Entwicklung der in Kapitel 6.4 vorgestellten Verfahren favorisiert wurde. Ein weiterer Nachteil speziell der Neuronalen Netze ist ihre mangelnde Transparenz bei der Entscheidungsfindung, die eine der Anforderungen an das System war.

Die Suche nach den besten Parametern, Regeln und FIS benötigte in Anbetracht der großen Datenmenge ein schrittweises, methodisches Vorgehen. Das modifizierte MOBD-

und Pan/Tompkins-Verfahren bieten in ihren Feature-Signalen so gut wie keine Möglichkeiten, Informationen zu extrahieren, die für die Schlagklassifikation genutzt werden könnten. Zwar bieten sich für einige Datensätze Breite und Amplitude des MWI-Signals als Parameter für die Unterscheidung von normalen und ventrikulären Schlägen an, jedoch hat sich dieser Parameter als unzuverlässig erwiesen [Haa05a].

Mit Parametern, die bei der QRS-Detektion mit Wavelet-Filtern extrahiert wurden, wurden ebenfalls Voruntersuchungen durchgeführt. Auf Grund der Matlab-Implementierung des Verfahrens erfolgte die Erstellung des Trainingssets aus Datensätzen der MITDB (Datensätze 100, 103, 106, 108, 114, 116, 119, 200, 203, 208, 223, 228, 233). Mit einem FIS-Netz mit einer Topologie nach Abbildung 6.4(b) konnten auf dem Trainingsset Werte für die Sensitivität für PVC von  $SE(V) = 95,3\%$  und die positive Prädiktivität von  $PP(V) = 64,0\%$  erzielt werden. Zwar ist diese Detektionsgüte bei weitem noch nicht ausreichend, jedoch bietet dieser Ansatz eine deutlich höhere Flexibilität. Daher wurde für die Erprobung von Parametern für die Schlagklassifikation folgendes Vorgehen gewählt:

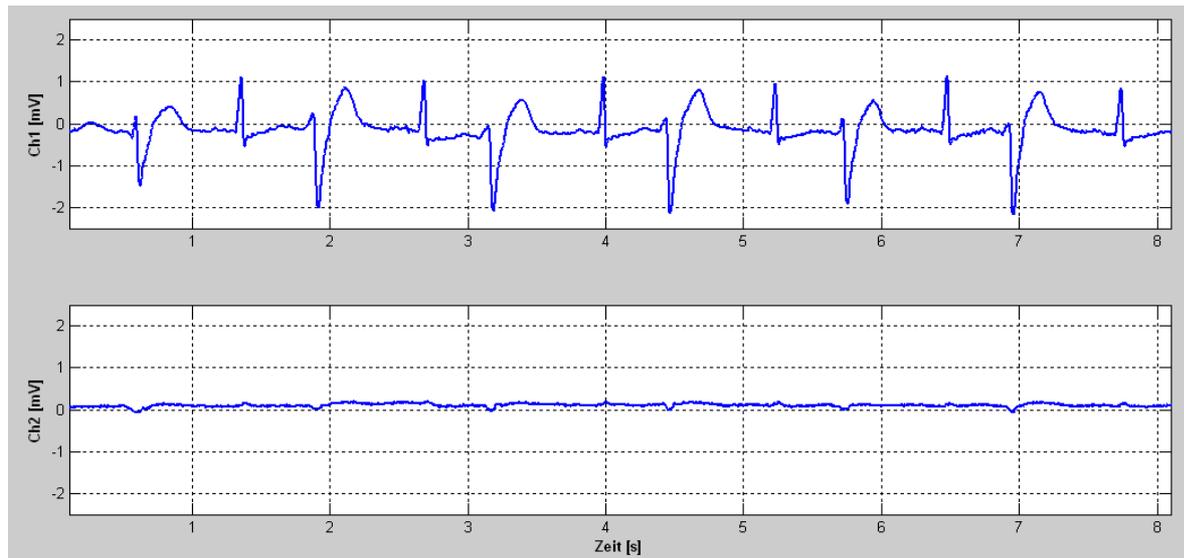
1. Vorverarbeitung der EKG-Signale: Filterung und Bildung der MML und MMP auf Grund der Wavelet-Skalensignale.
2. An Hand der Referenznotation wird das MMP ausgewählt, das am wahrscheinlichsten für die Detektion des QRS-Komplexes verantwortlich ist. Die Referenznotation wird diesem MMP zugeordnet, um das spätere überwachte Lernen zu ermöglichen. Dieser Vorgang wird „Matching“ genannt.
3. Extraktion der Parameter aus den Skalensignalen, aus den Schlagannotationen und aus dem EKG-Signal. Diese wird in Kapitel 8.5 im Detail erläutert.
4. Erstellung, Optimierung und Validierung von Fuzzy-Inferenz-Systemen und FIS-Netzen mit den in Kapitel 6.5 erläuterten Verfahren.

## 8.4 Randbedingungen für die Parameterextraktion und Schlagklassifikation

Um die Leistungsfähigkeit des Systems für einen späteren realen Einsatz einschätzen zu können, wurden einige Randbedingungen festgelegt. Es ist im Weiteren zu beachten, dass diese Randbedingungen im Vergleich zu der großen Mehrzahl der in Kapitel 8.2 vorgestellten Verfahren teilweise deutlich höhere Anforderungen an das Klassifikationssystem stellen. Dies ist bei der Interpretation und dem Vergleich der Ergebnisse zu berücksichtigen. Die einzelnen Randbedingungen werden im Folgenden vorgestellt und begründet.

**Keine Vorauswahl von bestimmten Parametervektoren:** Für viele Implementierungen von Klassifikationsmethoden ist eine Vorauswahl von Parametervektoren erforderlich, um akzeptable Zeiten für das Training zu erzielen oder andere systembedingte

Limitationen zu vermeiden. Dies birgt jedoch die Gefahr, dass die Varianz der auftretenden Signalmuster deutlich eingeschränkt wird und ein „Overfitting“ des Klassifikationssystems eintritt. Daher wurde im Rahmen dieser Arbeit bewusst auf eine solch starke Selektion verzichtet. Um überhaupt ein Training mit genügend Mustern für ventrikuläre Schläge zu ermöglichen, war jedoch eine Auswahl von Datensätzen mit einem möglichst hohen Anteil von PVC erforderlich. Außerdem wurden Datensätze mit einem sehr schlechten Signal-Rausch-Verhältnis (SNR) vom Training ausgeschlossen. Abbildung 8.2 macht deutlich, warum die Einbeziehung des zweiten Kanals des Datensatzes 200 der MITDB für die erste Betrachtung nicht sinnvoll ist.



**Abbildung 8.2:** Ausschnitt aus dem Datensatz 200 der MITDB. Der zweite Kanal (unten) weist eine sehr schlechte SNR auf.

**Beibehaltung der „natürlichen“ Kollektivverhältnisse:** PVC treten deutlich seltener im EKG auf als Normalschläge. Diese statistische Verteilung sollte sich auch im Trainingskollektiv widerspiegeln. Trotzdem muss die Anzahl der PVC im Trainingskollektiv so groß sein, dass die Chance besteht, den Großteil der möglichen Parameterwerte zu erfassen und valide Aussagen zur Detektionsgüte treffen zu können. Aus diesem Grund wurde ein Trainingsset für die weiteren Betrachtungen zusammengestellt, das aus den Datensätzen der MITDB gebildet ist, die prozentual die meisten PVC enthalten (siehe Tabelle B.5). Aus den Datensätzen 106, 119, 200 (Kanal 1), 208, 223 und 233 wurde ein Trainingsset mit insgesamt 19344 Normalschlägen und 7327 ventrikulären ektopten Schlägen gebildet. Schläge der anderen Klassen wurden zunächst ignoriert.

**Keine Vorauswahl der zu untersuchenden EKG-Kanäle:** Wenn nicht anders gekennzeichnet, wurden immer beide Kanäle eines Datensatzes für das Trainingsset verwendet. Eine weitere Auswahl von Parametervektoren auf den Datensätzen fand nicht statt. Es wurde auch nicht darauf geachtet, welche Ableitung in den einzelnen Kanälen verwendet wurde.

**Beschränkung der EKG-Vorverarbeitung auf ein Minimum:** Einzige Modifikation des für die Parameterextraktion verwendeten EKG-Signals im Vergleich zu den Originaldaten war eine Tiefpassfilterung mit einem Anit-Aliasing-Filter vor dem Resampling der Datensätze auf eine Abtastfrequenz von 250Hz.

**Extraktion der Parameter direkt aus dem EKG oder bereits vorhandenen Vorverarbeitungsstufen:** In dieser Arbeit wurden nur Parameter betrachtet, die direkt aus dem EKG oder den bereits durch die waveletbasierte QRS-Detektion vorhandenen Daten extrahiert werden konnten. Eine zusätzliche Verarbeitung des EKGs für die Schlagklassifikation wurde auf ein absolutes Minimum beschränkt (siehe Kapitel 8.5.3).

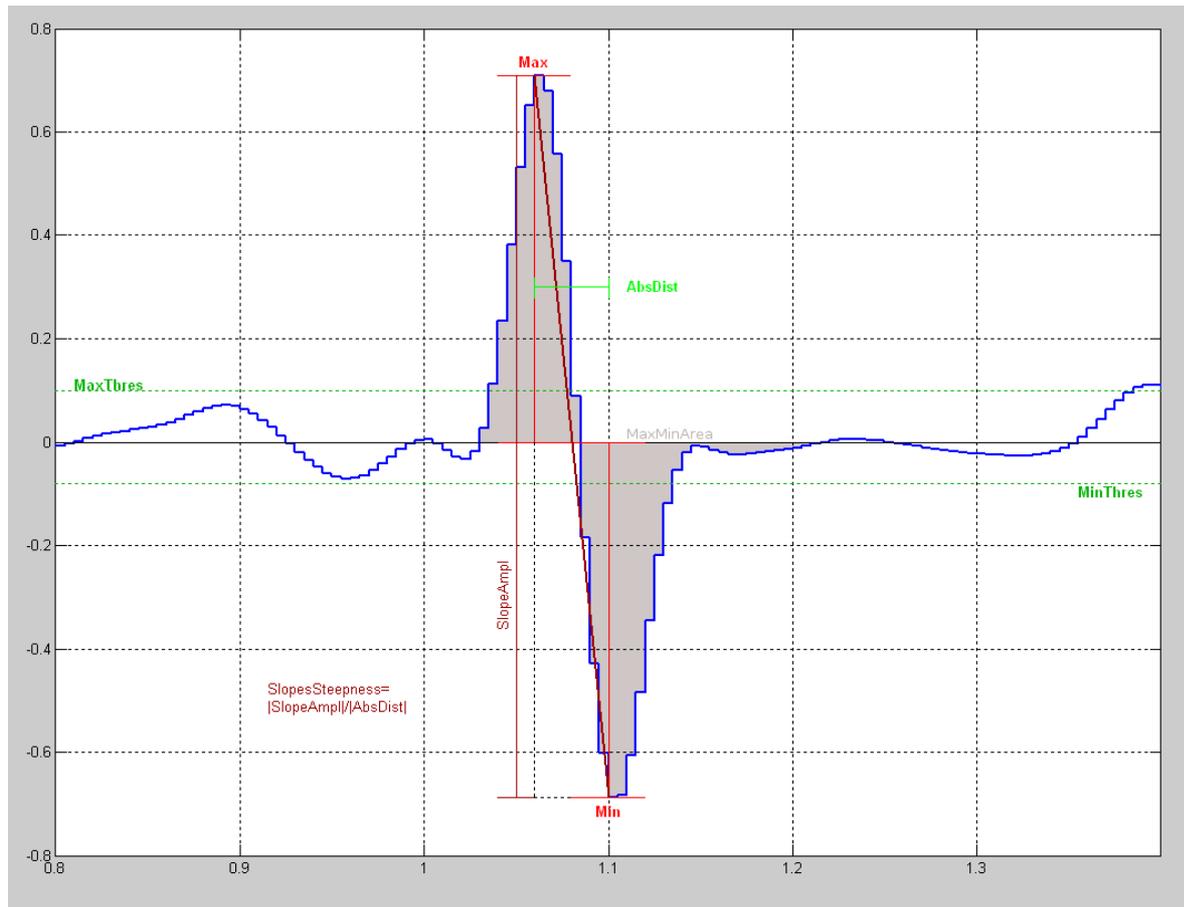
## 8.5 Parameter für die Schlagklassifikation

Im Folgenden werden die für die Schlagklassifikation herangezogenen Parameter vorgestellt. Nach dem „Matching“ zwischen Referenzannotation und MMP werden die Parameter wie in den einzelnen folgenden Abschnitten beschrieben extrahiert. Um trotz der großen individuellen Unterschiede zwischen den einzelnen Datensätzen eine verlässliche Klassifikation vornehmen können, werden diese Werte - falls nicht explizit anders beschrieben - im Anschluss mit dem Medianwert der letzten 100 vorangegangenen Normalschläge des Datensatzes normalisiert. Auf diese Weise ergeben sich für die Klassifikation stabilere Relativwerte. Der Median wurde gewählt, weil dadurch fehlerhafte Parameterwerte, die eventuell in den Ringpuffer mit den letzten 100 Normalvektoren eingetragen werden, eine weniger starke Auswirkung haben, als wenn der arithmetische Mittelwert betrachtet würde.

### 8.5.1 Waveletbasierte Parameter

In Kapitel 7.6 wurden verschiedene Parameter beschrieben, die für die waveletbasierte QRS-Detektion mit Hilfe eines FIS untersucht wurden. Diese Parameter werden auch hier wieder in die Betrachtung mit aufgenommen. Diese Parameter sind:

- Das Verhältnis der MML-Amplituden zu ihren skalenspezifischen Schwellwerte:  $Max2ThresMax_k$  bzw.  $Min2ThresMin_k$
- Die Abstände der Maxima und Minima eines MMPs in den Skalen:  $AbsDist_k$
- Die Abschätzung des Lipschitz-Exponenten  $\alpha'$
- Die Flankensteilheit zwischen den Extrema eines MMPs für jede Skala:  $SlopeSteepness_k$
- Die Fläche unterhalb der Extrema eines MMPs in den Skalen:  $MaxMinArea_k$ . Im Vergleich zu der Implementierung in Kapitel 7.6.3 wird hier jedoch einfach das Betragssignal in den Skalen bis zu den das MMP begrenzenden Nulldurchgängen aufsummiert.



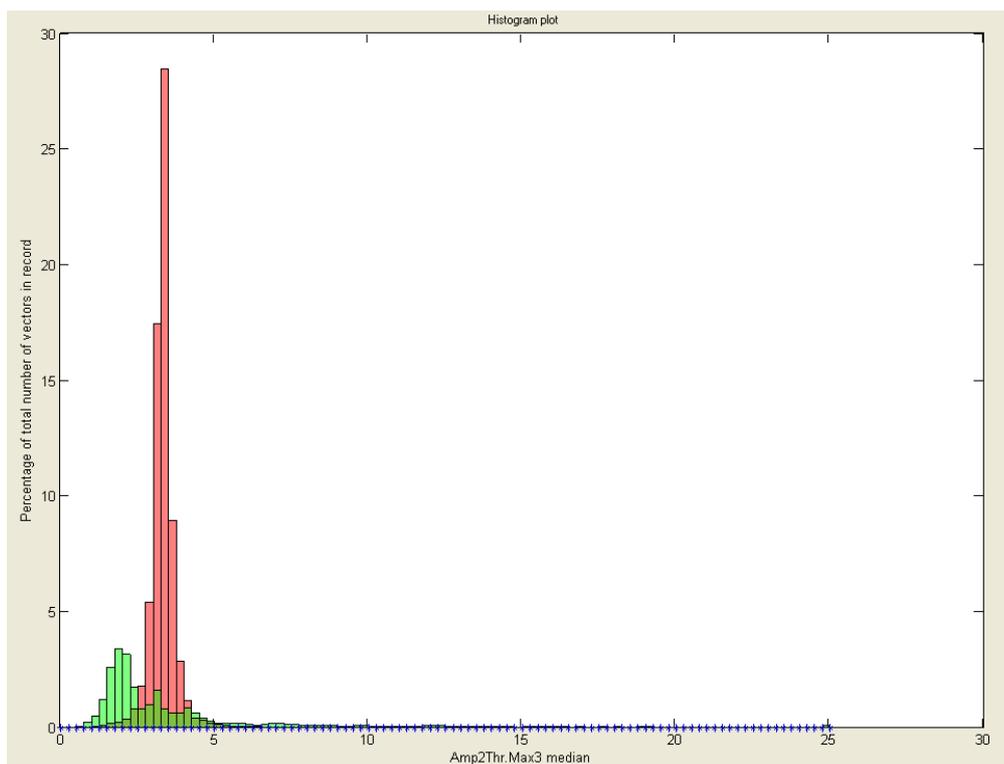
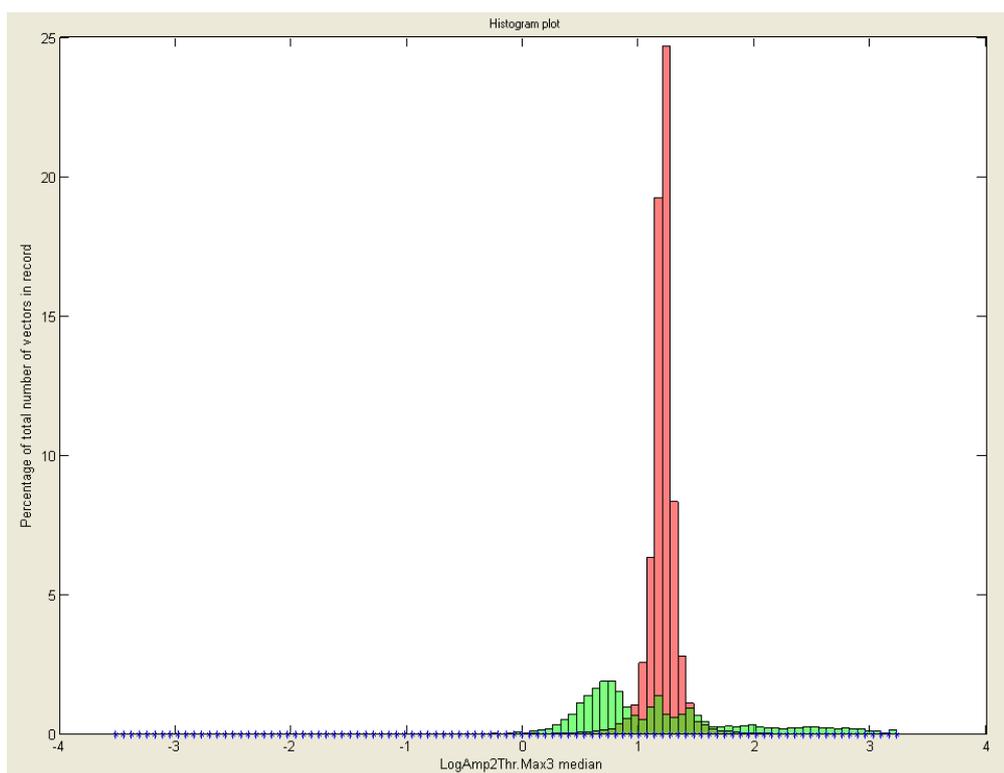
**Abbildung 8.3:** Illustration der skalenbasierten Parameter für die QRS-Klassifikation.

Abbildung 8.3 veranschaulicht die auf den Skalensignalen extrahierbaren Parameter. Die Schätzung des Lipschitz-Exponenten  $\alpha'$  wird wie in Gleichung 7.34 über mehrere Skalen hinweg berechnet. Zusätzlich zu den genannten Parametern werden die Amplitudenparameter noch logarithmiert. Dies dient primär dazu, die Werteverteilung zwischen 0 und 1 auf einen größeren Wertebereich zu transformieren, da die Optimierungsverfahren mit diskreten Schrittweiten bei der Bestimmung der Parameterverteilungen arbeiten. Abbildung 8.4 zeigt die Veränderung in der Werteverteilung bei der Logarithmierung für das Verhältnis der positiven MML-Amplituden zum Schwellwert für die Skala  $k = 3$ . Die Histogrammwerte sind mit der Gesamtzahl der vorhandenen Vektoren normiert worden, um die Größenverhältnisse der Kollektive zueinander besser zu illustrieren.

Alle skalenbasierten Parameter werden für  $k = 1 \dots 5$  berechnet. Dies ergibt insgesamt 36 Parameter, die theoretisch für die Klassifikation genutzt werden könnten.

## 8.5.2 Rhythmusbasierte Parameter

Ventrikuläre Extrasystolen sind durch ein verkürztes Kopplungsintervall charakterisiert. In der Mehrheit handelt es sich um kompensierte PVC, so dass das darauffolgende RR-Intervall deutlich verlängert erscheint (kompensatorische Pause). Daher werden

(a)  $Max2ThresMax_3$ (b)  $LogMax2ThresMax_3$ 

**Abbildung 8.4:** Histogramme für  $Max2ThresMax_3$  und  $LogMax2ThresMax_3$  auf dem Trainingsset. Die Verteilung der Werte für Normalschläge ist rot, die für PVC grün dargestellt.

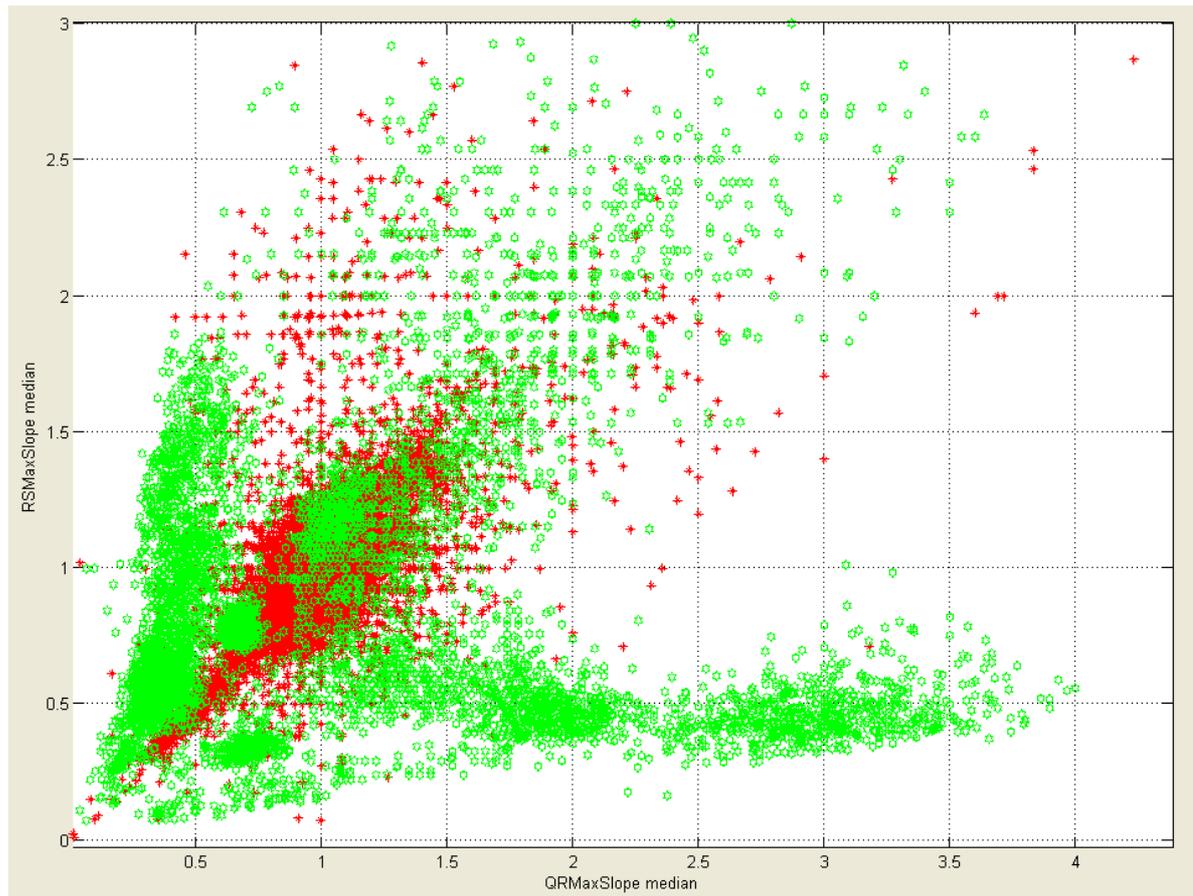
das RR-Intervall zum vorherigen Schlag  $RRInt$  und das RR-Intervall zum Folgeschlag  $NextRRInt$  als Parameter extrahiert. Neben den üblichen Relativwerten zum Median der letzten 100 RR-Intervalle werden hier auch die Absolutwerte extrahiert ( $RRInt_{abs}$ ,  $NextRRInt_{abs}$ ). Weiterhin wird das Verhältnis des aktuellen RR-Intervalls zu seinem direkten Vorgänger bestimmt und logarithmiert ( $RRRatio$  und  $LogRRRatio$ ). Auch diese Parameter sollten bei PVC stärker vom Normalwert, der ungefähr bei 1 liegen sollte, abweichen. Auch hier sollen die logarithmierten Werte eine bessere Auflösung des Intervalls zwischen 0 und 1 ermöglichen. Als weitere Rhythmusinformation wird noch bestimmt, ob es sich bei dem direkten Vorgänger um einen Normalschlag (Wert 0) oder um eine PVC handelt (Wert 1). Dieser binäre Parameter  $PredecessorV$  kann in der Klassifikation verwendet werden, um die späteren ventrikulären Schläge innerhalb einer tachykarden Salve zu identifizieren, da für diese z.B. die  $RRRatio$  keine aussagekräftigen Werte mehr liefert, weil sich das RR-Intervall nur noch relativ wenig ändert. In eine ähnliche Richtung zielen die Parameter  $ShareSBeats$  und  $ShareVBeats$ , die den Anteil der Normalschläge bzw. der PVC an den letzten 20 Schlägen aus der Referenz berechnen.

### 8.5.3 Morphologische Parameter

Diese Parameter werden direkt aus dem EKG gewonnen. Die Parameterextraktion für einen QRS-Komplex erfolgt in einem Zeitfenster um den detektierten Schlag. Dieses beginnt 250 ms vor der R-Zacke und endet 400 ms nach der R-Zacke. Das EKG wird vorher mit einem Cauer-Bandpass 9. Ordnung mit einem Durchlassbereich von 1-30 Hz vorwärts und rückwärts gefiltert, um keine Phasenverzerrung in das Signal zu induzieren. Die Parameterextraktion basiert auf dem in [Ham02] beschriebenen Verfahren: Über ein Flankenkriterium werden der Anfangs- und Endpunkt des QRS-Komplexes bestimmt. Weiterhin werden die Übergangspunkte zur isoelektrischen Linie vor und nach der R-Zacke gesucht. Als Isoelektrische wird ein Zeitabschnitt angesehen, in dem sich das EKG-Signal um weniger als  $100 \mu\text{V}$  ändert. Abhängig von den Signalverhältnissen muss dieses Kriterium für eine Zeitdauer von 80 bzw. 50 ms erfüllt sein. Von den jeweils zwei auf diese Weise bestimmten Anfangs- bzw. Endpunkten wird der wahrscheinlichere ausgewählt. Aus der Differenz wird die Breite des QRS-Komplexes  $QrsWidth$  berechnet. Aus Maximum und Minimum des QRS-Komplexes wird der Parameter  $QrsAmplitude$  bestimmt.

Über das Verfahren aus [Ham02] hinausgehend werden von der R-Zacke aus die Orte der Q- und der S-Zacke ermittelt. An Hand dieser Informationen werden folgende weitere Parameter bestimmt:

- $QRSlope$ : Absolutbetrag der mittleren Steigung zwischen Q- und R-Zacke durch lineare Interpolation. Durch die Betragsbildung wird dieser Parameter von der Polarität des QRS-Komplexes unabhängig. Dies gilt auch für die folgenden flankenbasierten Parameter.
- $QRMaxSlope$ : maximale Steigung zwischen zwei Samples auf der QR-Flanke
- $QRMinSlope$ : minimale Steigung zwischen auf der QR-Flanke



**Abbildung 8.5:** Ausschnitt aus dem Scatterplot für  $QRMaxSlope$  und  $RSMaSlope$  für das Trainingsset. Dargestellt sind die Vektoren für die Normalschläge (rot) und die Vektoren für PVC (grün).

- $RSSlope$ : mittlere Steigung zwischen R- und S-Zacke analog zu  $QRSlope$
- $RSMaSlope$ : Analogon zu  $QRMaxSlope$  auf der RS-Flanke
- $RSMiNSlope$ : Analogon zu  $QRMinSlope$  auf der RS-Flanke
- $QRWidth$ : Abstand zwischen Q- und R-Zacke
- $RSWidth$ : Abstand zwischen R- und S-Zacke. Diese beiden Parameter sind dafür gedacht, Schenkelblockbilder zu differenzieren, da dort durch die unphysiologische Erregung der einen Kammer oft eine Flanke des QRS-Komplexes deutlich breiter ist als die andere.
- $WidthRatio$ : Verhältnis von  $QRWidth$  zu  $RSWidth$ . Auch dieser Parameter soll Auskunft über die Symmetrie des QRS-Komplexes geben.
- $RAngle$ : Öffnungswinkel der R-Zacke: Winkel, unter dem sich die QR- und die RS-Flanke schneiden. PVC sollten wegen der unphysiologischen Erregung einen weiteren Öffnungswinkel aufweisen als Normalschläge.

- *RFlection*: Krümmung der EKG-Kurve in der R-Zacke. Für spitze Normalerregungen ist diese größer als bei unphysiologischem Erregungsverlauf. Für die Berechnung dieses Parameters wird der QRS-Komplex durch ein Polynom 3. Grades approximiert und daraus die Krümmung  $K$  in der R-Zacke über folgende Beziehung bestimmt (siehe [BSMM93])

$$K = \frac{\frac{d^2y}{dx^2}}{\left[1 + \left(\frac{dy}{dx}\right)^2\right]^{\frac{3}{2}}} \quad (8.1)$$

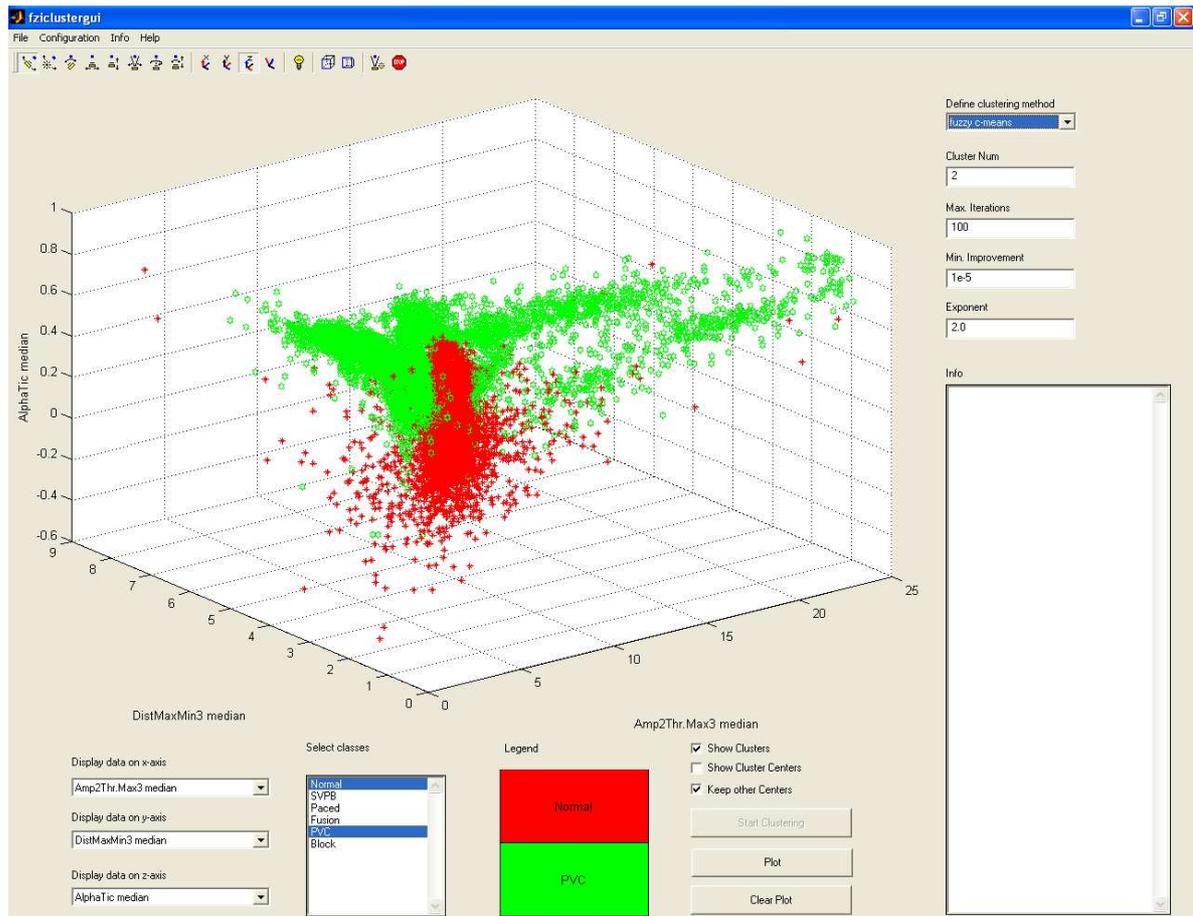
- Aus den Zeitpunkten, zu denen die isoelektrische Linie wieder erreicht wird, werden noch die Parameter *IsoRWidth* und *RIsoWidth* vor bzw. nach der R-Zacke bestimmt.

Besonders bei den letztgenannten Parametern, die aus dem EKG-Signal extrahiert werden, kommt es durch Störungen im EKG-Signal immer wieder zu Problemen bei der korrekten Bestimmung der Anfangs- und Endpunkte des QRS-Komplexes und bei der Detektion der Q- und S-Zacke. Diese können trotz aufwendiger Gegenmaßnahmen bisher nicht vollkommen ausgeschlossen werden und sind einer der Hauptgründe für die relativ breite Streuung der Parameterwerte, die eine Trennung der Schlagklassen erheblich erschweren. Abbildung 8.5 zeigt exemplarisch, wie stark sich die Parameterwerte für viele Vektoren der Normal- und PVC-Klasse überlappen.

## 8.6 Regeldefinitionen als Grundlage für die Fuzzy-Klassifikation

Abbildung 8.6 zeigt ein im Rahmen dieser Arbeit unter Matlab entwickeltes Graphic User Interface (GUI), mit dem Parameterverteilungen zwei- und dreidimensional visualisiert werden können. An Hand der Referenzannotationen können alle ermittelten Parametervektoren einer der sechs in Kapitel 8 definierten Schlagklassen zugeordnet und durch Auswahl in dem GUI angezeigt werden. Über verschiedene Menüpunkte können Informationen über die Anzahl der Parametervektoren für die einzelnen Schlagklassen abgerufen werden oder der Wertebereich von Parametern für die Visualisierung verändert werden, um Subkollektive anzeigen zu können. Diese Applikation enthält außerdem Möglichkeiten, die Daten mit zwei verschiedenen Verfahren zu clustern:

1. Subtraktives Clustern: Hier wird für jeden Parametervektor das Potenzial berechnet, ob es sich um ein Clusterzentrum handeln. Für ein identifiziertes Clusterzentrum werden alle Parametervektoren, die in einer (parametrisierbaren) Einflussumgebung liegen, aus dem Kollektiv entfernt und der Vorgang rekursiv fortgesetzt, bis alle Parametervektoren beschrieben sind. Diese Methode setzt keine bestimmte Anzahl von Clusterzentren voraus.
2. Fuzzy c-means Clustermethode: Ausgehend von initialisierten Clusterzentren, deren Anzahl vor Beginn feststehen muss, wird für jeden Datenpunkt der Zugehörigkeitsgrad zu einem Cluster berechnet. Durch Iteration wird eine Kostenfunktion



**Abbildung 8.6:** Matlab-GUI zur zwei- bzw. dreidimensionalen Visualisierung der Parameterverteilungen. Unten links können die darzustellenden Parameter ausgewählt werden. Die Parametervektoren sind in rot (Normalschläge) und grün (PVC) dargestellt.

minimiert, die durch die Summe der Abstände von Datenpunkten zu den Clusterzentren gewichtet mit ihrem Zugehörigkeitsgrad gebildet wird.

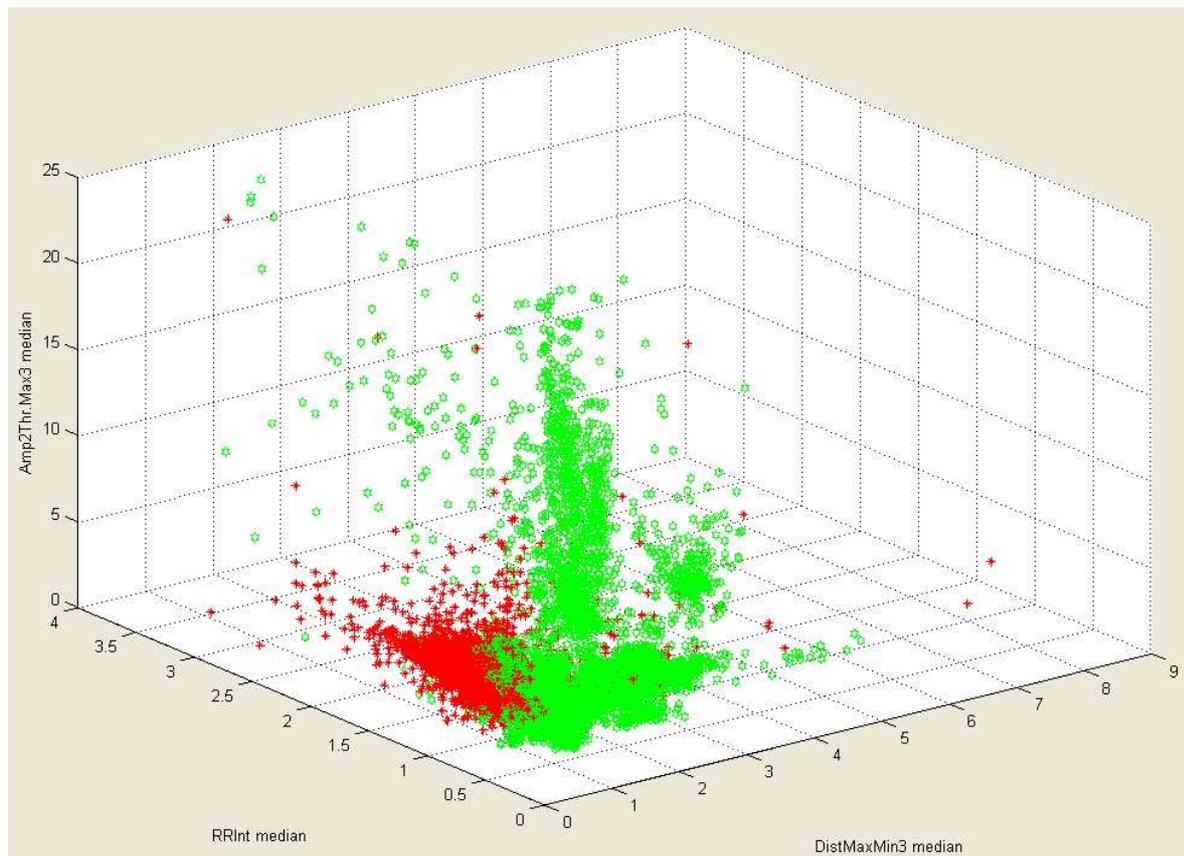
Geeignet gewählte Clusterzentren können an Hand ihrer Lage im Parameterraum beschrieben werden und bilden so eine Grundlage für die Regeln im Fuzzy-Inferenz-System. Alternativ kann die Lage der „Parameterwolken“ direkt in linguistische Terme gefasst werden.

In einem weiteren Matlab-GUI kann die statistische Verteilung der Parameterwerte mit Histogrammen für die verschiedenen Schlagklassen visualisiert werden. Abbildung 8.4 zeigt zwei Beispiele für diese Darstellung. Die Parameterdistribtionen für die Schlagklassen können mit dem Lilliefors-Test auf Normalverteilung überprüft werden, um so Hinweise auf mögliche Einteilungen des Parameterraums zu erhalten. Generell ist jedoch keine Normalverteilung für Parameterwerte bei größeren Kollektiven nachweisbar. Trotzdem kann auch das Histogramm Aufschluss darüber geben, ob sich ein Parameter für die Klassenunterscheidung eignet, insbesondere dadurch, dass die Auftretenswahrscheinlichkeiten der Parameterwerte für die Klassen untereinander in Relation gesetzt werden können.

## 8.7 Differenzierung von supraventrikulären und ventrikulären Schlägen

Die Parametrisierung automatischer Clusterverfahren für Parameterverteilungen, wie sie in Abbildung 8.6 dargestellt sind, ist nicht trivial. Für erste Versuche ist die direkte linguistische Beschreibung schneller und intuitiver, so dass sie in der Folge für die ersten Entwürfe von FIS(-Netzen) benutzt wurde.

Für das Trainingskollektiv wurden durch Inspektion der Verteilungen Parameter für das Fuzzy-Inferenz-System der ersten Stufe gewählt und für diese eine Regelbasis gebildet. Begonnen wurde mit den Parametern  $RRInt$ ,  $DistMaxMin_3$  und  $Max2MaxThres_3$ . Für jeden Entwicklungsschritt wurden die verschiedenen Optimierungsverfahren für die Zugehörigkeitsfunktionen evaluiert.



**Abbildung 8.7:** 3D-Visualisierung der Parameterverteilung für  $Max2MaxThres_3$ ,  $DistMaxMinThres_3$  und  $RRInt$  (Rot=Normal, Grün=PVC).

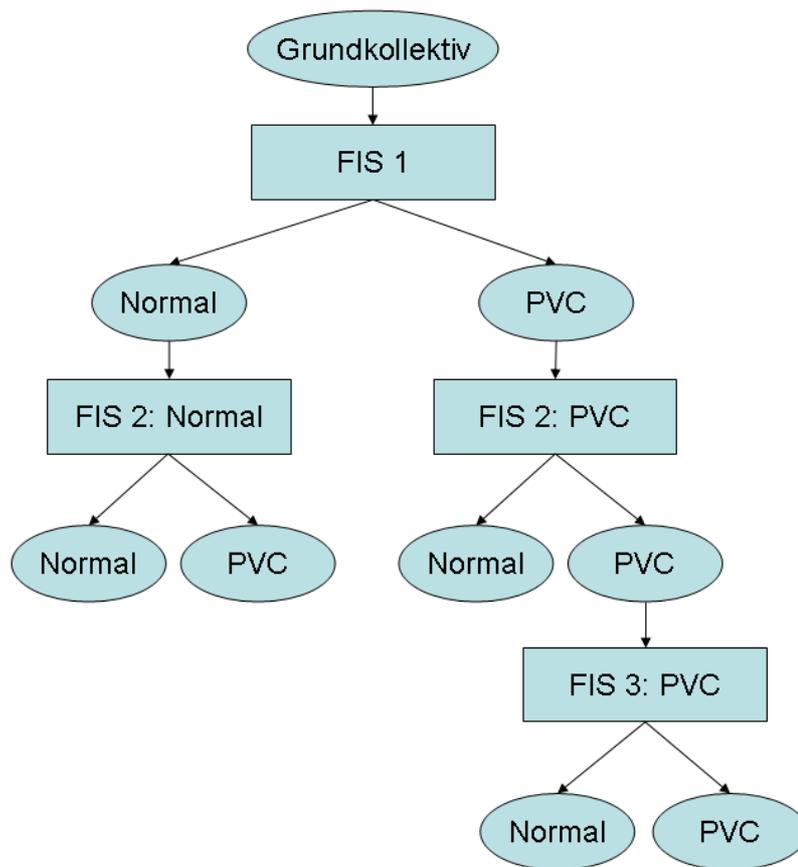
Dabei zeigte sich das NFS-Verfahren aus Kapitel 6.5.2 dem NEFCLASS- und den NFC-Verfahren überlegen. Tabelle 8.4 zeigt die Ergebnisse für alle Verfahren bei Anwendung auf die Parametervektoren des Trainingskollektivs. In der ersten Stufe sollte die Sensitivität für PVC möglichst hoch sein, um die weitere Verarbeitung zu erleichtern.

Durch sequentielle Tests der Ergebnisse einer Klassifikationsstufe auf dem Trainingskollektiv wurde ein FIS-Netz nach Abbildung 8.8 erstellt. Dazu wurden für die Subkol-

**Tabelle 8.4:** Trainingsergebnisse der ersten Stufe für die verschiedenen Optimierungsverfahren.

	NEFCLASS-J	NFS	NFC1	NFC2
SE(N) [%]	98,1	94,8	94,7	97,0
PP(N) [%]	87,4	96,2	96,0	93,8
SE(V) [%]	62,7	90,2	89,7	83,2
PP(V) [%]	92,6	86,8	86,4	91,3

lektive der Ergebnisklassen der vorangegangenen Klassifikationsstufen die Parameterverteilungen reevaluiert, neue Fuzzy-Inferenz-Systeme definiert und trainiert.



**Abbildung 8.8:** FIS-Netztopologie für die Klassifikation Normal-PVC

In den weiteren Stufen wurden noch die Parameter  $\alpha'$ ,  $QrsWidth$  und  $MaxMinArea_3$  verwendet. Damit wird bisher nur ein kleiner Teil der zur Verfügung stehenden Parameterbasis genutzt. Die anderen Parameter können jedoch in weiteren Klassifikationsstufen zum Einsatz kommen, wenn sich die zu klassifizierenden Kollektive so verkleinert haben, dass sie signifikant werden. Die Trainingsergebnisse für das FIS-Netz sind in Tabelle 8.5 aufgelistet. Trotz des asymmetrischen Trainingssets wird eine hohe Detektionsgüte für die PVC-Klasse erzielt.

**Tabelle 8.5:** Klassifikationsergebnisse für das FIS-Netz auf dem Trainingsset.

<b>Training</b>		
test/REF	NORMAL	PVC
normal	18963	552
pvc	381	6775
Summe	19344	7327
	SE [%]	PP [%]
Normal	98,0	97,2
PVC	92,5	94,7

Nach erfolgreichem Training wurde das gesamte Fuzzy-Netz mit den gesamten Parametervektoren für die Klassen Normal und PVC der MITDB für den ersten Kanal getestet. Die Ergebnisse zeigt Tabelle 8.6. Dabei konnte die Sensitivität für PVC in etwa gehalten werden, während die positive Prädiktivität hohe Einbußen in Kauf nehmen musste. Für über 90% der falsch positiven Detektionen ist die dritte Stufe im PVC-Zweig von Abbildung 8.8 verantwortlich, obwohl diese im Training noch eine positive Prädiktivität von 97% auf den Trainingsdaten erzielt hatte.

**Tabelle 8.6:** Klassifikationsergebnisse für das FIS-Netz auf dem Validierungsset.

<b>Validierung</b>		
test/REF	NORMAL	PVC
normal	71837	533
pvc	3458	7075
Summe	75295	7608
	SE [%]	PP [%]
Normal	95,4	99,3
PVC	93,0	67,2

Die bisher gewählten Parameter auf dem Testkollektiv variieren trotz der großen Anzahl von Normalschlägen im Trainingskollektiv noch so stark, dass sich die Klassifikationsleistung deutlich verschlechtert. Dieses Teilkollektiv ist also nicht repräsentativ genug für die gesamte Schlagklasse Normal, was die großen Herausforderungen der QRS-Klassifikation eindrücklich illustriert. Allerdings ist durch den Aufbau des Systems gewährleistet, dass man die problematischen Bereiche der Klassifikation schnell erkennen kann, da es möglich ist, gezielt die falsch klassifizierten Parametervektoren zu begutachten. In der Folge gibt es zwei Möglichkeiten, um gezielte Maßnahmen zur Verbesserung der Detektionsleistung einzuleiten:

1. Verringerung der Varianz der Parameterwerte, um eine bessere Trennung der Klassen zu ermöglichen. Ein Beispiel dafür ist die Stabilisierung der Lokalisation der Anfangs- und Endpunkte von QRS-Komplexen in verrauschten Signalabschnitten.
2. Gezielte Optimierung der hauptverantwortlichen Fuzzy-Inferenz-Systeme unter Berücksichtigung der falsch klassifizierten Parametervektoren. Dies kann sowohl die Auswahl von Trainingsvektoren als auch die verwendete Regelbasis betreffen.

Trotz der Verschlechterung der Detektionsleistung beim Test auf der gesamten Datenbasis erscheint der grundsätzliche Ansatz für die QRS-Klassifikation vielversprechend. Im Vergleich zu anderen in der Literatur beschriebenen Verfahren, die ebenfalls mit einem globalen Klassifikationssystem arbeiten und nicht eine zusätzliche Anpassung auf Basis der einzelnen Datensätze vornehmen ([HPT97], [CJB05]), schneidet der gewählte Ansatz genauso gut bzw. besser ab, insbesondere was die Sensitivität für PVC angeht. Generell ist beim Vergleich der erzielten Ergebnisse mit den in der Literatur angegebenen Werten zu beachten, dass nur zu Teilen aussagekräftige statistische Kennwerte angegeben werden oder in vielen Fällen nur auf einer kleinen, ausgewählten Datenbasis validiert wird. In anderen Fällen ist die Anzahl der zu extrahierenden Parameter sehr groß oder es wird eine lokale Optimierung des Verfahrens vorgenommen, um die Klassifikationsgüte zu erhöhen. Dagegen ist die Komplexität und die Anzahl der verwendeten Parameter des hier vorgestellten Systems vergleichsweise gering, eine lokale Anpassung des Klassifikators ist nicht notwendig. Die verwendeten Parameter sind sehr schnell und einfach zu extrahieren, selbst wenn für die QRS-Detektion ein anderes als das waveletbasierte Verfahren verwendet werden sollte, da die relativ aufwendige Bildung der MMPs bei Vorhandensein einer R-Zacken-Lokalisation erheblich vereinfacht wird. Durch die sequentielle Klassifikation muss auch nicht für jeden QRS-Komplex der gesamte Satz der aktuell verwendeten Parameter extrahiert werden, sondern dies kann erst dann erfolgen, wenn der jeweilige QRS-Komplex durch das Fuzzy-Inferenz-System klassifiziert wird, das diesen Parameter benötigt. Der Mehraufwand, der durch Bestimmung der Zugehörigkeitsgrade und Auswertung der Regelbasis entsteht, wird durch die prinzipielle Überlegenheit der unscharfen gegenüber der scharfen Logik kompensiert. Damit besitzt das System eine geringe Komplexität, ist bei der Klassifikationsentscheidung sehr transparent gehalten und damit sehr gut für den mobilen Einsatz geeignet. In Bezug auf die Güte der Schlagklassifikation besteht noch großes Potenzial, das durch weitere systematische Untersuchung der gegenwärtig vorhandenen Parameterbasis, deren sinnvolle Ergänzung und Weiterentwicklung und durch die Entwicklung weiterer FIS-Netze (auch für die Klassifikation der anderen Schlagklassen) realisiert werden muss. Die Nutzung automatischer Verfahren, z.B. zur Clusteranalyse, sollte dabei fortwährend in Erwägung gezogen werden, auch wenn erste Versuche keine erkennbaren Vorteile gegenüber der manuellen Vorgehensweise gezeigt haben. Ein hybrider Ansatz mit einer manuellen Vorauswahl der relevanten Parameter und die Weiterverarbeitung mit automatischen Verfahren könnte hier zum Erfolg führen.

# 9 Erkennung von ventrikulären tachykarden Arrhythmien

In Kapitel 5.2 wurde die Wichtigkeit einer zuverlässigen Detektion von ventrikulären Tachykardien (VT) oder Flimmern (VF) aufgezeigt. Dieses Kapitel gibt zunächst einen Überblick über die Veränderungen im EKG-Signal beim Eintreten einer VT/VF und stellt anschließend verschiedene in der Literatur beschriebene Methoden und Parameter zur Erkennung tachykarder ventrikulärer Rhythmusstörungen vor. Im Anschluss werden die eigenen im Rahmen dieser Arbeit erzielten Ergebnisse vorgestellt und diskutiert: In Kapitel 9.3 werden die verschiedenen Parameter vorgestellt, die auf Grundlage der Wavelet-Transformationen des EKG-Signals gewonnen werden können. Danach werden in Kapitel 9.4 die Methodik, die Datenbasis und die für die Klassifikation verwendeten Fuzzy-Systeme vorgestellt. Die Diskussion der erzielten Klassifikationsergebnisse bildet den Abschluss dieses Kapitels.

## 9.1 Signaleigenschaften des EKGs bei Auftreten von VT/VF

In Kapitel 3.4.3 wurden bereits Beispiele für die verschiedenen Formen von tachykarden Rhythmusstörungen gezeigt. Daher soll an dieser Stelle nur noch auf die hauptsächlich in diesen Segmenten auftretenden EKG-Morphologien eingegangen werden.

### 9.1.1 Morphologie des EKGs bei VT und VF

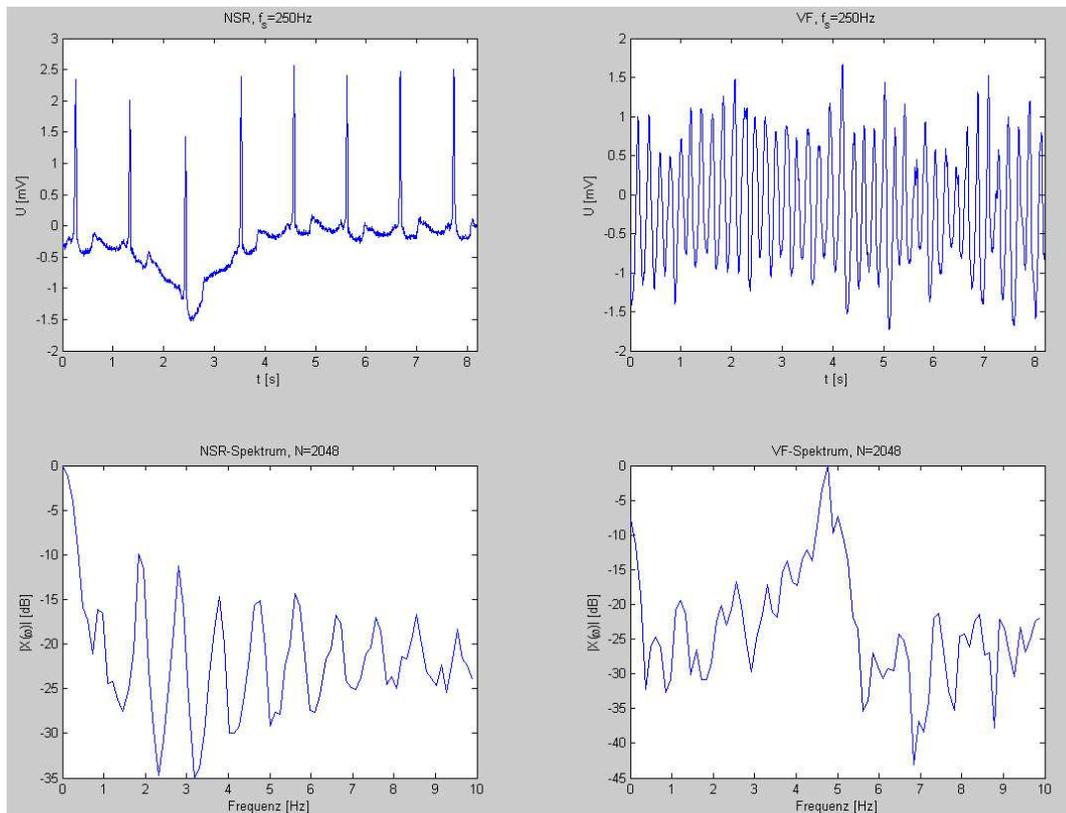
**Ventrikuläre Tachykardie (VT):** Das EKG zeigt gut trennbare einzelne Kammerkomplexe, die aber grob deformiert sind. Dies zeigt sich u.a. in einer Verbreiterung des QRS-Komplexes über 120 ms. Die Herzfrequenz liegt zwischen 160 und 180 bpm. Kennzeichnend ist eine Vorhof-Kammer-Dissoziation, d.h. dass die Kammeraktion nicht durch eine Erregung des Vorhofes initiiert wird. Meist ist bei einer VT keine P-Welle mehr im EKG erkennbar, da sie von den Kammeraktionen überlagert werden. Im anderen Fall können sie keinem QRS-Komplex zugeordnet werden. Niederfrequente VT können in vielen Fällen kreislaufmäßig noch gut toleriert werden. Es kann daher vorkommen, dass auch länger anhaltende Episoden von den Patienten nicht bemerkt werden.

**Kammerflattern:** Dies ist eine besondere Form der VT, bei dem sich Kammeranfangsteil und Kammerendteil im EKG nicht mehr unterscheiden lassen. Dies schlägt sich in einer sinuoidalen Morphologie nieder. Die isoelektrische Linie wird nicht mehr erreicht und die Frequenz der Herzerregung liegt hierbei meist über 200 bpm. Es besteht die Gefahr des Übergangs in Kammerflimmern.

**Ventrikuläre Fibrillation (VF):** Kammerflimmern bzw. VF ist durch irregulär einfallende, bei jeder Kammeraktion unterschiedlich geformte Wellen gekennzeichnet. Die Amplitude ist anfangs noch recht hoch, wird bei anhaltender Rhythmusstörung jedoch schnell kleiner, wenn die kreisenden Erregungen in immer kleinere Bezirke aufbrechen und sich daher ihre Potenziale im Oberflächen-EKG überlagern und auslöschen. Im weiteren Fortgang ist eine Auftrennung des Signals in einzelne Komplexe nicht mehr möglich, die Ermittlung einer Herzfrequenz daher sehr schwierig. Meist werden Werte zwischen 200 und 300 bpm angegeben. Kammerflimmern ist defibrillierungspflichtig, das Herz erbringt hierbei keine Auswurfleistung mehr.

### 9.1.2 Eigenschaften des EKGs im Frequenzbereich

Im Frequenzbereich können weitere wichtige Unterschiede zwischen den verschiedenen Rhythmusklassen gefunden werden. Dazu ist es notwendig, eine genügend hohe Frequenzauflösung zu verwenden, um besonders die niederfrequenten Teil des EKG-Spektrums hinreichend genau auflösen zu können.



**Abbildung 9.1:** Darstellung des EKG-Spektrums für ein NSR- (links unten) und ein VF-Segment (rechts unten) des Datensatzes cu01 der CUDB. In der oberen Reihe jeweils die zugrundeliegenden EKG-Zeitreihen.

Abbildung 9.1 zeigt die Spektralanalyse eines normalen Sinusrhythmus (NSR) und eines VF-Segments im direkten Vergleich. Das NSR-Segment zeichnet sich durch ein

breites Spektrum mit vielen harmonischen Signalanteilen aus [CMC95]. Bei ungestörten Signalen wird das erste Maximum im Frequenzspektrum oberhalb der Gleichsignal-Komponente bei 0 Hz mit der Herzschlagfrequenz zusammenfallen. Die Amplituden der Harmonischen fallen mit zunehmender Frequenz ab, das erste Maximum liegt am niederfrequenten Rand des Spektrums im Bereich zwischen 0,5 Hz und 2,5 Hz. Das Spektrum reicht bis in den Bereich von etwa 100 Hz [TWT84], nach [BU02] bis ca. 200 Hz, jedoch ist der Hauptanteil der Energie im Frequenzbereich bis etwa 30 Hz enthalten.

Beim Kammerflattern und -flimmern konzentriert sich die Energie im Spektrum in einem Bereich zwischen 3 und 8 Hz. Meist ist nur eine Harmonische zu diesem Maximum erkennbar. Die Erscheinungsform des Spektrums ist als Ausdruck der Resonanzerscheinung im Herzen durch den Reentry-Mechanismus zu interpretieren. Die Mittenfrequenz des Maximums entspricht dabei der Frequenz des Wiedereintritts der Erregung.

## 9.2 Ansätze zur Klassifikation von VT-/VF-Episoden

In der Literatur finden sich viele verschiedene Ansätze für die Detektion von VT/VF im EKG. Einen besonderen Schub in diesem Bereich ergab sich durch die Anfang der 1990er Jahre einsetzende Entwicklung von Automatischen Externen Defibrillatoren (AED), die bei bestehendem Verdacht auf Herzkammerflimmern das EKG automatisch analysieren und eine Defibrillationsempfehlung aussprechen. Dadurch ist auch Laien die effektive Behandlung dieser lebensgefährlichen Rhythmusstörung möglich.

### 9.2.1 Stand der Technik und Forschung

#### Übersicht über in der Literatur beschriebene Verfahren

Im Folgenden sollen exemplarisch einige der in der Literatur zu findenden Verfahren und Parameter zur Detektion von VT/VF vorgestellt werden. Es werden nur solche Verfahren dargestellt, für die die Implementierung nachvollziehbar ist.

**Parameterextraktion im Zeitbereich:** Ein häufig verwendeter, aus dem Zeitsignal extrahierter Parameter sind die *Threshold Crossing Intervals (TCI)*, die zuerst von Thakor im Jahr 1990 vorgestellt wurden [TZP90]. Bei den TCI wird die Dauer zwischen den Zeitpunkten bestimmt, für die das EKG einen signaladaptiven Schwellwert überschreitet. Für NSR, VT und VF ergeben sich unterschiedliche Mittelwerte und Varianzen für die TCI, gegen die die aktuellen Werte verglichen werden. Für NSR ist der TCI-Wert hoch, weil entsprechend viel Zeit zwischen den QRS-Komplexen vergeht, in denen der Schwellwert nicht überschritten wird. Je unregelmäßiger der Rhythmus jedoch wird, desto geringer werden diese Zeitspannen. In [CCF96] wurde der TCI-Parameter durch Berücksichtigung der Refraktärzeit des Herzens modifiziert.

Ein weiterer auf Zeitbereichsparametern beruhender Ansatz wird in [TT97] beschrieben. Neben der Standardabweichung der TCI und der Anzahl von Schwellwertüberschreitungen wird der Anteil der Zeit ermittelt, für den sich das Betragssignal des EKGs oberhalb des signaladaptiven Amplitudenschwellwerts befindet. Dieser Parameter wird als *Percent of Time Above or Below Thresholds (PTABT)* bezeichnet und auf einem

Abschnitt von mehreren Sekunden Länge berechnet. Sollten diese Parameter nicht für eine Klassifikation ausreichen, wird zusätzlich die Autokorrelationsfunktion des EKGs herangezogen (siehe nächster Abschnitt).

**Periodizität des Zeitsignals:** Chen [CT87] versucht die fehlende Periodizität des EKG-Signals in VT-/VF-Abschnitten für die Analyse zu nutzen. Dazu wird die Autokorrelationsfunktion (**AKF**) des EKGs berechnet und versucht, eine lineare Regression für die Maxima der AKF zu finden. Dies gelingt nur im Fall von NSR, was als Detektionsmerkmal genutzt werden kann.

**Komplexität und Nicht-Linearität des Zeitsignals:** Eine Bestimmung der Signalkomplexität  $C(\mathbf{n})$  durch Transformation des EKG-Signals in einen binären Datenstring wird in [ZZTW99] vorgestellt. Die Komplexität ergibt sich dabei durch Bestimmung des Vokabulars des binären Datenstrings mit Hilfe einer quantitativen Analyse. Die Umwandlung in die 0-1-Folge erfolgt durch Vergleich mit für die Rhythmusklassen NSR, VT und VF spezifischen Schwellwerten. Sun [SCK05] vergleicht dieses Komplexitätsmaß mit dem **Hurst-Index**. Der Hurst-Index  $H$  ist ein skalarer Parameter mit  $0 < H < 1$  zur Beschreibung eines fraktalen Brown'schen Bewegungsmodells (fBm), das zur Beschreibung von nicht-stationären selbstähnlichen Prozessen dient. Nach Anwendung einer Wavelet-Transformation - Sun benutzt das quadratische Spline-Wavelet aus [LZT95] - kann der Hurst-Index aus der Varianz der ermittelten Wavelet-Koeffizienten  $d_k(n)$  ( $k$  ist der Skalenindex) nach folgender Beziehung bestimmt werden:

$$\log_2(\text{var}(d_k(n))) = (2H + 1)k + \text{konst.} \quad (9.1)$$

**Nutzung der Spektraleigenschaften:** Ein erster Ansatz, die Änderung der Spektralcharakteristik im Falle von VF für ihre Detektion zu nutzen, wurde 1978 von Kuo und Dillmann [KD78] vorgestellt. Diese VF-Filter-Leck-Technik (**Leakage**) beruht darauf, aus EKG-Segmenten die Mittenfrequenz mit einer adaptiven Bandsperre herauszufiltern. Dies geschieht durch Berechnung der mittleren Periodendauer  $T$  des Signals  $s(j)$  mit der Beziehung

$$T = 2\pi \frac{\sum |s(j)|}{\sum |s(j) - s(j-1)|} \text{ mit } j = 0, 1, \dots, N-1 \quad (9.2)$$

und anschließendes Verschieben des Signal um eine halbe Periode. Dadurch werden sinusoidale Signalkomponenten der Frequenz  $f = \frac{1}{T}$  ausgelöscht. Durch die Konzentration der Signalenergie in einem relativ engen Band durch den sinusoidalen Signalverlauf im Falle von VF lässt sich auf Grund der Restenergie des Spektrums auf VF oder NSR schließen.

Ein ähnlicher Ansatz wird in [Hew98c] beschrieben, wobei hier das EKG-Signal näherungsweise als Dreieckssignal modelliert wird.

Jekova [JK04] benutzt ebenfalls ein speziell entworfenes Bandpassfilter, das auf die Frequenzkomponenten von normalen QRS-Komplexen optimiert ist und gleichzeitig für VF typische Frequenzen aus dem Signal herausfiltert. Nach dieser Filterung werden

drei Variablen bestimmt, die aus den ersten zwei statistischen Momenten des Betragssignals ermittelt werden. Die Rhythmusklassifikation erfolgt durch Vergleich dieser Werte mit empirisch ermittelten Grenzen. Bei Unklarheit wird zusätzlich das von [KD78] vorgestellte Periodenkriterium eingesetzt, um über die vorherrschende Herzrate eine abschließende Beurteilung zu fällen.

Ein Detektionsverfahren basierend auf der schnellen Fourier-Transformation (**FFT**) des EKG-Signals wird in [NBB<sup>+</sup>88] vorgestellt. In diesem Verfahren wird die Konzentration der Signalenergie und die gleichzeitige Dämpfung der Harmonischen bei Vorliegen von VF ausgenutzt. Ein weiteres FFT-basiertes Verfahren aus [BRCM89] wird in [CMC93] getestet.

Ein Verfahren zur VT-/VF-Detektion auf Basis eines *Damped Exponential*-Modells (**DE**) des EKG-Signals wird in [CC95] und [CC96] beschrieben. Dieser Ansatz ist einer autoregressiven Modellierung des Signals sehr ähnlich. Das Signal wird durch Amplituden und Pole des DE-Modells und einen unkorrelierten Rauschanteil beschrieben. Aus den Filterkoeffizienten lässt sich die Energieverteilung des Signals schätzen und daraus zwei Klassifikationsparameter berechnen. Der Aufwand des Verfahrens ist von der Ordnung  $O(N^2)$ , das Eingangssignal  $s(n)$  kann laut [CC96] vorher ohne Qualitätseinbußen bei der Klassifikation dezimiert werden.

**Zeit-/Frequenz-Distributionen, Wavelet-Transformationen:** Auf Grund der wechselseitigen Abhängigkeit von Zeit- und Frequenzauflösung bei der FFT wurden in verschiedenen Studien auch andere Zeit- und Frequenzdistributionen (*Time Frequency Distributions*, **TFD**) eingesetzt. Eine Übersicht möglicher TFDs wird in [AT95] vorgestellt, ohne jedoch konkrete Ergebnisse zu nennen.

[MRRIVC99] vergleicht die Choi-Williams-Distribution (**CWD**) und die Cone-Kernel-Distribution (**CKD**) miteinander.

In [MRLSM<sup>+</sup>98] wird eine Spline-Wavelet-Transformation (**SWT**) über fünf Skalen als TFD eingesetzt. Aus den Skalensignalen wurden insgesamt 46 Parameter extrahiert und daraus die aussagekräftigsten für die endgültige Klassifikation bestimmt.

[BDL04] verwendet für die Unterscheidung von NSR und VF die Standardabweichung der *Instantaneous Frequency* (**IF**). Diese wird über eine analytische Wavelet-Transformation (AWT) und der daraus abgeleiteten Bestimmung der Neigung von sog. Wavelet-Ridges (siehe [Mal01]) berechnet.

**Einsatz von Neuronalen Netzen und Fuzzy-Systemen:** Sugiura [SHHK98] extrahiert vier verschiedene Parameter aus dem EKG und führt diese einem **Fuzzy**-System mit 16 Regeln zu, um zwischen NSR, VT und VF zu unterscheiden.

Die in [MRLSM<sup>+</sup>98] extrahierten Parameter werden in [MRVCGCG00] mit Hilfe von Support Vector Machines (**SVM**) klassifiziert.

Wang [WZTX01] berechnet auf kurzen EKG-Abschnitten die sog. Short-Time Generalized Dimensions (**STGDs**)  $D(t, q)$  ( $q$  ist ein Parametrisierungsfaktor des Verfahrens). Für  $q = 2, 4$  werden Maxima, Minima und Mittelwerte aus  $D(t, q)$  bestimmt und einem modifizierten Fuzzy-Kohonen-Netzwerk zur Klassifikation zugeführt.

## Beurteilung der Verfahren

Die in der Literatur beschriebenen Verfahren können nur sehr eingeschränkt miteinander verglichen werden. Dies hängt damit zusammen, dass über lange Zeit keine ausreichende und verbindliche Datenbasis für die Evaluierung derartiger Algorithmen vorlag, die einen direkten Vergleich ermöglichen würde. Dies betrifft v.a. die älteren der vorgestellten Verfahren. Viele der Autoren testeten ihre Verfahren auf der MITDB, der AHADB und der CUIDB, in einem Fall ([JK04]) wird die MIT/BIH Ventricular Arrhythmia Database herangezogen. Nur in einem Teil der Studien werden die gesamten Datenbanken für den Test herangezogen, in vielen Fällen werden nur Teile davon verwendet oder die Daten spezifisch aufgearbeitet, u.a. auch durch Überarbeitung der öffentlich zugänglichen Annotationen. Einige der veröffentlichten Studien testeten darüber hinaus auf denselben Daten, die für die Entwicklung oder das Training des Verfahrens herangezogen wurden. Es gibt einige Übersichtsartikel ([CMC93], [ATU03], [Jek00], [JCD01]), die unterschiedliche Verfahren u.a. auch hinsichtlich ihrer Störempfindlichkeit miteinander vergleichen. Teilweise kommen dabei einige der oben genannten Probleme wie eine unvollständig beschriebene Datenbasis wieder zum Tragen. [BU02] stellt eine Übersicht über einige Verfahren vor, die die in der Literatur angeführten Werte zusammenfasst. In Anhang D befindet sich mit Tabelle D.1 eine aus diesen und den oben genannten Quellen zusammengefasste Übersicht der Verfahren und deren Werte für die Sensitivität, Spezifität und Genauigkeit auf verschiedenen Testdaten.

## 9.3 Waveletbasierter Ansatz für die VT-/VF-Detektion

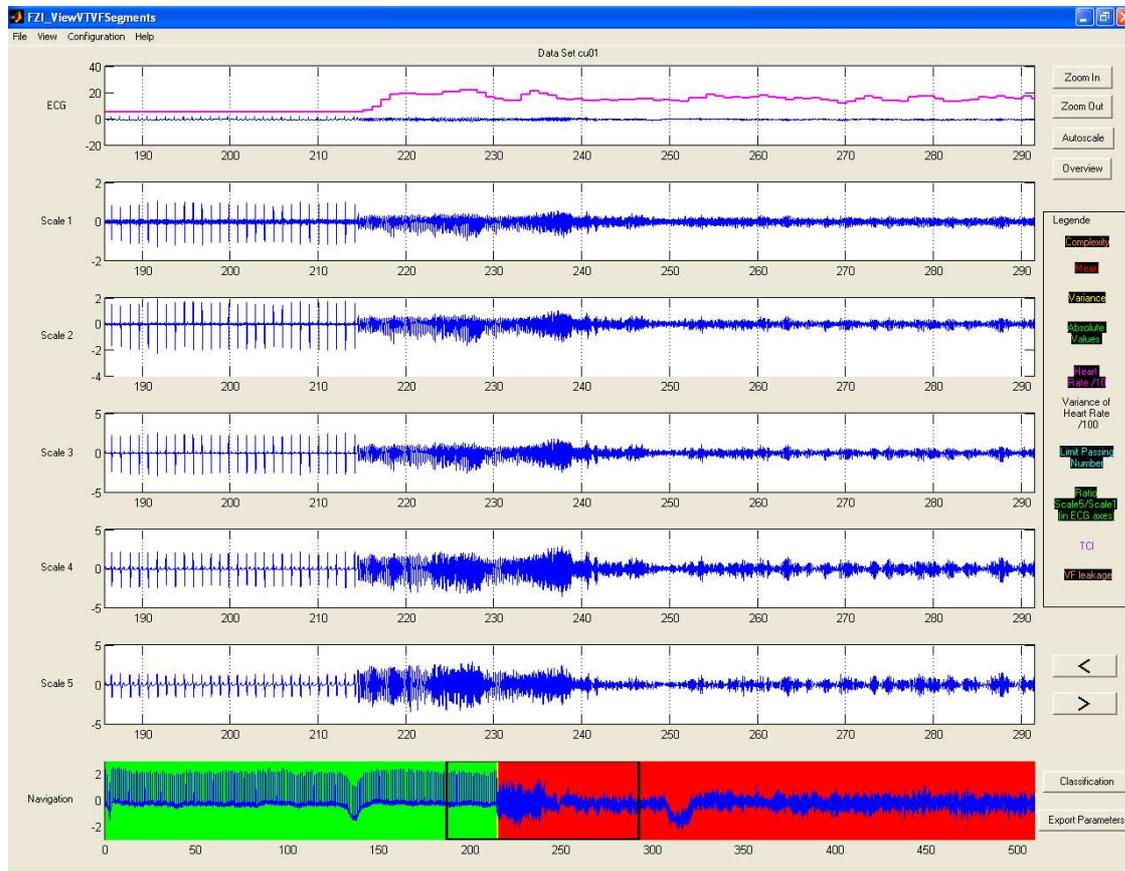
An Hand der unterschiedlichen im Kapitel 9.2.1 betrachteten Ansätze drängt sich die Nutzung der durch die Wavelettransformation gewonnenen Information - z.B. über die Signalenergie in den einzelnen Skalen - auf, um diese für die Rhythmusklassifikation und hier besonders zur Detektion von VT/VF zu verwenden. Die zu diesem Zweck gewonnenen Parameter und die für die Klassifikation verwendeten Regeln werden im Folgenden vorgestellt.

### 9.3.1 Matlab-GUI für die Entwicklung der waveletbasierten VT-/VF-Detektion

Zur Aufbereitung der Wavelettransformation wurde ein selbst entwickeltes Matlab Graphical User Interface (GUI) verwendet, wie es Abbildung 9.2 zeigt. Im Hauptfenster sind zwei EKG- und fünf Wavelet-Achsen vorhanden. Die erste EKG-Achse zeigt denselben Zeitabschnitt wie die Wavelet-Achsen. In diesen Achsen können auch die zeitlichen Verläufe der ermittelten Parameter eingeblendet werden. Die zweite EKG-Achse, die als Navigations-Achse bezeichnet wird, stellt eine Übersicht über das gesamte EKG-Signal dar und zeigt den in den anderen Achsen gezeigten Signalausschnitt durch ein schwarzes Rechteck an. Da die verwendeten EKG-Datensätze mit Notationen versehen sind, können drei Arten von Rhythmussegmenten bereits bestimmt und daraufhin in Sekundenschritten entsprechend farblich in der Navigations-Achse unterlegt werden. Grün

kennzeichnet nicht defibrillationspflichtige Bereiche, gelb steht für Übergänge und rot für VT/VF.

In den Wavelet-Achsen werden die ersten fünf Skalen der Wavelettransformierten des EKG-Signals dargestellt. Zu diesem Zweck wurden die in Kapitel 7.6 beschriebenen Wavelet-Filter zur Verarbeitung des EKG-Signals eingesetzt.



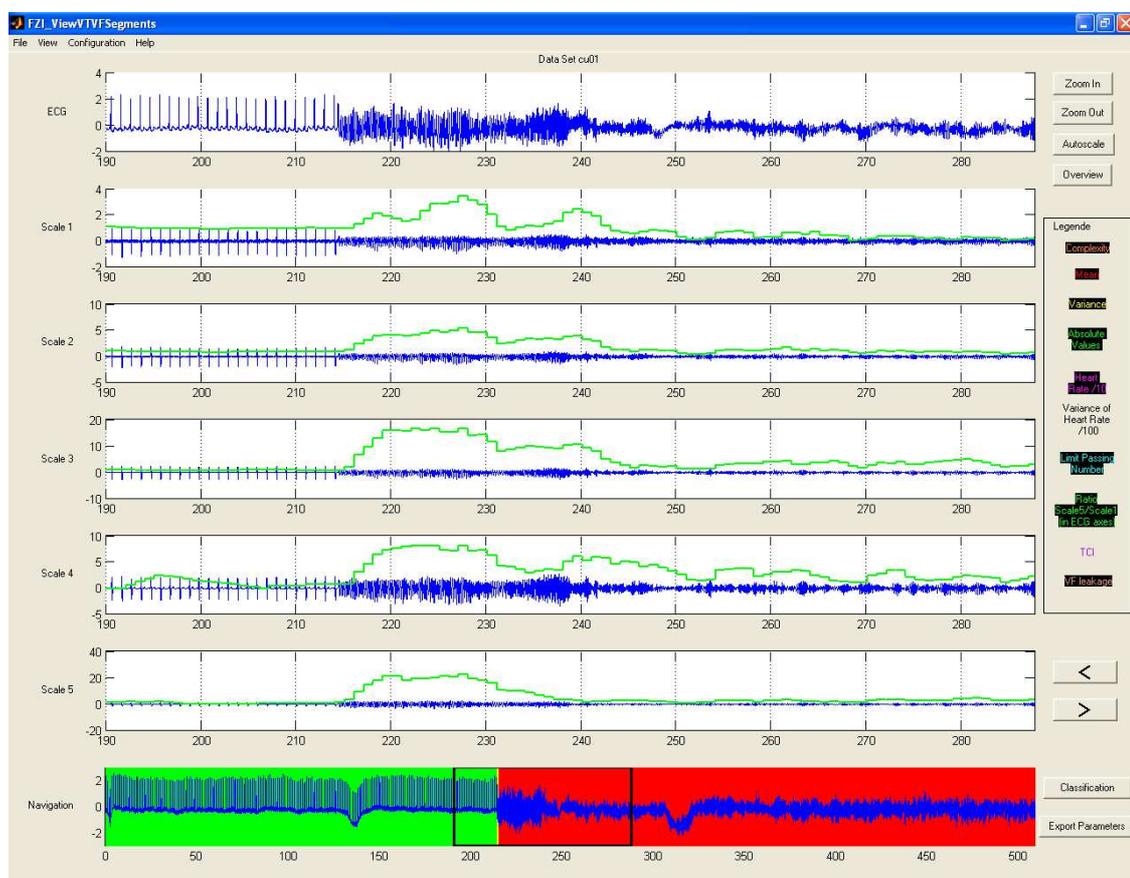
**Abbildung 9.2:** Herzrate (magenta) bei Datensatz cu01 aus [Phy04]. Aus Gründen der Visualisierung ist die Herzrate im Faktor 1 : 10 dargestellt. In den ersten fünf Achsen ist ein Ausschnitt des Datensatzes zu sehen, der durch das Rechteck in der Navigationsachse (ganz unten) definiert ist.

### 9.3.2 Parameter für die VT-/VF-Detektion

**Mittelwert und Varianz** Bei der Suche nach geeigneten Parametern zur Erkennung von VT/VF wurden zunächst die statistischen Werte Mittelwert und Varianz in allen Skalen und dem EKG auf Sekundenbasis gebildet und ausgegeben. Für die Signalklassifikation erwiesen sich diese Parameter als ungeeignet. Die Varianz wird aber in der Folge als signaladaptiver Schwellwert benutzt. Für die Extraktion von Parametern aus dem EKG-Signal kann der Mittelwert genutzt werden, um dieses von Gleichanteilen zu befreien, die die Klassifikation behindern würden.

**Herzrate** Wie in Kapitel 9.1 bereits erklärt, lässt sich über die Bestimmung der Herzrate ab einer Schlagzahl von ca. 160 bpm auf VT/VF schließen. Da bereits in [LZT95] die QRS-Detektion erfolgreich mit den Li-Wavelets durchgeführt wurde, wurde auf der Grundlage dieser Vorgehensweise ein QRS-Detektor implementiert, dessen Funktionsweise in Kapitel 7.6 dargelegt ist. Die Bestimmung der Herzrate ist von der Qualität des QRS-Detektors abhängig. Je höher die Schlagfrequenz des Herzens bei einer ventrikulären Tachykardie wird, umso unregelmäßiger werden die QRS-Komplexe bis sie annähernd in eine Schwingung übergehen, und umso schwerer wird die korrekte Detektion einer „R-Zacke“. Bei Kammerflimmern wird dies durch die Signalmorphologie noch weiter erschwert.

Für die Ermittlung der Herzrate wird für jede Sekunde der Mittelwert der letzten zehn RR-Intervalle berechnet. Dieser Wert wird in Gleichung 3.12 eingesetzt. Abbildung 9.2 zeigt den Verlauf der Herzrate für den Datensatz cu01 der CUDB.



**Abbildung 9.3:** Summe der Absolutwerte (grün) pro Sekunde (bei Datensatz cu01 aus [Phy04])

**Summe der Absolutwerte (Sum of Absolute Values - SAV)** Betrachtet man die Summe der Absolutwerte der Signalanteile in den einzelnen Skalen pro Sekunde, stellt man fest, dass diese Summen über weite Strecken für VT/VF größer sind als bei NSR (siehe Abbildung 9.3). Der normale Sinusrhythmus ist, idealisiert betrachtet, charakte-

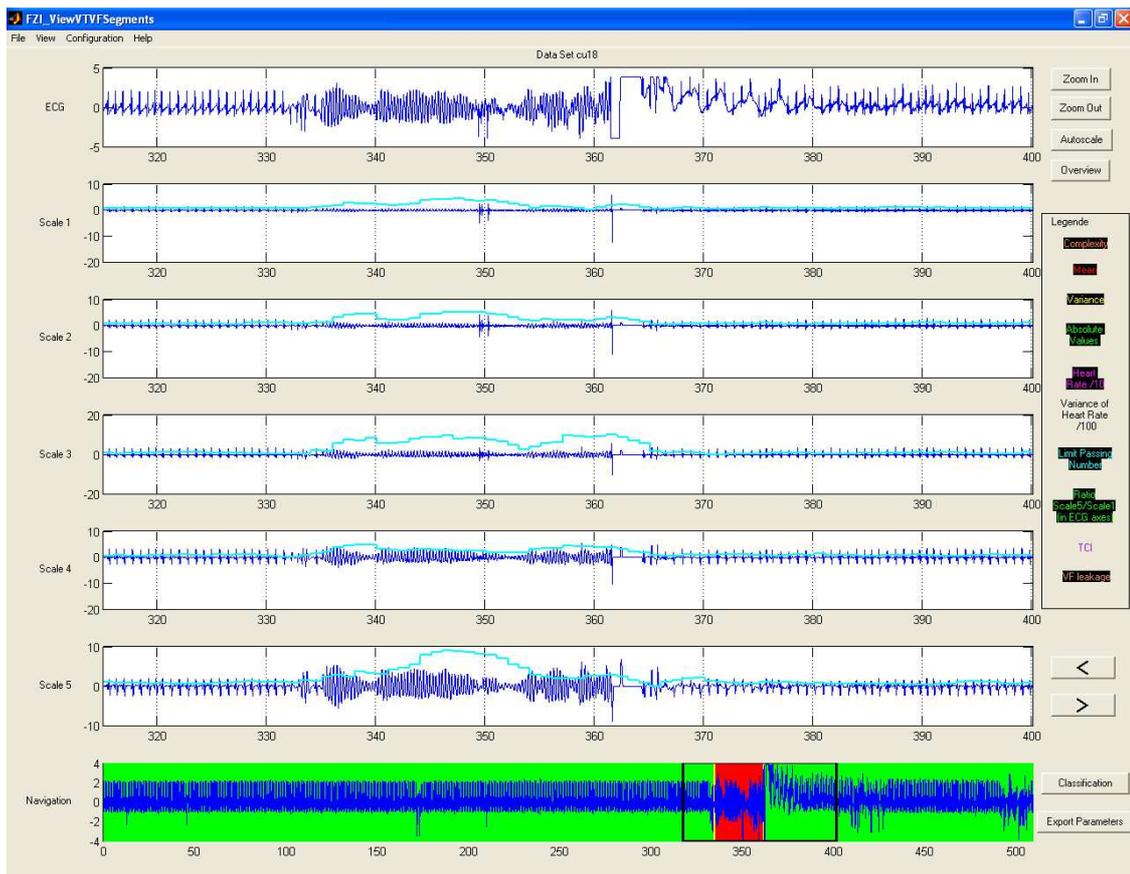
risiert durch lange Nullstrecken zwischen den QRS-Komplexen. In der Realität ergeben sich zwar Schwankungen um die Nulllinie aufgrund von Störungen, jedoch von vergleichsweise geringer Amplitude. Deshalb wird sich bei der Summe der Absolutwerte ein kleiner Wert ergeben. Bei VT/VF liegt eine dauernde Oszillation um die Nulllinie vor, bei Kammerflattern sind bisweilen Amplituden ähnlich derer von R-Zacken möglich. Aufgrund dieser erhöhten Schlagzahl bei VT/VF mit nicht zu vernachlässigenden Amplituden ergibt sich hier die größere Summe. Zur Berechnung wurden die Signale der Waveletskalen in Sekundenabschnitte unterteilt, von den einzelnen Samples der Betrag gebildet und diese aufsummiert.

Diese Betragssumme kann zumindest in den höheren Skalen als Energie des Signals in dem der Skala entsprechenden Frequenzbereich gedeutet werden, da durch die verwendete Li-Wavelettransformation eine starke Bandpassfilterung gegeben ist.

Um den Einfluss von Signalstörungen v.a der Nulllinie von NSR-Segmenten auf diesen Parameter zu minimieren, wurde die halbe Standardabweichung als Schwelle festgelegt. Es werden nun nur noch Werte oberhalb dieser Schwelle aufsummiert, um so die Aussagekraft dieses Parameters zu erhöhen.

**Wavelet-Zeit oberhalb eines Schwellwerts (Wavelets Above Limit - WAL)** Dieser Parameter ähnelt der in [TT97] vorgestellten PTABT, wird hier jedoch auf die einzelnen Wavelet-Skalen angewandt. Meist sind Störanteile im EKG-Signal (Netzbrumm, Bewegungsartefakte) in Signalbereichen normaler QRS-Komplexe dem Betrag nach in allen Skalen kleiner als die WT von VT/VF-Bereichen. Legt man nun ein Band um die Nulllinie jeder Achse, welches die Störsignale zwischen den QRS-Komplexen noch einschließt, kann daraus ein neuer Parameter gewonnen werden, indem alle Signalpunkte gezählt werden, die das Band noch verlassen. In nicht defibrillationspflichtigen Bereichen sind dies nach Möglichkeit nur noch QRS-Komplex-Anteile. In VT/VF-Abschnitten werden jedoch nahezu alle Schwingungen, die die Tachykardie charakterisieren, erfasst. Der Parameter wird bei VT/VF also tendenziell große Werte annehmen, sonst niedrige. Ein anschauliches Beispiel hierfür liefert der Datensatz *cu18*. In Abbildung 9.4 ist ein Signalausschnitt zu sehen, bei dem das VT/VF-Segment deutlich erhöhte Werte dieses Parameters aufweist.

Der Schwellwert für die Gewinnung dieses Parameters wird als Hälfte der Standardabweichung des Signals für jede betrachtete Sekunde des Datensatzes definiert. Auf diese Weise ist ein einfach zu extrahierender, signaladaptiver Schwellwert gegeben. Die Standardabweichung selbst hat sich als in vielen Fällen zu hoch erwiesen: In VT/VF-Bereichen nimmt die Amplitude häufig nach wenigen Sekunden ab oder es kommt im Fall der Torsade de pointes zu einem An- und Abswellen der Amplitude. Ist dies der Fall, kann es vorkommen, dass die Standardabweichung nicht mehr von den Peaks des Flimmerns überschritten wird, was zu einer Verfälschung des Parameters führt. Gerade in VT/VF-Segmenten sollte die Zeit oberhalb des Schwellwertes größer sein als bei NSR. Um dieses Problem zu umgehen, wird durch Verwendung der halben Standardabweichung wieder eine größere Unterscheidbarkeit von NSR und VT/VF aus dem WAL-Parameter ermöglicht. Für das EKG wird der Parameter analog zum geschilderten Vorgehen extrahiert.



**Abbildung 9.4:** Der Parameter WAL: Anzahl der Grenzwertüberschreitungen pro Sekunde (cyan) im Datensatz cu18 aus [Phy04].

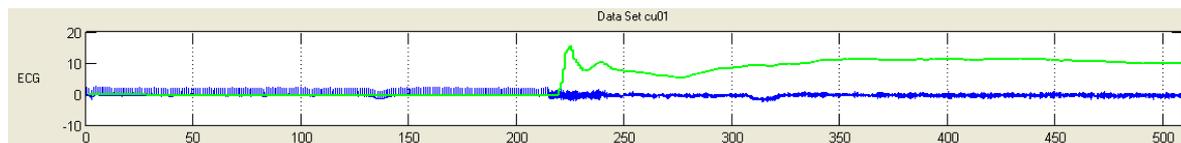
**Korrelation der Parameter mit der QRS-Detektion** Um die Anfälligkeit der Parameter WAL und SAV für Störsignale weiter zu reduzieren, wurde eine Abhängigkeit dieser Parameter von QRS-Komplexen bzw. VT/VF-Schlägen eingeführt. Die QRS-Komplex-Erkennung wurde zunächst allein zur Bestimmung der Herzrate benötigt. Für die Berechnung von WAL und SAV findet sie folgendermaßen Anwendung: Da viele Störsignale wie beispielsweise Bewegungsartefakte eine Amplitude besitzen, die höher ist als die bei WAL und SAV durch die Standardabweichung festgelegten Schwellwerte, gehen diese Störungen voll in die Parameter ein. Sie können in NSR-Segmenten den Anschein von VT/VF erwecken, falls die Störungen die entsprechenden Frequenzen aufweisen. Um dies zu verhindern, werden bei den SAV-Werten nun die Werte um einen QRS-Komplex, die noch oberhalb der Schwelle liegen, aufsummiert im Gegensatz zu sämtlichen Werten oberhalb der Schwelle. Analog werden bei den WAL-Werten nur noch die Zeiten um QRS-Komplexe gezählt.

**„Cross-Scale-Ratio“** Beobachtet man den Verlauf der Amplituden in den einzelnen Skalen, so kann festgestellt werden, dass bei Übergängen von NSR nach VT/VF in Skala 1 die Amplitude schlagartig abnimmt, während sie in Skala 5 annähernd konstant bleibt oder kurzzeitig größer wird. Dieses Verhalten lässt sich mit den spektralen Bestandteilen

von NSR und VT/VF erklären wie sie in Kapitel 9.1 aufgezeigt wurden.

Im vorliegenden Analyseverfahren ergeben sich für Skala 1 durch das verwendete Wavelet-Filter bei einer Abtastrate von 250 Hz ein 3-dB-Durchlassbereich von 62,5 Hz bis 125 Hz. In diesem Bereich gibt es nur bei NSR nennenswerte Signalanteile, woraus der Abfall beim Übergang zu VT/VF resultiert. In Skala 5 mit Frequenzen zwischen 2 Hz und 6,5 Hz hat VT/VF seine stärksten Signalanteile, weshalb es zu einer gleichbleibenden, eventuell sogar ansteigenden Amplitude kommt.

Bildet man das Verhältnis der Maxima aus Skala 5 und Skala 1 pro Sekunde, kann ein Anstieg bei Übergängen von NSR zu VT/VF beobachtet werden, der sich aus den oben genannten Frequenzbetrachtungen ergibt. Auch dieser Parameter wurde von QRS-Komplexen abhängig gemacht, so dass nur die zu einem Schlag zugehörigen Maxima pro Sekunde Verwendung finden.

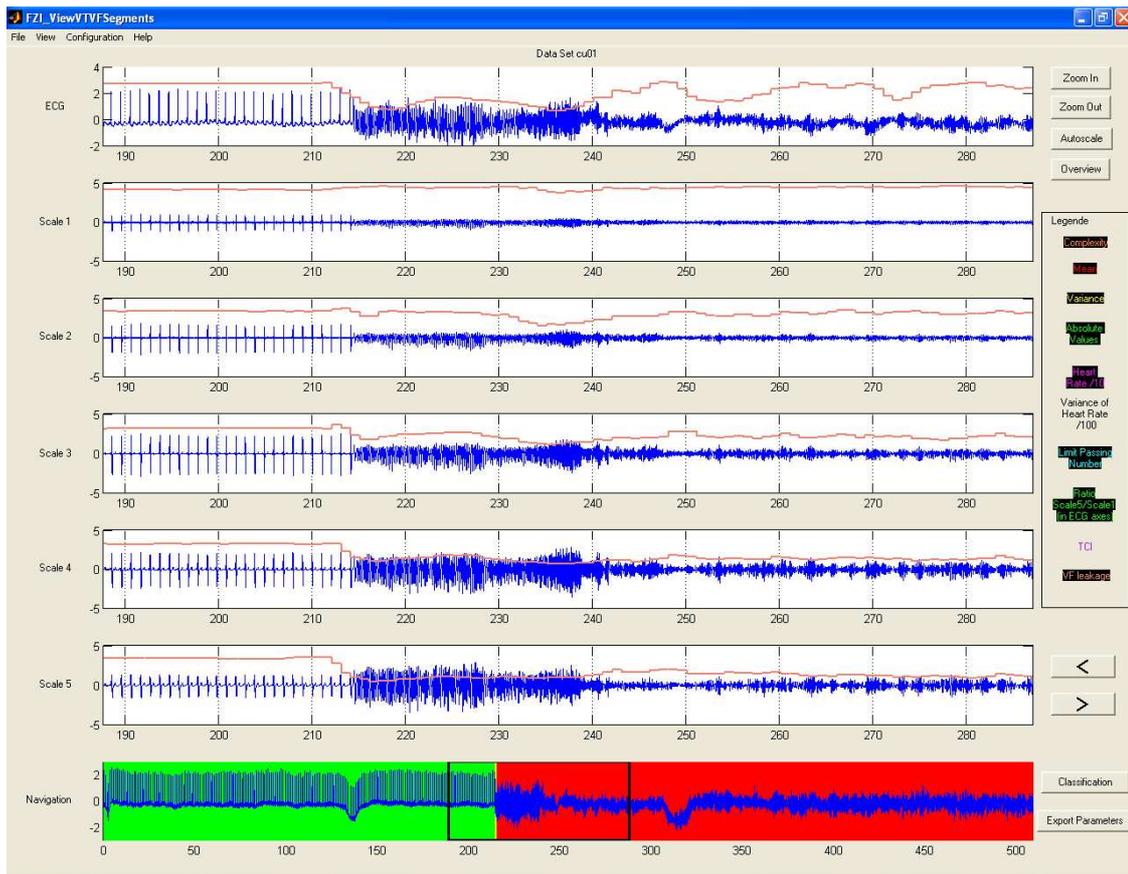


**Abbildung 9.5:** Veranschaulichung des Parameters Cross-Scale-Ratio in der EKG-Achse für den Datensatz cu01. Deutlich ist der Anstieg bei Beginn des VF-Segments erkennbar.

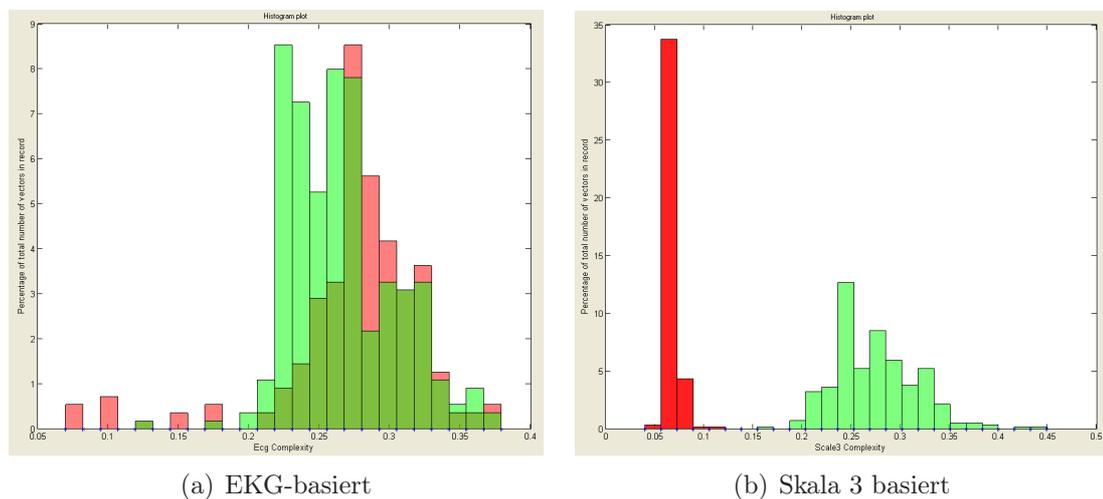
**Filter-Leakage der Wavelet-Skalen** Dieser Parameter ist eine Anwendung des VF-Leakage-Verfahrens nach [KD78] auf die einzelnen Skalensignale mit der in Gleichung 9.2 beschriebenen mittleren Periodendauer  $T$ . Durch die Bandpasscharakteristik der Wavelet-Filter ergibt sich theoretisch vor allem für höhere Skalen eine stärkere Prägnanz des Parameters in VT-/VF-Segmenten als bei der Anwendung auf das EKG-Signal selbst. Abbildung 9.6 zeigt diesen Sachverhalt deutlich für den Übergang zwischen NSR und VT/VF im Datensatz cu01 der CUDB.

**Signalkomplexität der Skalensignale** Analog zu [ZZTW99] wird die Komplexität sowohl des EKGs als auch der verschiedenen Skalensignale nach der in [KS87] beschriebenen Methode berechnet. Das EKG wird zuvor durch einen Schwellwertvergleich in einen Binärstring transformiert. Aus Visualisierungsgründen werden in Abbildung 9.7 zwei Histogramme der statistischen Parameterverteilung für die auf dem EKG-Signal und der Wavelettransformierten für  $k = 3$  berechnete Komplexität gezeigt. Es ist deutlich zu erkennen, dass eine Klassifikation mit diesem Parameter für die Skalensignale vor allem höherer Ordnung einfacher ist.

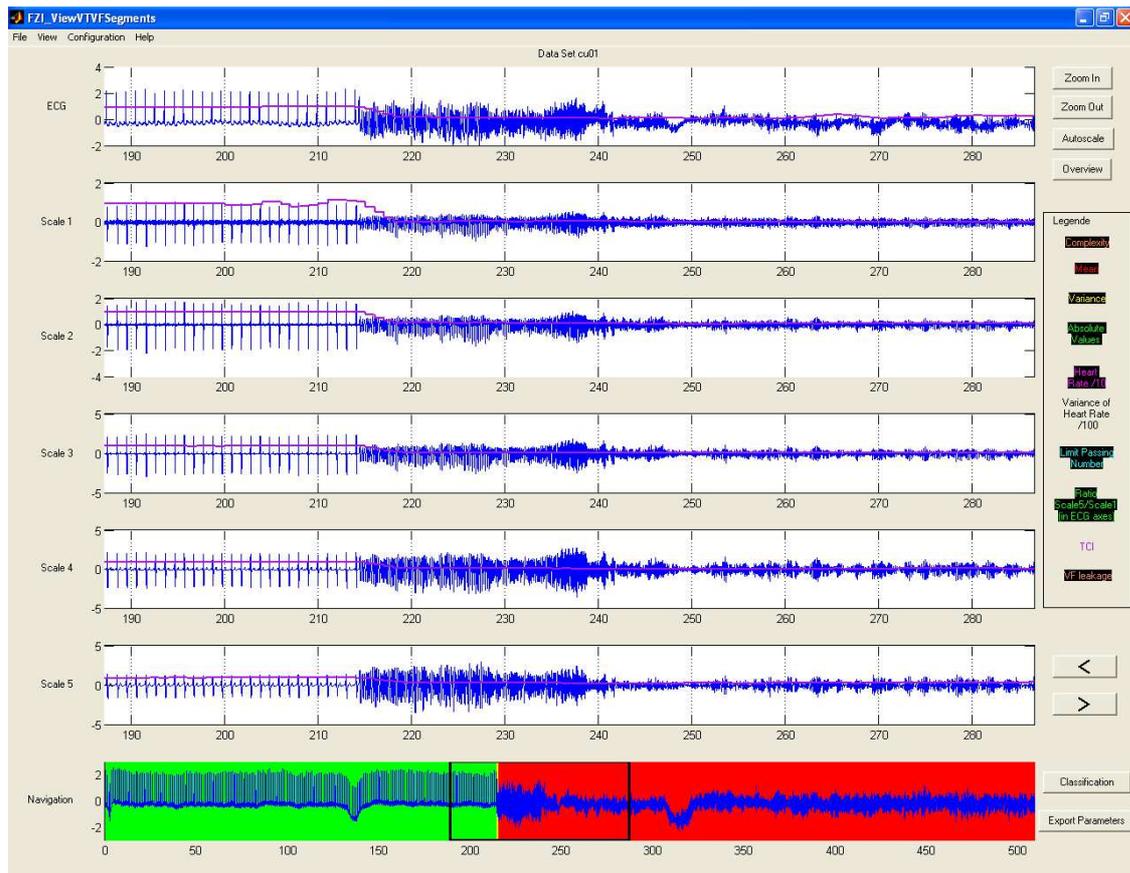
**TCI in Skalensignalen** Auch bei diesem Parameter handelt es sich um eine direkte Anwendung des in [TZP90] beschriebenen TCI-Parameters. Dieser wird neben dem EKG auch auf die Skalensignale angewendet. Auch hier verhält sich der Parameter auf den Skalensignalen stabiler, auch wenn dies nicht so offensichtlich ist wie bei dem Filter-Leakage-Parameter. Abbildung 9.8 zeigt ebenfalls den Übergang zwischen NSR und VT/VF in Datensatz cu01 und den TCI-Verlauf auf allen sechs verfügbaren Zeitsignalen.



**Abbildung 9.6:** Verlauf des Filter-Leakage-Parameters beim Übergang zwischen NSR und VF für den Datensatz cu01 der CUDB



**Abbildung 9.7:** Statistische Verteilung des Komplexitätsparameters auf Grundlage des EKGs (a) und des Skalensignals für  $k = 3$  (b) für den Datensatz cu01. Im Vergleich sind die skalenbasierten Parameter sehr gut voneinander getrennt. In beiden Bildern sind NSR-Segmente rot und VT-/VF-Segmente grün dargestellt.



**Abbildung 9.8:** Verlauf des TCI-Parameters auf dem EKG und den fünf wavelettransformierten Signalen für den NSR/VF-Übergang in Datensatz cu01.

## 9.4 Vorgehen bei der VT-/VF-Klassifikation

### 9.4.1 Evaluationsmethode auf der Datenbasis

Die einschlägigen Standards (siehe Anhang A.2) schreiben das Tool `epic` (bzw. nach einer Namensänderung `epicmp`) aus der WFDB-Softwarebibliothek für die Evaluation von VT-/VF-Detektoren vor. Dieses Tool vergleicht die Position der Referenzmarker („[“ für den Beginn einer VF-Episode und „]“ für deren Ende) mit den durch das getestete System generierten Markern. Daraus werden die Zeiten sich überlappender Segmente gleicher bzw. differierender Klassifikation gebildet, aus denen nach den bekannten Formeln (siehe Anhang A.1) eine sogenannte „Duration Sensitivity“ (*DSE*) bzw. „Duration Predictivity“ (*DPP*) berechnet werden kann. Zusätzlich wird noch eine Sensitivität (*ESE*) und positive Prädiktivität (*EPP*) für das Erkennen von VT-/VF-Episoden berechnet. Allerdings reicht es z.B. für ein TP-Ereignis aus, eine längere VT-/VF-Episode nur für sehr kurze Zeit zu erkennen. Umgekehrt führt bereits die kurzzeitige falsch positive VT-/VF-Diagnose in einem NSR-Segment zu einem FP-Ereignis. Auf Grund der geringen Anzahl von Episoden in den zur Verfügung stehenden Datenbanken haben solche Detektionen für diese Statistik eine überproportionale Auswirkung, so dass diese Parameter nur schlecht zum Vergleich herangezogen werden können. Deutlich aussagekräftiger sind die auf die Zeitdauer bezogenen statistischen Werte.

An dieser Stelle ist anzumerken, dass, soweit dies aus den Veröffentlichungen zu entnehmen ist, alle Autoren der in Kapitel 9.2.1 vorgestellten Verfahren diese auf kurzen Episoden mit einheitlichem Rhythmus getestet haben. Außer den Veröffentlichungen, die ausdrücklich die Sensitivität von Verfahren gegenüber Störungen untersuchen, sind diese Segmente außerdem artefaktfrei. Durch dieses Vorgehen kann auch auf einer beschränkten Datenbasis wie der CUDB eine relativ hohe Anzahl von Episoden erzeugt werden, so dass die Werte für *ESE* und *EPP* statistisch valide gemacht werden können. Trotzdem sagen die damit erzeugten Werte noch nichts über die *DSE* und *DPP* aus, die von den Verfahren erreicht werden kann. Dies ist aber im Prinzip der aussagekräftigere Parameter für die Leistungsfähigkeit der Verfahren und wird daher auch in den Standards als Nachweis gefordert.

In dieser Arbeit wurde die durch das Standard-Tool `epic` vorgegebene Berechnung der *DSE* und *DPP* nachgebildet und parallel zum vorgeschriebenen Tool verwendet. Dies geschah aus folgendem Grund: `epic` listet die Werte für *DSE* und *DPP* nur auf Basis der einzelnen Datensätze auf. Eine genaue Aufschlüsselung der TP-/TN-/FP-/FN-Zeiten wird nicht vorgenommen. Daher ist es nicht möglich, eine Gesamtperformance des Verfahrens auf einer bestimmten Datenbank anzugeben.

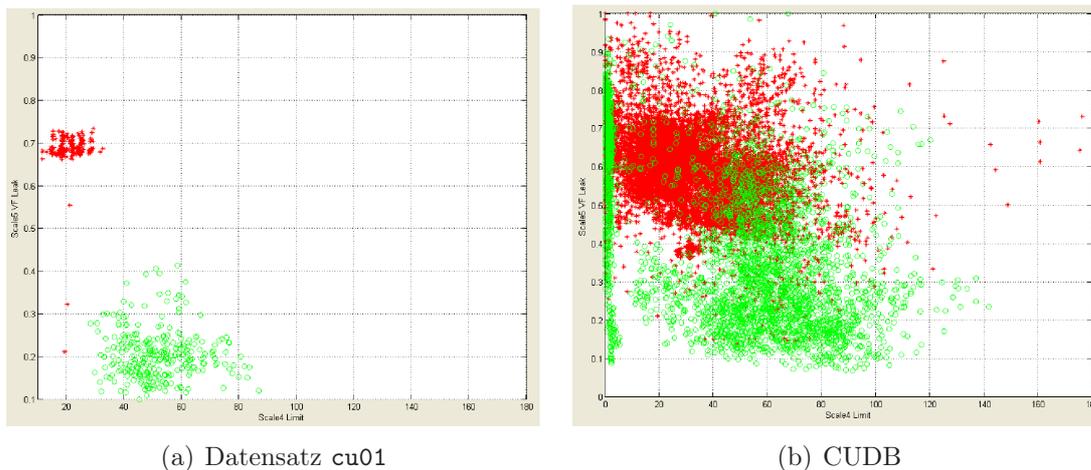
Es wurde folgendes Vorgehen gewählt: Die Referenz wurde an Hand der WFDB-Annotationen für den Beginn bzw. das Ende der VT-/VF-Episoden auf Sekundenbasis generiert. Die Sekunden, in denen die Annotationen zu liegen kommen werden mit „1“ als Übergangsegment gekennzeichnet, bei der Auswertung aber später ausgenommen. Die anderen Sekundensegmente wurden mit „0“ (nicht defibrillationspflichtig, NSR) und „2“ (defibrillationspflichtig, VT/VF) bezeichnet. Auf diese Weise ist eine sekundenge-naue Bestimmung von *DSe* und *D + P* möglich, was für eine Bewertung der Verfahren vollkommen ausreicht. Für die Analyse wurde die CUDB herangezogen, da bis auf eine sehr kurze Episode in der MITDB keine der anderen Datenbanken VT-/VF-Segmente

enthält. Die Datensätze cu02 und cu12 wurden auf Grund ihrer fragwürdigen Annotationen bei der Auswertung nicht berücksichtigt. Die anderen Datensätze wurden keiner weiteren Auswahl unterzogen. Damit wurden auch viele artefaktbehaftete Segmente bei der Analyse berücksichtigt.

### 9.4.2 Klassifikation mit ANFIS

In einer ersten Implementierung wurden für Teile der in Kapitel 9.3 beschriebenen Parameter unter Matlab ein ANFIS generiert, wie es in Kapitel 6.5.4 vorgestellt wurde. Mit Hilfe der Matlab-Funktion `genfis1` wurden die Fuzzy-Inferenz-Systeme automatisch generiert. Diese wurden auf den Datensätzen der CUDB getestet. Der Ausgabewert der Sugeno-FIS wird zunächst über vier Sekunden gemittelt und anschließend gerundet. Sekundensegmente, welche danach Werte  $y \geq 2$  aufweisen, werden als VT/VF bezeichnet, alle anderen Segmente werden als nicht-defibrillationspflichtig eingestuft. Diese konservative Auslegung soll die Anzahl der falsch positiven Alarme reduzieren, die später zu Fehlalarmen führen würden und damit die Akzeptanz des Systems verringern könnten.

Probleme mit ANFIS entstehen, wenn eine größere Anzahl von Parametern mit mehreren Zugehörigkeitsfunktionen miteinander verknüpft werden sollen. Die Regelbasis wird dann schnell sehr groß und unhandlich (siehe Kapitel 6.5.1) und das Training des Systems wird durch die hohe Anzahl von Freiheitsgraden sehr langsam.



**Abbildung 9.9:** Vergleich der Parameterverteilungen für den Parameter WAL Skala 4 (x-Achse) und VF-Leakage Skala 5 (y-Achse) für den Datensatz cu01 und die gesamte CUDB. NSR-Segmente sind rot, VT-/VF-Segmente grün gekennzeichnet.

### 9.4.3 Klassifikation mit NEFCLASS-J, NFS und NFC

Zunächst wurden durch visuelle Inspektion der Parameterverteilungen in den speziell für diesen Zweck entwickelten Matlab-GUIs (siehe Kapitel 8.6) für die Datensätze der CUDB geeignet erscheinende Parameter identifiziert. Das Tool zur zwei- bzw. dreidimensionalen Darstellung wurde darüber hinaus dafür benutzt, durch subtraktives Clustern oder unter Nutzung des in Matlab implementierten Fuzzy-c-mean-Algorithmus

geeignete Clusterzentren für die linguistische Beschreibung zu identifizieren. Abbildung 9.9 zeigt exemplarisch das Problem der Parameterstreuung, das auch bei der QRS-Klassifikation eine zuverlässige Klassifizierung erschwert hat: In Abbildung 9.9(a) ist die Parameterverteilung für den Datensatz cu01 der CUDB zu sehen, der völlig unkritisch zu analysieren ist. In Abbildung 9.9(b) ist dagegen die Verteilung für dieselben Parameter (WAL Skala 4 und VF-Leakage Skala 5) auf der gesamten Datenbank CUDB zu sehen. Auf Grund der auftretenden Parameterverteilungen konnten mit den automatischen Methoden nur unbefriedigende Ergebnisse beim Auffinden repräsentativer Clusterzentren erzielt werden. Stattdessen wurde eine linguistische Beschreibung der Parameter favorisiert.

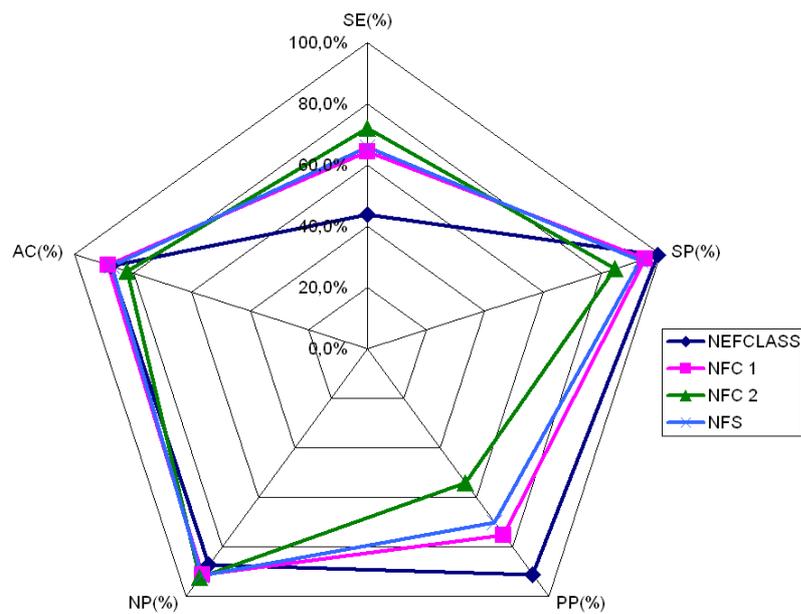
In den Abbildungen 9.10 bis 9.13 sind einige der auf Grundlage aller Datensätze der CUDB erreichten Ergebnisse als Netzdarstellung zu sehen. Für die Optimierung der Zugehörigkeitsfunktionen wurden alle in den Kapiteln 6.5.1 bis 6.5.3 beschriebenen Verfahren verwendet. Bei der automatischen Optimierung der Regelbasis in NEFCLASS-J ergab sich häufig, dass bis auf eine Variable alle anderen aus dem FIS entfernt wurden. Teilweise wurden auch die Zahl der Zugehörigkeitsfunktionen für diese Variable auf zwei reduziert, so dass das FIS zu einem diskreten, binären Klassifizierer wurde. Die durchweg geringe Sensitivität der mit NEFCLASS erstellten FIS liegt zum Teil hierin begründet. Ein anderer Grund ist die ungleiche Verteilung der Ergebnisklassen im Trainingskollektiv. Diese Problematik wurde durch die beiden NFC-Methoden und das NFS umgangen. Bei letzterem ergab sich in einigen Fällen, dass das FIS nicht mehr trainiert werden konnte, da sonst die Merkmalsfunktionen nicht erlaubte Formen angenommen hätten. Diese sind in den Legenden der Abbildungen mit NFS\* gekennzeichnet.

Bei der Beurteilung der Verfahren wurde besonders auf die Sensitivität (SE) und die positive Prädiktivität (PP) für VT-/VF-Segmente geachtet, da diese beiden Parameter am aussagekräftigsten für die Güte der Klassifikation sind. Insgesamt ergibt sich für die Methode NFC 1 aus diesen Ergebnissen das ausgewogenste Bild, so dass sie in der Folge für die Optimierung der FIS weiterverwendet wurde.

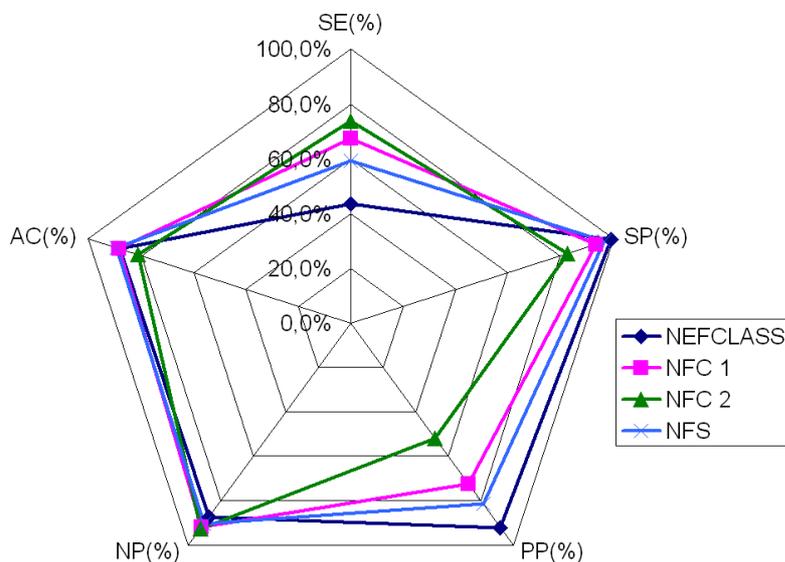
Auf Grundlage der gemachten Erfahrungen wurde ein „Start-Fuzzy-Inferenzsystem“ (SFIS) mit acht Regeln entwickelt, das aus folgenden Parametern besteht:

- Herzrate (HR)
- WAL-Parameter Skala 4 (WAL4)
- Signalkomplexität Skala 3 (Compl3)
- VF-Leakage Skala 5 (VFLeak5)

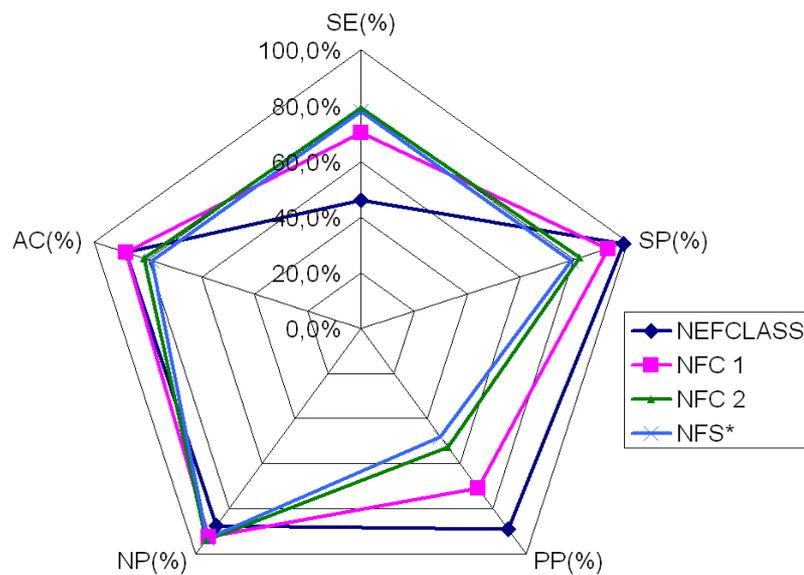
Um eine Vergleichsmöglichkeit für das Verhalten der EKG-basierten Parameter gleicher Charakteristik zu haben, wurden diese Parameter ebenfalls direkt aus dem EKG-Signal extrahiert. Dieses System wird im Weiteren „EFIS“ (EKG-FIS) genannt. Diese beiden Systeme wurden mit Hilfe von extrahierten Parameterwerten für die ersten zehn Datensätze cu01 bis cu11 der CUDB (cu02 wurde nicht berücksichtigt) optimiert. Da die Klassifikationsgüte für das SFIS noch zu gering war, wurden die bei dieser Klassifikation als „unsicher“ eingestuften Parametervektoren mit einem weiteren FIS nochmals klassifiziert, also die Topologie nach Abbildung 6.4(c) verwendet. Der Schwellwert für



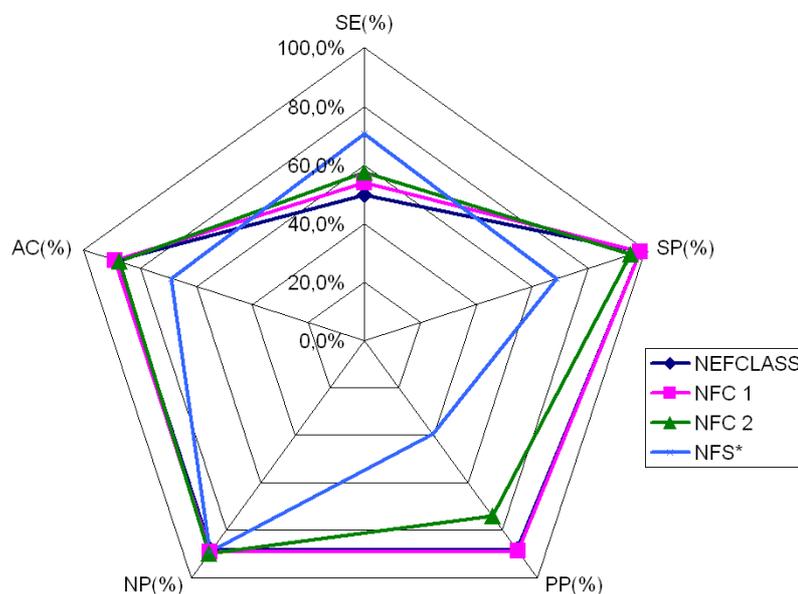
**Abbildung 9.10:** Netzdarstellung für die statistischen Parameter bei Verwendung der Parameter WAL Skala 4 und VF-Leakage Skala 5 für die einzelnen Optimierungsverfahren.



**Abbildung 9.11:** Netzdarstellung für die statistischen Parameter bei Verwendung der Parameter WAL Skala 4, Signalkomplexität Skala 3 und VF-Leakage Skala 5.



**Abbildung 9.12:** Netzdarstellung für die statistischen Parameter bei Verwendung der Parameter Herzrate, WAL Skala 4, Signalkomplexität Skala 3 und VF-Leakage Skala 5.



**Abbildung 9.13:** Netzdarstellung für die statistischen Parameter bei Verwendung der Parameter Herzrate, Cross-Scale-Ratio, WAL Skala 4 und VF-Leakage Skala 5.

die Einstufung als unsicherer Schwellwert wurde zu  $q = 0,8$  gewählt. Dieses FIS für die Feinklassifikation wird FFIS genannt und verwendet folgende Parameter:

- Signalkomplexität Skala 3
- TCI Skala 2
- VF-Leakage Skala 5

Die dazu äquivalenten Parameter wurden außerdem direkt aus dem EKG extrahiert und mit den bei der Klassifikation mit EFIS als unsicher erkannten Vektoren ein zweites FIS (EFFIS) trainiert. Durch Kombination der verschiedenen Systeme wurden damit insgesamt vier verschiedene Tests generiert:

- Test 1: SFIS alleine
- Test 2: EFIS alleine
- Test 3: SFIS und FFIS
- Test 4: EFIS und EFFIS

Um die Auswirkung der Länge der Segmente, die für die Berechnung der einzelnen Parameter herangezogen werden, zu studieren, wurden die oben genannten Parameter auf den Datensätzen der CUDB für Segmente von ein bis acht Sekunden Länge extrahiert. Die Segmentlänge wird mit „CropSize“ bezeichnet. Um einzelne, durch Artefakte bedingte Ausreißer zu eliminieren, wird im Anschluss an die Analyse eine Glättung der Klassifikation vorgenommen. Zu diesem Zweck werden nur zusammenhängende VT-/VF-Segmente, die eine bestimmte Mindestdauer („SmoothingDuration“) überschreiten mit „VT/VF“ als endgültiger Klassifikation versehen. Kürzere VT-/VF-Segmente werden zu NSR umklassifiziert. Als Mindestlänge für die VT-/VF-Segmente wurden nach mehreren Vorversuchen Zeitdauern von acht bis zehn Sekunden festgelegt. Auf diese Weise wird die Zahl falsch positiver VT-/VF-Detektionen und damit auch die Anzahl von möglichen Fehlalarmen minimiert. Dieses Vorgehen geht jedoch zu Lasten der Sensitivität. Um trotzdem eine Aussage treffen zu können, ob relevante Episoden mit ausreichender Sicherheit erkannt werden, wurden die Testklassifikationen noch mit einer auf das bekannte Sekundenraster modifizierten Referenz mit dem Standardtool `epic` verglichen und die Episodensensitivitäten und -prädictivitäten bestimmt.

## 9.5 Ergebnisse der VT-/VF-Rhythmusklassifikation

### 9.5.1 Klassifikation mit ANFIS

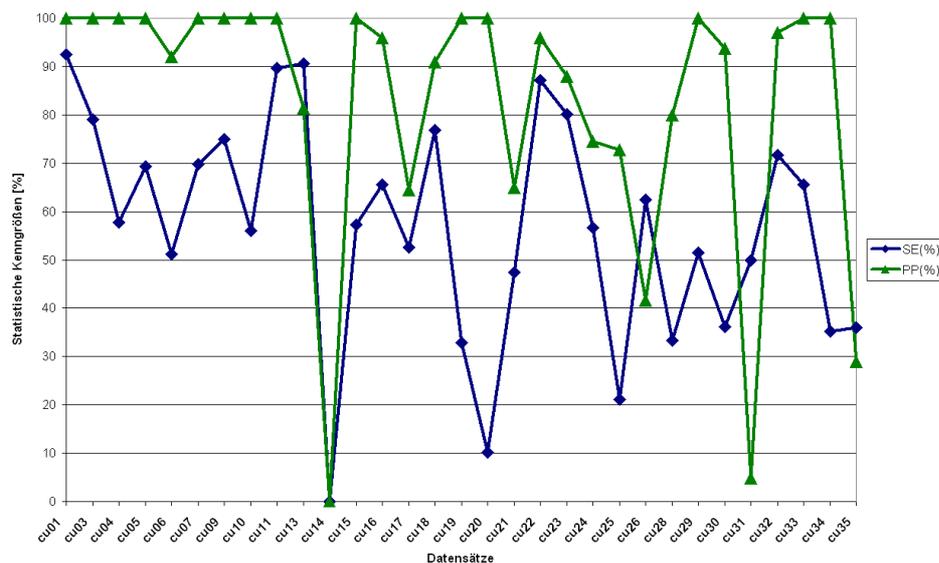
Tabelle 9.1 stellt die durch die Kombination von vier Parametern aus zwei Parameterklassen (SAV und WAL) erzielten Ergebnisse auf Sekundenbasis für die Datensätze der CUDB dar, die detailliert in Tabelle E.17 zu finden sind. In den Abbildungen 9.14 und 9.15 ist eine Übersicht über das Verhalten der statistischen Kennwerte auf den verschiedenen getesteten Datensätzen der CUDB zu sehen. Es ist zu beachten, dass

**Tabelle 9.1:** Statistische Auswertung der Parameter „Summe der Absolutwerte“ und „WAL“ aus den Wavelet-Skalen drei und vier

CUDB	TN	FN	TP	FP	SE [%]	SP [%]	PP [%]	NP [%]	AC [%]
Summe	11883	1451	2023	346	58,2	97,2	85,4	89,1	88,6

durch die geringe Anzahl vorhandener VT-/VF-Sekunden vor allem die Werte für SE und PP sehr stark schwanken. Aus diesem Grund ist die Berechnung der statistischen Kenngrößen auf der Grundlage der Summe aller Segmente aussagekräftiger.

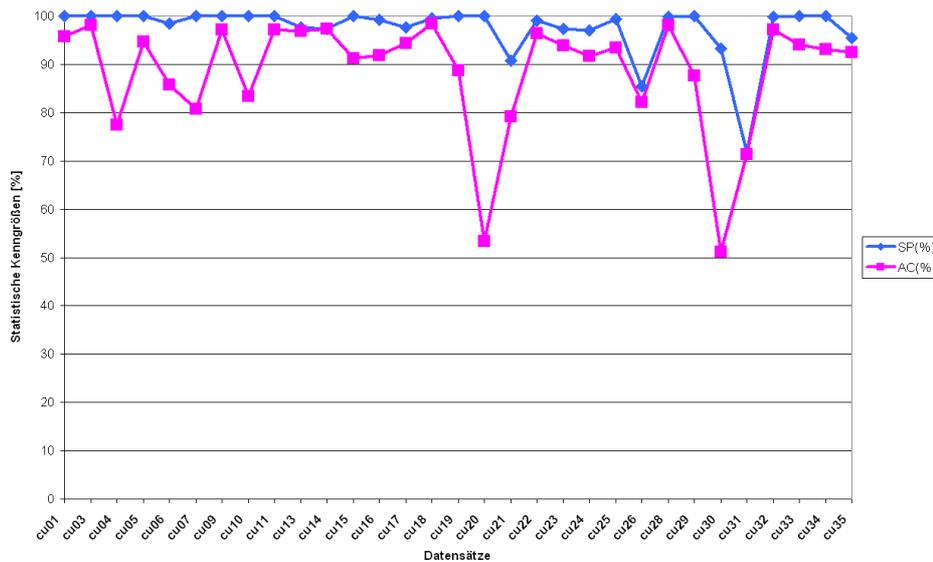
Hier und im Folgenden wird auf die Darstellung der negativen Prädiktivität (NP) verzichtet, da diese wegen des starken Ungleichgewichts zwischen der Anzahl von NSR- und VT-/VF-Segmenten der Genauigkeit (AC) sehr stark ähnelt.



**Abbildung 9.14:** Verhalten der sekundenbasierten statistischen Kennwerte SE und PP auf den getesteten Datensätzen der CUDB bei der Klassifikation mit dem ANFIS-basierten System. Es ist zu beachten, dass im Datensatz cu14 keine VT-/VF-Episoden notiert sind.

### 9.5.2 Klassifikation mit NFC

Die Tabellen 9.2 und 9.4 zeigen die mit den oben genannten Tests erzielten Ergebnisse für alle Datensätze der CUDB mit den bekannten Ausnahmen cu02 und cu12. In beiden Fällen ist deutlich die Überlegenheit der auf Basis der Wavelettransformierten extrahierten Parameter im Vergleich zu den direkt aus dem EKG extrahierten zu sehen. Zwar ist die Spezifität bzw. die positive Prädiktivität für die Anwendung des EFIS am größten. Damit ist die Anzahl der falsch positiv als VT/VF deklarierten Segmente hier am geringsten. Andererseits sind die Einbußen in der Sensitivität so stark, dass der Einsatz einer anderen Konfiguration vorzuziehen ist. Dies spiegelt sich auch in der deutlich geringeren Episodensensitivität in Tabelle 9.3 wider. Durch die sequentielle



**Abbildung 9.15:** Verhalten der sekundenbasierten statistischen Kennwerte SP und AC auf den getesteten Datensätzen der CUDB bei der Klassifikation mit dem ANFIS-basierten System.

Kombination von zwei FIS (Test 3) ist außerdem eine Verbesserung der Detektionsleistung im Vergleich zu den mit dem ANFIS erzielten Klassifikationsergebnissen sowohl für die Sensitivität als auch für die positive Prädiktivität zu konstatieren.

Die in Tabelle 9.3 und 9.5 bei der Auswertung mit dem *epic*-Tool für DSE und DPP erzielten Werte sind nicht direkt mit den Werten für SE und PP aus Tabelle 9.2 und 9.4 vergleichbar. Dies liegt daran, dass DSE und DPP als Durchschnittswerte aus den durch *epic* auf jedem Datensatz berechneten Werte berechnet wird. Die Länge der einzelnen Rhythmussegmente bleibt dabei unberücksichtigt. Die Unterschiede zwischen den Werten zeigen, dass die sekundenbasierte Auswertung besser für die Beurteilung der Klassifikationsgüte des Verfahrens geeignet ist.

Interessant sind die Auswertungen mit *epic* vor allem dafür, wieviele der im Datensatz vorhandenen Episoden durch die FIS(-Kombinationen) detektiert werden konnten. Ein weiterer Punkt ist, ob die falsch positiven Detektionen im Zusammenhang mit vorhandenen VT-/VF-Episoden auftreten. In diesem Fall wären sie eher zu verkraften, da dies im späteren Einsatz nicht zu einem echten Fehlalarm führen würde. Stünde die detektierte Episode dagegen allein, so würde dies zu einem unnötigen Alarm führen. In dieser Hinsicht ergibt sich ein relativ konsistentes Bild zwischen den beiden Auswertungsverfahren, besonders bei den kürzeren Extraktionszeitfenstern. Tendenziell ist jedoch EPP höher als PP und damit die Fehlalarmquote geringer. Das deutet darauf hin, dass die Klassifikationssysteme schon vor dem Beginn der Referenznotation VT/VF detektieren oder nach Ende einer Episode noch länger diese Klassifikation beibehalten.

Eine größere Länge der Segmente für die Parameterextraktion führt bei allen durchgeführten Tests zunächst zu einer deutlichen Zunahme der Sensitivität für VT/VF. Ab ca. 4 Sekunden Länge des Extraktionsfensters sind nur noch geringfügige Änderungen der statistischen Kennwerte vorhanden. Die Abbildungen 9.16 und 9.17 zeigen dies für

**Tabelle 9.2:** Vergleich der durchgeführten Tests für die verschiedenen FIS und ihre Kombinationen mit Parametern, die auf Segmenten von vier Sekunden Länge extrahiert wurden. Die Mindestlänge von VT-/VF-Segmenten betrug acht Sekunden.

CUDB	TN	FN	TP	FP	SE[%]	SP[%]	PP[%]	NP[%]	AC[%]
Test 1	12811	1700	1870	312	52,4	97,6	85,7	88,3	88,0
Test 2	13060	2746	824	63	23,4	99,5	92,9	82,6	83,2
Test 3	12810	1385	2185	313	61,2	97,6	87,5	90,2	89,8
Test 4	12490	1981	1589	633	44,5	95,4	71,5	86,3	84,3

**Tabelle 9.3:** Vergleich der mit *epic* durchgeführten Tests für die verschiedenen FIS und ihre Kombinationen mit einer Extraktionslänge von vier und einer Mindestlänge von acht Sekunden.

	ESE [%]	EPP [%]	DSE [%]	DPP [%]
Test1	88	86	57	84
Test2	69	89	26	88
Test3	92	85	61	86
Test4	83	74	49	76

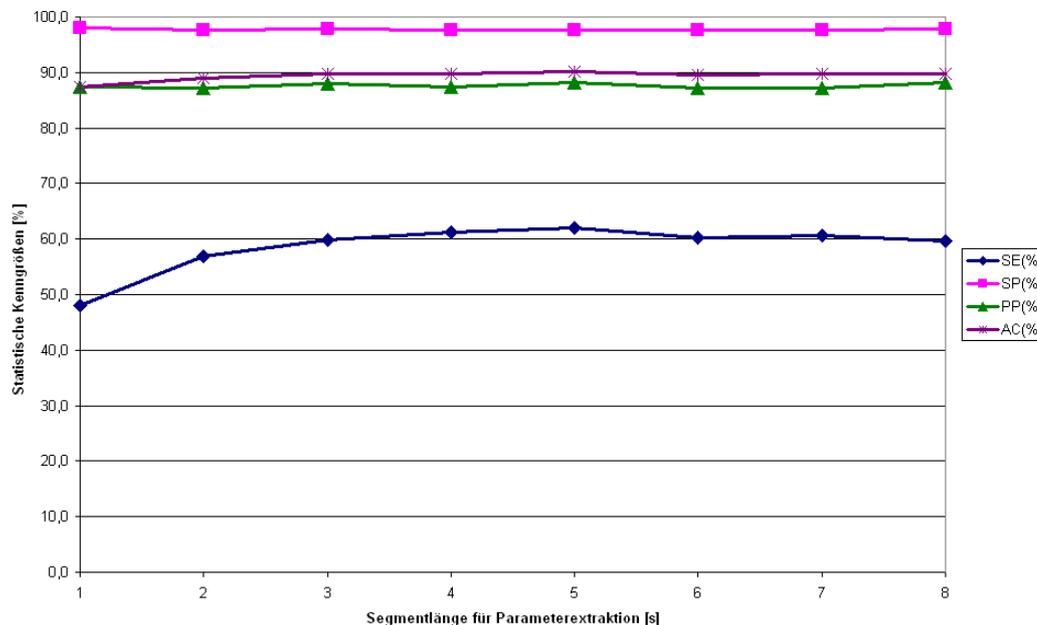
**Tabelle 9.4:** Vergleich der durchgeführten Tests für die verschiedenen FIS und ihre Kombinationen mit Parametern, die auf Segmenten von acht Sekunden Länge extrahiert wurden. Die Mindestlänge von VT-/VF-Segmenten betrug acht Sekunden.

	TN	FN	TP	FP	SE[%]	SP[%]	PP[%]	NP[%]	AC[%]
Test 1	12872	1676	1900	268	53,1	98,0	87,6	88,5	88,4
Test 2	12700	2460	1116	440	31,2	96,7	71,7	83,8	82,7
Test 3	12854	1441	2135	286	59,7	97,8	88,2	89,9	89,7
Test 4	11951	1795	1781	1189	49,8	91,0	60,0	86,9	82,2

**Tabelle 9.5:** Vergleich der mit *epic* durchgeführten Tests für die verschiedenen FIS und ihre Kombinationen mit einer Extraktions- und Mindestlänge von acht Sekunden.

	ESE [%]	EPP [%]	DSE [%]	DPP [%]
Test 1	88	91	55	89
Test 2	76	78	32	77
Test 3	88	86	61	86
Test 4	90	69	55	71

den sekundenbasierten Vergleich und die Standardevaluation mit `epic`. Für Zeitdauern größer als vier Sekunden hat die Länge des Extraktionsfensters uneinheitliche Auswirkungen: Meist erhöht sich die Sensitivität bei längeren Segmenten (Ausnahme ist Test 4) und auch die positive Prädiktivität nimmt zu (Ausnahme: Test 2).



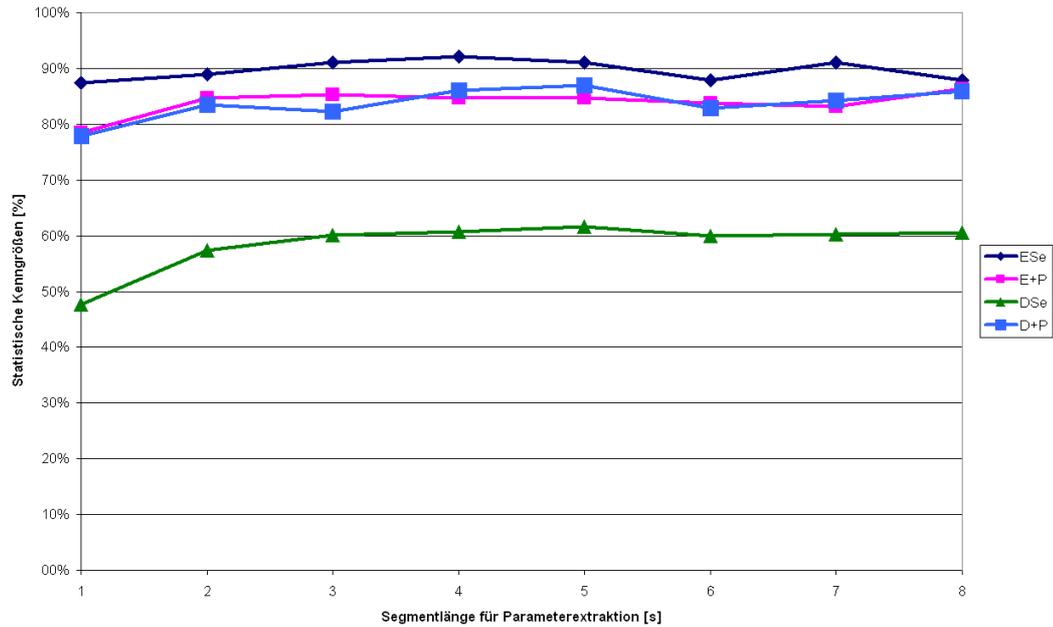
**Abbildung 9.16:** Auswirkung der Segmentlänge für die Parameterextraktion auf die statistischen Kenngrößen beim sekundenbasierten Test mit Datensätzen der CUDB.

Für die Auswertung mit `epic` spielt die Länge des Extraktionsfensters ebenfalls nur bei der Zeitdauersensitivität DSE eine merkliche Rolle. Die Schwankungen der anderen Kennwerte fallen deutlicher aus als bei den sekundenbasierten Kennwerten in Abbildung 9.16. Dies ist besonders bei ESE und EPP in ihrer Charakteristik begründet, da sich durch das kleine Kollektiv Schwankungen stärker niederschlagen.

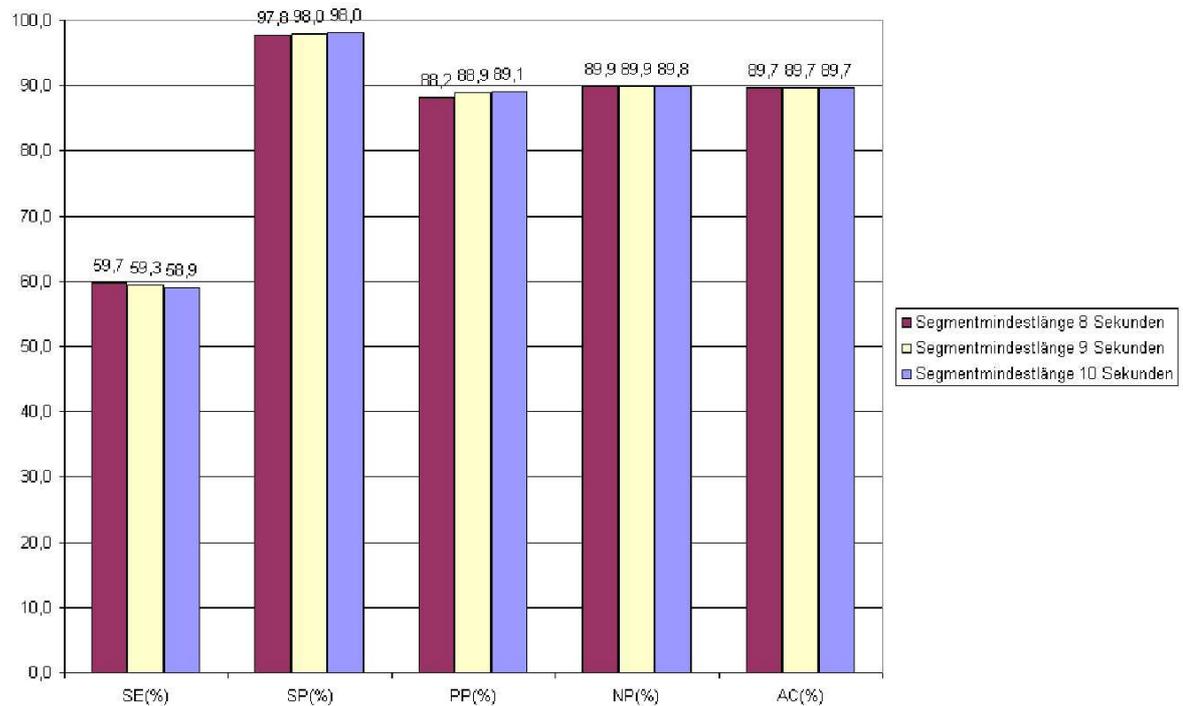
Die Mindestlänge zusammenhängender VT-/VF-Segmente hat geringe Auswirkungen, wie in Abbildung 9.18 zu sehen ist. Mit zunehmender Länge nimmt die Sensitivität etwas ab, da einige Segmente noch nach NSR umklassifiziert werden. Die anderen statistischen Kenngrößen bleiben aber im Wesentlichen unverändert.

Exemplarisch werden im Folgenden die statistischen Kennwerte für die Parameterextraktion auf einer Länge von vier Sekunden und mit einer Mindestlänge für die endgültigen VT-/VF-Segmente von acht Sekunden vorgestellt, weil für diese Kombination der beste Kompromiss zwischen Sensitivität und positiver Prädiktivität erzielt werden konnte. Um sich ein Bild über das Verhalten der waveletbasierten FIS-Kombination auf den einzelnen Datensätzen der CUDB zu machen, werden in den folgenden Abbildungen die statistischen Kennwerte über die einzelnen Datensätze hinweg aufgetragen.

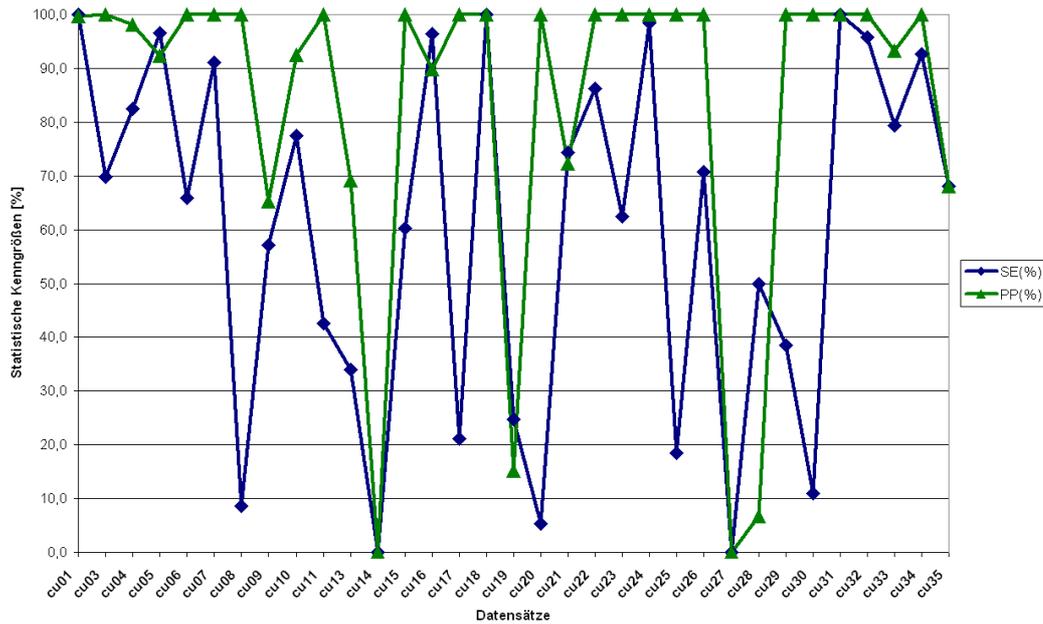
Für die Darstellung in Abbildung 9.19 ist zu beachten, dass im Datensatz `cu14` keine VT-/VF-Episode vorliegt. Dies wird vom Klassifikationsverfahren auch so erkannt (siehe Tabelle E.18), in der grafischen Excel-Darstellung jedoch auf Null gesetzt. Die Spezifität und Genauigkeit beträgt jedoch 100%, wie Abbildung 9.20 zu entnehmen ist.



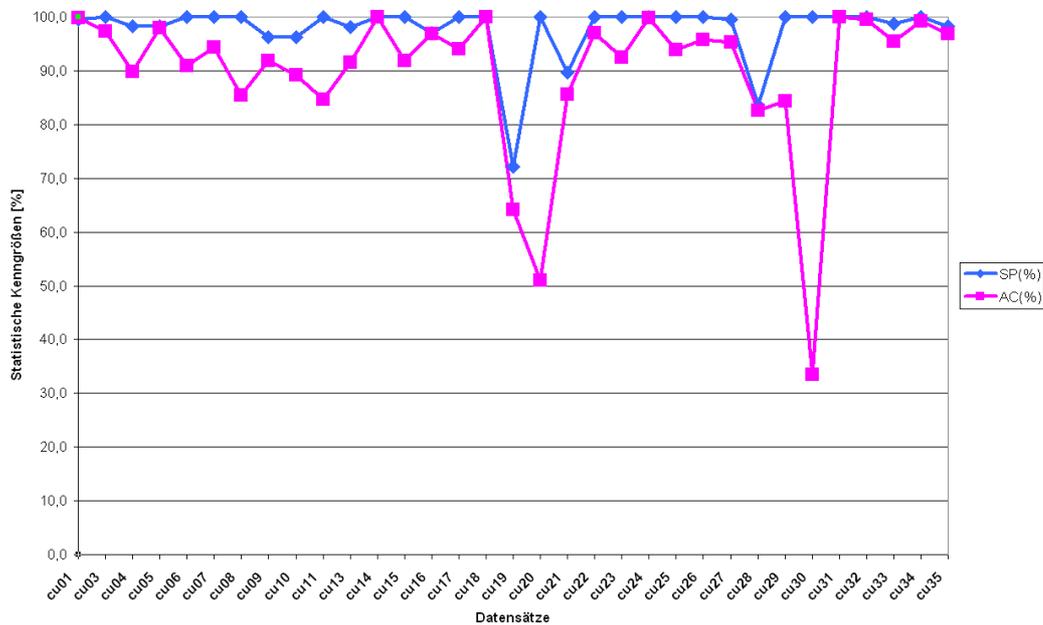
**Abbildung 9.17:** Auswirkungen der Segmentlänge für die Parameterextraktion auf die statistischen Kennwerte der epic-Evaluation.



**Abbildung 9.18:** Auswirkungen der unterschiedlichen Mindestlänge zusammenhängender VT-/VF-Segmente auf die statistischen Kenngrößen der Klassifikationsleistung.

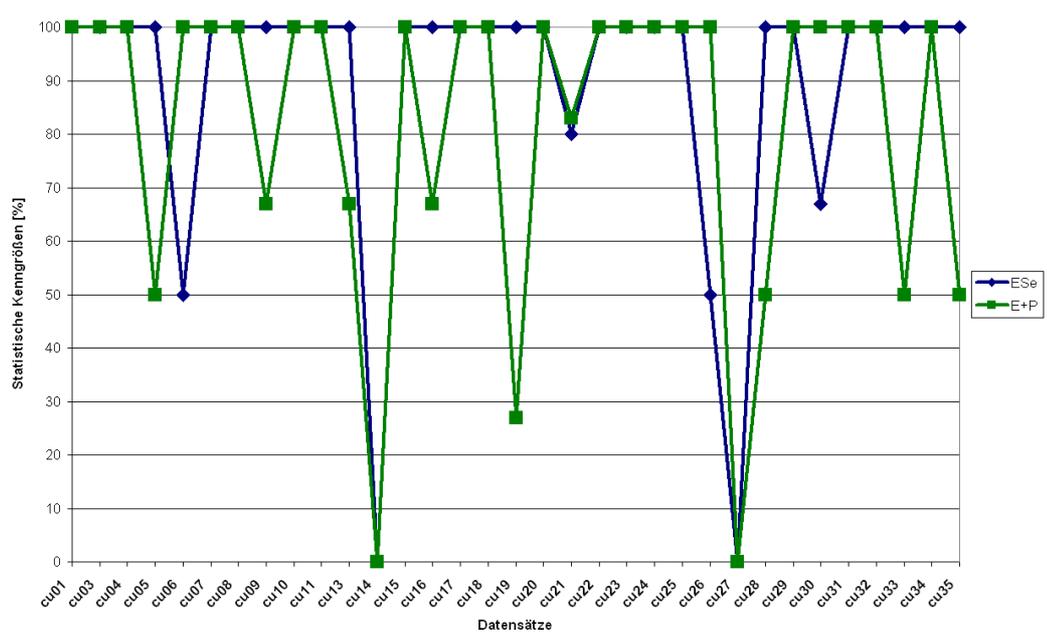


**Abbildung 9.19:** Sensitivität(SE) und positive Prädiktivität (PP) bei sekundenbasierter Auswertung auf den Datensätzen der CUDB. CropSize: vier Sekunden, Smoothing-Duration: acht Sekunden.



**Abbildung 9.20:** Spezifität (SP) und Genauigkeit (AC) bei sekundenbasierter Auswertung auf den Datensätzen der CUDB. CropSize: vier Sekunden, SmoothingDuration: acht Sekunden.

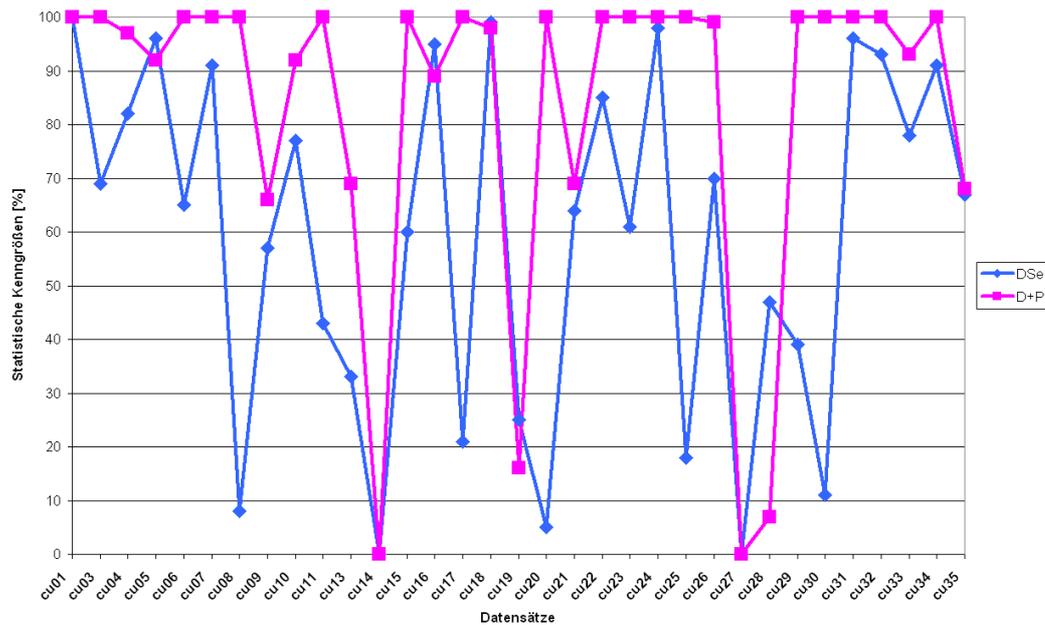
Betrachtet man in Abbildung 9.21 die unterschiedlichen auf Basis der einzelnen Datensätze berechneten Werte für die Episodensensitivität und -prädiktivität, so ist zunächst festzustellen, dass die Episodensensitivität fast immer 100% beträgt. Nur in vier Datensätzen (cu14 ist von dieser Betrachtung wie oben bereits erläutert auszunehmen) werden VT/VF-Episoden nicht erkannt. Nur in einem Fall (cu27) wird eine Episode mit etwa 20 Sekunden Dauer nicht detektiert. In nur sieben Datensätzen werden ein oder mehrere falsch positive VT-/VF-Episoden detektiert, wobei in allen Datensätzen auch echte VT-/VF-Episoden und in vielen Fällen andere hochpathologische, wenn auch nicht defibrillationspflichtige Herzrhythmen vorliegen. Insgesamt ist die Episodenprädiktivität und auch die sekundenbasierte PP mit ca. 85% bzw. 88% ausreichend hoch.



**Abbildung 9.21:** Einzelergebnisse für ESE und EPP auf den Datensätzen der CUDB für eine CropSize von vier Sekunden und eine SmoothingDuration von acht Sekunden.

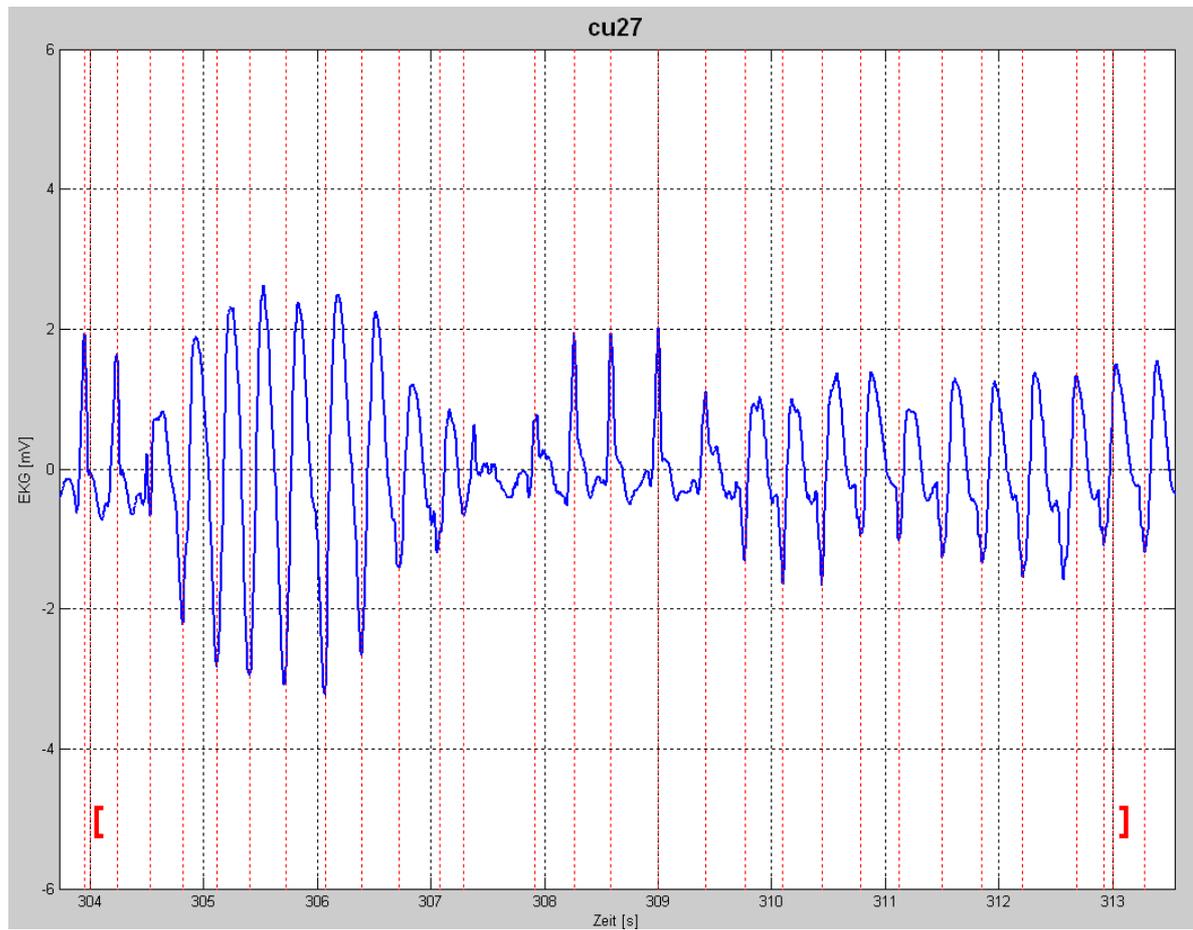
Der Verlauf von DSE und DPP über die einzelnen Datensätze in Abbildung 9.22 entspricht nahezu dem von SE und PP in Abbildung 9.19. Die Fehler, die durch die größere zeitliche Diskretisierung im Sekundenrastrer und das Ignorieren der Übergangsegmente von NSR zu VT/VF und zurück entstehen, sind also sehr gering. Umgekehrt sind damit die auf der gesamten Datenbank durch Summation der TN-/FN-/TP- und FP-Segmente ermittelten statistischen Kennwerte als valide einzustufen.

Die Ergebnisse der VT-/VF-Detektion lassen eine Implementierung in einem mobilen System zur Überwachung von entsprechend gefährdeten Patienten als realistisch erscheinen. Zwar werden in der vorliegenden Untersuchung die hohen in der Literatur zu findenden Werte nicht erreicht. Dies liegt aber im Wesentlichen in der Wahl der Datenbasis begründet, die bewusst so erfolgte, um ein möglichst robustes System zu generieren. Dies ist mit der in dieser Arbeit erstmalig erfolgten Anwendung von waveletbasierten Parametern in hohem Maße erreicht worden. Betrachtet man das vorhandene Datenmaterial der CUDB genauer, so sind die erreichten Ergebnisse umso höher einzustufen: Viele der Datensätze enthalten stark artefaktbehaftete Signale und auch in den für die



**Abbildung 9.22:** Einzelergebnisse für DSE und DPP auf den Datensätzen der CUBD für eine CropSize von vier Sekunden und eine SmoothingDuration von acht Sekunden.

Tests berücksichtigten Datensätzen erscheinen einige der Referenzannotationen immer noch sehr fragwürdig. Abbildung 9.23 auf der nächsten Seite zeigt dazu das Beispiel einer ventrikulären Tachykardie im Datensatz cu27, die in der Referenzannotation nicht vorhanden ist. Sicherlich könnten durch eine medizinisch fundierte Vorauswahl oder Re-Annotation der Datensätze die Ergebnisse deutlich verbessert werden. Andererseits sind anders als in der einschlägigen Literatur die erzielten Ergebnisse damit vollständig transparent und daher mit denen anderer Verfahren, die auf die gleiche Weise getestet werden, vergleichbar. Dies ist für die bisher vorhandenen Veröffentlichungen nicht möglich.



**Abbildung 9.23:** VT-Episode im Datensatz cu27, die vom Klassifikationssystem erkannt wurde (beachte die entsprechenden WFDB-Annotationen), in der Referenzannotation jedoch nicht vorhanden ist (CropSize acht Sekunden, SmoothingDuration zehn Sekunden).

# 10 Zusammenfassung und Ausblick

Herz-Kreislauferkrankungen sind die häufigste Todesursache und der größte Kostenfaktor im Gesundheitswesen in Deutschland. Verbesserungen ihrer Therapie oder ein durch frühzeitige Intervention verbesserter Krankheitsverlauf haben daher sehr großes Einsparpotenzial.

Der Einsatz telemedizinischer Systeme in diesem Bereich wird als Chance begriffen, die Therapie durch eine engere Kopplung zwischen Patient und Arzt zu verbessern und außerdem die Therapiekosten für die Behandlung chronisch kranker Patienten unter anderem durch kürzere Krankenhausaufenthalte zu senken. Dies wird vor allem dadurch erreicht, dass für die Datenerhebung und den Datenaustausch zwischen Patient und Arzt kein Krankenhausaufenthalt oder Arztbesuch mehr notwendig sind und damit ein erheblicher Kosten- und Zeitfaktor entfällt. Weiterhin sind eine bessere Therapiekontrolle und -führung durch den verbesserten Datenaustausch zwischen Patient und Arzt möglich. Ein weiterer Faktor ist die schnellere Einleitung von Notfallmaßnahmen beim Eintreten eines lebensbedrohlichen Zustandes. Bei einer automatisierten Alarmierung können lebensrettende Therapiemaßnahmen schneller eingeleitet, die Genesungschancen des Patienten nachhaltig verbessert und auf diese Weise die Folgekosten reduziert werden.

Voraussetzung dafür ist die Entwicklung mobiler Systeme, die in der Lage sind, den Patientenzustand selbständig zu analysieren und bei Eintreten eines relevanten Ereignisses eine Datenübertragung an ein Servicecenter oder eine ähnliche Einrichtung zu initiieren, in der dann entsprechende Maßnahmen ergriffen werden können.

Der Analyse des Elektrokardiogramms (EKG) kommt dabei eine zentrale Rolle zu, da es das wichtigste Signal zur Überwachung der menschlichen Herzaktivität ist. Aus diesem Grund existieren bereits zahlreiche mobile Systeme, die in der Lage sind, das menschliche EKG aufzunehmen und zu übertragen. Eine automatische Analyse findet dann jedoch entweder auf einer Zentralstation statt oder ist nur für sehr bestimmte Krankheitsbilder geeignet. Im ersten Fall muss eine permanente Datenübertragung gewährleistet sein, was eine Einschränkung des möglichen Überwachungsbereichs zur Folge hat. Andere telemedizinische Systeme sind auf die Interaktion mit dem Benutzer angewiesen, um Daten an die Gegenstelle übertragen zu können. Diese Systeme schöpfen die Potenziale der Telemedizin daher bei Weitem nicht aus.

Es müssen somit Verfahren entwickelt werden, die eine zuverlässige Analyse des EKGs leisten und auf mobilen Systemen implementiert werden können. Das Verfahren soll eine maximale Flexibilität aufweisen und bei verschiedenen Patienten mit einer unterschiedlichen Anzahl von EKG-Kanälen und differierenden Elektrodenkonfigurationen arbeiten können, ohne spezielle Anpassungen vornehmen zu müssen. Grundlage einer solchen Analyse ist die zuverlässige Detektion des QRS-Komplexes, für die ein leistungsfähiger Mehrkanaldetektor entwickelt werden muss. Für die Überwachung kardiologischer Risikopatienten ist weiterhin die Detektion ventrikulärer Erregungsbildungsstörungen

von besonderem Interesse. Dazu müssen in einer ersten Stufe normale und ventrikuläre ektope QRS-Komplexe differenziert werden können. Ventrikuläre tachykarde Rhythmusstörungen sind vorrangige Ursache für den plötzlichen Herztod. 70% der ca. 120000 jährlich in Deutschland Betroffenen sind bereits vorher als Risikopatienten bekannt und damit potenzielle Nutzer des angestrebten mobilen Systems. Daher kommt der Erkennung von lebensgefährlichen VT-/VF-Episoden, die eine schnelle Notfalltherapie durch die automatische Alarmierung des Patienten-Service-Centers ermöglicht, eine äußerst wichtige Rolle zu.

Diese drei eben erwähnten Punkte werden in der vorliegenden Arbeit vor dem Hintergrund der Anwendung in einem mobilen System aufgegriffen. In jedem der drei Teilthemen wurde die sehr umfangreiche Literatur aufgearbeitet und die lohnendsten Ansätze hinsichtlich Detektions- bzw. Klassifikationsgüte und erforderlichen Rechenaufwand identifiziert. Dabei trat in allen Bereichen das Problem auf, dass die beschriebenen Verfahren häufig auf proprietären Daten evaluiert wurden und die Ergebnisse dadurch nicht direkt miteinander vergleichbar sind. Darum wurde in dieser Arbeit darauf geachtet, dass die vorgenommenen Auswertungen vollständig auf öffentlich zugänglichem Datenmaterial durchgeführt wurden. An diesem Material wurden nur in begründeten Ausnahmefällen möglichst geringe Änderungen vorgenommen, beispielsweise bei der Anpassung der Referenzannotation für die Auswertung der VT-/VF-Detektion. Es wurde darauf geachtet, dass die ursprüngliche Aussage erhalten blieb und die Änderungen werden in dieser Arbeit sorgfältig beschrieben. So weit wie möglich wurden die entwickelten Algorithmen mit den Werkzeugen evaluiert, die von den einschlägigen Standards vorgeschrieben werden. Dieses Vorgehen wurde gewählt, um ein Nachvollziehen der Ergebnisse zu ermöglichen und die Vergleichbarkeit mit anderen Verfahren zu maximieren.

Aus der Vielzahl von dokumentierten Verfahren zur QRS-Detektion wurde eine Auswahl der am besten dokumentierten Verfahren getroffen, die für den mobilen Einsatz tauglich erschienen oder sich durch eine gute Detektionsleistung auszeichneten. Nach einer ersten Evaluationsphase wurden drei Verfahren mit unterschiedlichen Schwerpunkten in Bezug auf Implementierungs- und Rechenaufwand, Detektionsverzögerung und Detektionsgüte für eine Testimplementierung ausgewählt. Teilweise konnten die in der Literatur angegebenen Werte auf vergleichbaren Datenbasen nicht reproduziert werden. Am stärksten betraf dies das waveletbasierte Verfahren, das aber auf Grund seiner Vorteile für die Extraktion weiterer Parameter zur Schlag- und Rhythmusklassifikation weiter verfolgt wurde.

Durch verschiedene Modifikationen konnte die Detektionsleistung aller Verfahren deutlich erhöht werden. Weiterhin wurden alle QRS-Detektoren durch auf das jeweilige Verfahren angepasste Strategien für den Mehrkanaleinsatz erweitert. Für alle drei Verfahren wurde diese Erweiterung erstmalig durchgeführt.

Für das MOBD-basierte Verfahren wurde eine die ursprüngliche Implementierung deutlich erweiternde Entscheidungslogik für die Artefakt- und QRS-Detektion und ein bewusst einfach gehaltener Multikanaldetektor implementiert, um das Verfahren für den Einsatz im Mobilsystem möglichst schlank zu halten. Das Verfahren schneidet zwar bei der Detektionsgüte im Vergleich mit den anderen beiden Detektoren schlechter ab, benötigt aber die wenigsten Ressourcen und ist daher für den Einsatz im Mobilsystem grundsätzlich weiter attraktiv. Dies gilt insbesondere, wenn höhere Abtastraten verwendet werden, welche die auftretenden Sensitivitätsprobleme größtenteils beheben.

Das Pan/Tompkins-Verfahren wurde durch die dynamische Anpassung des Glättungsfilters der letzten Stufe für die bessere Detektion von tachykarden Schlägen modifiziert. Für die Multikanalentscheidung wurde ein auf der Glaubwürdigkeit der Detektionen der Einzelkanäle beruhendes System entwickelt, das die Detektionsleistung insbesondere im Bereich der positiven Prädiktivität deutlich verbessern konnte. Damit ist dieses Verfahren auch am wenigsten anfällig für falsch positive Detektionen in verrauschten und gestörten Signalen.

Erstmals wurde bei dem waveletbasierten QRS-Detektionsverfahren ein hybrides Klassifikationssystem mit einer unscharfen Klassifikationsstufe implementiert. Dazu wurden Studien zur Definition eines optimalen Parametersets für die Detektion durchgeführt, in denen Regelbasen für Kombinationen unterschiedlicher Parameter entwickelt wurden. Die Zugehörigkeitsfunktionen dieser Fuzzy-Inferenzsysteme wurden dann mit einem wissensbasierten Trainingsalgorithmus optimiert. In Kombination mit einer nachgeschalteten diskreten Klassifikationsstufe konnten für die Mehrkanaldetektion sehr gute Werte für die Sensitivität von über 99,8% und für die positive Prädiktivität von ca. 99,4% und mehr auf den Standard-Datenbanken erzielt werden. Auch die Sensitivität der QRS-Detektion für ventrikuläre Schläge erreicht mit deutlich über 98% und bis zu 99,6% auf den Datenbanken sehr zufriedenstellende Ergebnisse. Trotz seiner Komplexität ist auch dieser QRS-Detektor für die Implementierung auf einer mobilen Plattform geeignet.

Zwei der Detektionsverfahren wurden über ein neu entwickeltes Interface in kommerzielle Software zur Langzeit-EKG-Auswertung integriert und dort getestet. Die Möglichkeit einer konsistenten Umsetzung dieser Detektionsverfahren auf eine mobile Plattform mit Hilfe des Tools „GeneralStore“ zur automatischen Modell-Transformation mit anschließender Code-Generierung wurde exemplarisch umgesetzt. Modellrechnungen ergeben eine Betriebsdauer von deutlich mehr als 24 Stunden beim Einsatz der Verfahren auf dem Mobilsystem.

Die Forderung, für ein großes Patientenkollektiv mit einem möglichst einfachen, transparenten Verfahren eine sichere Klassifikation von QRS-Komplexen und EKG-Rhythmen zu gewährleisten stellte eine große Herausforderung im Rahmen dieser Arbeit dar. Fuzzy-Inferenz-Systeme sind gut für diese Aufgabe geeignet, weil sie auf einer linguistischen Regelbasis arbeiten und damit ihre Entscheidungsfindung transparent und ohne Probleme für den menschlichen Anwender verständlich ist. Sie bieten auch einfache Möglichkeiten, bereits vorhandenes Wissen über das Vorgehen bei der Klassifikation in die Regelbasis zu integrieren. Ein wesentliches Kriterium für die Leistungsfähigkeit von Fuzzy-Inferenz-Systemen ist die optimale Abstimmung seiner Zugehörigkeitsfunktionen auf die Klassifikationsaufgabe. Bislang verfügbare Methoden für die Optimierung von Zugehörigkeitsfunktionen haben den Nachteil, dass die Trainingsmuster in etwa gleich auf die verschiedenen Ergebnisklassen verteilt sein müssen, um mit der Minimierung des Gesamtfehlers für die Klassifikation auch das Ergebnis für jede Klasse zu optimieren. Weniger häufig auftretende Klassen werden bei diesen Methoden vernachlässigt. Die verfügbaren Kollektive weisen jedoch ein starkes Ungleichgewicht zu Ungunsten der für die Klassifikation besonders relevanten pathologischen EKG-Muster auf.

Aus diesem Grund wurde im Rahmen dieser Arbeit ein ursprünglich für die Schlafstadienklassifikation bestimmter Trainingsalgorithmus modifiziert. Dieser ist in der Lage, selten auftretende Ereignisse in der Klassifikation höher zu gewichten, für den Ein-

satz in der EKG-Klassifikation. Aufbauend auf den damit gewonnenen Erfahrungen wurden zwei neue Methoden für die Optimierung von Fuzzy-Zugehörigkeitsfunktionen entwickelt. Alle drei Verfahren arbeiten zuverlässiger für die gegebenen Klassifikationsaufgaben als ein zum Vergleich herangezogenes Neuro-Fuzzy-System, das dieselbe Topologie verwendet.

Für die Visualisierung der Parameterverteilungen für die verschiedenen Ergebnisklassen der Schlag- und Rhythmusklassifikation wurde eine Vielzahl von Tools geschaffen, die die Beurteilung der Parameter und die Bildung der Regelbasen für die Klassifikation erheblich vereinfachen. Sie stellen außerdem bereits eine Anzahl automatischer Verfahren zur Clusteranalyse bereit, die im weiteren Entwicklungsverlauf noch weiterentwickelt und ergänzt werden können. Diese Tools leisten auch notwendige Datentransformationen zwischen den in Matlab extrahierten Parametern und den unter Java auf Textdateien arbeitenden Klassifikationsverfahren.

Erstmals wurden im Rahmen dieser Arbeit Parameter, die aus der Wavelettransformation des EKG-Signals stammen, für die QRS-Klassifikation eingesetzt. Hinzu kommen Parameter, die direkt aus der QRS-Detektion bzw. aus dem EKG auf sehr einfache Weise gewonnen werden können. Bei diesen waren erhebliche Anstrengungen erforderlich, um eine Extraktion mit möglichst geringer Variation auch bei schlechteren Signalverhältnissen zu gewährleisten. Trotzdem gestaltet sich eine zuverlässige Klassifikation sehr schwierig wie erste Ergebnisse auf der MITDB belegen. Hierbei tritt besonders das Phänomen auf, dass das Trainingsset nicht ausreichend repräsentativ für die große auftretende Varianz von möglichen Parameterwerten ist. Auf dem Trainingsset wurden akzeptable Werte von 92,5% für die Sensitivität und 94,7% für die positive Prädikktivität bei ventrikulären Schlägen erzielt. Diese Werte konnten bei der anschließenden Validierung jedoch nicht bestätigt werden. Zwar ist die Sensitivität mit 93,0% relativ hoch, doch die Anzahl der falsch positiven Detektionen von ventrikulären Schlägen lässt noch keinen realen Einsatz zu. Im Vergleich zu anderen in der Literatur beschriebenen Verfahren, die mit einem globalen Klassifikationssystem arbeiten, also keine spezielle Anpassung an die einzelnen Datensätze vornehmen, konnten vergleichbare, in Teilbereichen auch deutlich bessere Ergebnisse erzielt werden. Die Komplexität des Systems ist jedoch deutlich geringer und dieses somit gut für den mobilen Einsatz geeignet. Für den realen Einsatz sind noch intensive Arbeiten notwendig, um den hohen Anforderungen, die zu Beginn der Systementwicklung hinsichtlich der Universalität des Verfahrens gestellt wurden, genügen zu können. Die bisher erreichten Ergebnisse bieten dafür jedoch eine gute Grundlage.

Wie bei der QRS-Klassifikation wurde auch für die Detektion von VT-/VF-Episoden eine Vielzahl von Parametern für die Klassifikation evaluiert. Verschiedene Fuzzy-Inferenz-Systeme wurden implementiert und auf Datensätzen getestet, die von Standards vorgeschrieben sind. Für ein bestimmtes Netz von Fuzzy-Inferenz-Systemen, das auf der Reklassifikation von als unsicher eingestuften Parametervektoren beruht, wurden die Auswirkungen verschiedener Parameter für die Merkmalsextraktion untersucht. Im Vergleich zu den in der Literatur beschriebenen Verfahren wurden in der vorliegenden Arbeit sehr hohe Anforderungen an das Klassifikationssystem gestellt, was vor allem durch die vorgegebenen Datenquellen bedingt ist. Trotzdem konnten mit dem Verfahren gute Ergebnisse erzielt werden, die für seinen Einsatz in einem mobilen Monitoringsystem sprechen. Es wurden etwa 92% der relevanten Ereignisse detektiert, wobei

in 13–15% der detektierten Ereignisse eine falsch positive Detektion vorlag. Dies lässt angesichts der dieser Auswertung zugrundeliegenden Signaldaten eine akzeptable Quote von Fehlalarmen im Realeinsatz erwarten.

Das größte Potenzial für weitere Entwicklungen liegt in der Erweiterung der im Rahmen dieser Arbeit vorgestellten Kombination von spezialisierten Fuzzy-Inferenz-Systemen zu einer komplexen Netzstruktur. Momentan ist für die Parameterauswahl, die Regelerstellung und die Verknüpfung der einzelnen Fuzzy-Systeme zu einer komplexeren Topologie noch ein hohes Maß an manueller Interaktion notwendig. Für das entstehende „Fuzzy-Inferenz-Netz“ sollten flexible Trainingsverfahren entwickelt werden, die durch stetige Rückpropagierung des gesamten Klassifikationsfehlers und Fehlern für die Klassifikation der Teilklassen ein gezieltes Einzeltraining der miteinander verknüpften Fuzzy-Inferenz-Systeme ermöglichen. Dabei sollten auch Strategien für das dynamische Hinzufügen und Entfernen von Parametern in den Teilsystemen erarbeitet werden. Die in dieser Arbeit verfolgte Strategie der Nutzung „natürlicher“ Kollektive und der daraus folgende Einsatz von Gewichten für die einzelnen Parametervektoren während des Trainings sollte fortwährend berücksichtigt und systematisch ausgebaut werden.

Eine Erhöhung der Klassifikationsleistung kann durch weitere Verringerung der Streuung der extrahierten Parameter erzielt werden. Ein Beispiel ist die weitere Verbesserung und Stabilisierung der Lokalisation der Anfangs- und Endpunkte von QRS-Komplexen speziell in verrauschten Signalabschnitten. In dieser Arbeit wurde so weit wie möglich auf eine zusätzliche Signalverarbeitung verzichtet, um die Kosten der Parameterextraktion möglichst gering zu halten. Trotzdem konnten schon erhebliche Erfolge bei der Extraktion von stabilen Parametern erzielt werden. Alle zusätzlichen Maßnahmen müssen daher auf einen bestmöglichen Kompromiss zwischen Aufwand und Nutzen überprüft werden, um die angestrebte Anwendung in einem mobilen Überwachungssystem nicht zu gefährden. In diesem Zusammenhang sollten auch Möglichkeiten der Merkmalstransformation (z.B. durch Hauptkomponentenanalyse) systematisch untersucht werden.

Die praktische Umsetzung der vorgestellten Detektions- und Klassifikationsmodule in einem mobilen System ist ein weiterer Schritt, für den in dieser Arbeit die ersten Grundlagen gelegt wurden. In einer weiteren Arbeit wurde mit der Entwicklung einer solchen mobilen Plattform begonnen, auf der erste Teilmodule im Rahmen dieser Arbeit bereits teilautomatisiert implementiert wurden. Hier sind noch detaillierte Arbeiten notwendig, die vor allem auf die Optimierung des automatisch aus dem UML-Modell generierten Codes zielen, ohne dass darunter die Konsistenz der Verfahren im Vergleich zu den für den stationären Einsatz entwickelten Implementierungen leidet. Ein erster erfolgreicher Schritt in diese Richtung wurde in dieser Arbeit getan.



# A Medizinische Statistik und Standards

Dieser Abschnitt gibt einen Überblick über Kenngrößen der medizinischen Statistik, die wichtig für die Beurteilung von EKG-Klassifikationssystemen sind. Des Weiteren werden die wichtigsten internationalen Standards und Guidelines in diesem Bereich angesprochen, die teilweise die Grundlage für die vorliegende Arbeit bildeten.

## A.1 Statistik in der Medizin

Bei der Bewertung diagnostischer Methoden in der Medizin können verschiedene Größen zur Validierung von Ergebnissen berechnet werden. Dies ist notwendig, da bei der Zuordnung von Symptomen, extrahierten Parametern oder anderen Größen, die für die Diagnose verwendet werden, zu unterschiedlichen Ergebnisgruppen verschiedene Arten von Fehlern auftreten können. Diese können mit den im Folgenden beschriebenen Kenngrößen quantifiziert werden und erlauben den Vergleich unterschiedlicher Methoden hinsichtlich ihrer Klassifikationsgüte.

Zunächst können Größen definiert werden, die die Richtigkeit der Zuordnung von Ereignissen zu bestimmten Ergebnisklassen beschreiben. Seien  $x, y$  Ereignisse, die es in die Ergebnisklassen  $X, Y$  zu klassifizieren gilt, und sei die richtige (Referenz-)Zuordnung folgendermaßen:

$$x \overset{!}{\in} X \quad y \overset{!}{\in} Y$$

Dann werden für die Zuordnung der Ereignisse zu den Klassen folgende Bezeichnungen verwendet:

- **TP(X), TP(Y)** (true positive): Das Ereignis  $x$  wird korrekt der Klasse  $X$  zugeordnet, das Ereignis  $y$  korrekt der Klasse  $Y$ .
- **TN(X), TN(Y)** (true negative): Das Ereignis  $y$  wird korrekt *nicht* der Klasse  $X$  zugeordnet, das Ereignis  $x$  korrekt *nicht* der Klasse  $Y$ .
- **FP(X), FP(Y)** (false positive): Das Ereignis  $y$  wird fälschlicherweise der Klasse  $X$  zugeordnet, das Ereignis  $x$  fälschlicherweise der Klasse  $Y$ . Dies wird auch Fehler 1. Art genannt.
- **FN(X), FN(Y)** (false negative): Das Ereignis  $x$  wird fälschlicherweise *nicht* der Klasse  $X$  zugeordnet, das Ereignis  $y$  wird fälschlicherweise nicht der Klasse  $Y$  zugeordnet. Dies wird auch als Fehler 2. Art bezeichnet.

Für den Fall, dass es nur zwei Ergebnisklassen gibt, gilt immer:

$$\begin{aligned} TP(X) &= TN(Y) & TP(Y) &= TN(X) \\ FP(X) &= FN(Y) & FP(Y) &= FN(X) \end{aligned}$$

Beim Vergleich des Ergebnisses eines Verfahrens mit einer Referenz lassen sich die oben aufgeführten Größen als eine Matrix darstellen. Tabelle A.1 zeigt ein Beispiel für drei Ergebnisklassen  $X$ ,  $Y$  und  $Z$ . Die Klassifizierung, die vom Verfahren vorgenommen wurde (im Weiteren auch Testergebnis genannt), wird mit den kleinen Buchstaben  $x$ ,  $y$  und  $z$  versehen, die Referenzklassifizierung dagegen mit großen Buchstaben.

**Tabelle A.1:** Ergebnismatrix für eine Klassifikation mit drei Ergebnisklassen.

Test \ Referenz	$X$	$Y$	$Z$
$x$	$xX$	$xY$	$xZ$
$y$	$yX$	$yY$	$yZ$
$z$	$zX$	$zY$	$zZ$

Die Werte für  $TP$ ,  $FP$  und  $FN$  der einzelnen Ergebnisklassen werden dann auf folgende Art und Weise berechnet:

$$\begin{aligned} TP(X) &= xX & TP(Y) &= yY & TP(Z) &= zZ \\ FP(X) &= xY + xZ & FP(Y) &= yX + yZ & FP(Z) &= zX + zY \\ FN(X) &= yX + zX & FN(Y) &= xY + zY & FN(Z) &= xZ + yZ \end{aligned} \quad (\text{A.1})$$

Aus den Einträgen der Matrix A.1 lassen sich folgende Qualitätskriterien (medizinischer) Verfahren berechnen, die meist in Prozent angegeben werden.

- **SE(X):** Die *Sensitivität* (engl. *sensitivity*)

$$SE(X) = \frac{TP(X)}{TP(X) + FN(X)} \quad (\text{A.2})$$

gibt an, wieviele der Ereignisse der Klasse  $X$  tatsächlich vom betrachteten Verfahren erkannt werden.

- **PP(X):** Mit der positiven Prädiktivität (engl. *positive predictivity*)

$$PP(X) = \frac{TP(X)}{TP(X) + FP(X)} \quad (\text{A.3})$$

wird ermittelt, wie hoch die Wahrscheinlichkeit ist, dass ein  $X$  zugeordnetes Ereignis tatsächlich dieser Klasse angehört. Die positive Prädiktivität  $PP(X)$  ist also indirekt ein Maß für die „Fehlalarmquote“  $FA(X)$  eines Verfahrens für die Klasse  $X$ , die durch  $FA(X) = 1 - PP(X)$  gegeben ist.

- **SP(X)**: Die *Spezifität* (engl. *specificity*)

$$SP(X) = \frac{TN(X)}{TN(X) + FP(X)} \quad (\text{A.4})$$

gibt die Wahrscheinlichkeit für das Verfahren an, dass es ein Ereignis *nicht* der Klasse  $X$  zuordnet, wenn es dieser nicht angehört.

- **NP(X)**: Die negative Prädiktivität (engl. *negative predictivity*)

$$NP(X) = \frac{TN(X)}{TN(X) + FN(X)} \quad (\text{A.5})$$

dagegen gibt an, wie hoch die Wahrscheinlichkeit ist, dass ein Ereignis *nicht* der Klasse  $X$  angehört, wenn das Verfahren dieses nicht dieser Klasse zuordnet.

- **AC**: Die Genauigkeit (engl. *accuracy*)

$$AC = \frac{TP + TN}{TP + TN + FP + FN} \quad (\text{A.6})$$

gibt Aufschluss darüber, wieviele der Ergebnisse richtig sind. Die Genauigkeit wird für alle Ergebnisklassen berechnet, daher ist eine gesonderte Auszeichnung der Ergebnisklasse nicht möglich.

Abhängig von der Zusammenstellung des Kollektivs können die Werte für die positive und negative Prädiktivität schwanken, je nachdem wie häufig die einzelnen Ergebnisklassen auftreten, während die Werte für Sensitivität und Spezifität unabhängig davon sind. Gibt es ein starkes Ungleichgewicht zwischen den Ergebnisklassen, so verschlechtert sich die positive Prädiktivität für die weniger häufig auftretende Klasse(n).

Im Rahmen dieser Arbeit interessiert u.a. die Güte von QRS-Detektionsverfahren, also die Unterscheidung zwischen den Ereignissen *QRS-Komplex* und *kein QRS-Komplex*. In diesem Fall kann es in den meisten Fällen keine Einträge für  $TN$ -Ereignisse geben, da das Ereignis *kein QRS-Komplex* naheliegenderweise in den Referenzdaten nicht annotiert wird. Es ist also nicht möglich, einen Wert für die Spezifität zu berechnen. In diesem Fall, der auch von den einschlägigen Standards (siehe Kapitel A.2) angenommen wird, werden für die Verfahren nur die Werte für  $SE$  und  $PP$  bestimmt.

## A.2 Aktuelle Standards für EKG-Geräte mit Auswertungsfunktion

Es gibt mehrere internationale und nationale Normen, die sich mit EKG-Geräten beschäftigen. Neben den allgemeinen Anforderungen zur technischen Sicherheit medizinischer Geräte, die z.B. in [en696] und deren Subnormen beschrieben werden, werden hier noch besondere Anforderungen an die Eingangsstufen der EKG-Geräte bezüglich Defibrillationsfestigkeit, Signalgüte etc. gestellt. Auch für die Speicherung und Wiedergabe der aufgenommenen Daten werden Anforderungen formuliert. Der für diese Arbeit

relevante Teil der Standards beschreibt die Vorgehensweise zum Test der Analyseverfahren für den Fall, dass das Gerät eine automatische Interpretation des EKGs vornimmt und nicht nur als Aufnahme- und Wiedergabemedium dient. Standards mit detaillierten diesbezüglichen Aussagen sind:

- DIN EN60601-2-47 [en602]
- DIN EN60601-2-51 [en604]
- ANSI/AAMI EC38 [ans]
- ANSI/AAMI EC57 [ans98]

Die Norm EN60601-2-47 und die ANSI/AAMI-Standards schreiben einen Teil der in Anhang B.3 vorgestellten Datenbanken zur Evaluierung der Auswertelgorithmen des ambulanten EKG-Aufzeichnungssystems vor. Für die Schlagklassifikation sollen die Konfusionsmatrizen an Hand der MITDB, der AHDB und der EDB erstellt werden. Für die Auswertung bezüglich der Detektion von VT-/VF-Ereignissen soll nach diesen Standards die CUDB herangezogen werden. Im Rahmen dieser Arbeit wurden die durch die Standards vorgeschriebenen Evaluationstools (siehe Anhang B.2.2) verwendet. Die Standards formulieren jedoch keinerlei Mindestanforderungen bezüglich der Detektionsgüte, so dass in diesem Bereich v.a. der Vergleich mit anderen am Markt befindlichen Lösungen notwendig ist. Allerdings ist es in vielen Fällen sehr schwierig, genau nachzuprüfen, inwieweit wirklich standardkonform getestet wurde, da es Möglichkeiten gibt, Teile der Datenbanken (z.B. die Datensätze mit durch einen Herzschrittmacher induzierten Schlägen) von der Analyse auszuschließen. In den wenigsten Fällen wird dies jedoch detailliert aufgeschlüsselt. Bei der Schlagklassifikation unterscheiden diese drei Normen fünf verschiedene Klassen für QRS-Komplexe:

- Normalschläge (N): Alle vom Sinusknoten ausgehenden Schläge, darunter auch Schenkelblockbilder
- Supraventrikuläre ektope Schläge (S): Atriale oder nodale vorzeitige Schläge oder Ersatzsystemen, sowie fehlgeleitete atriale Extrasystolen
- Ventrikuläre ektopische Schläge (V): Vorzeitige ventrikuläre Schläge, R-on-T-Phänomene oder eine ventrikuläre Ersatzsysteme
- Fusionsschläge (F): Fusion eines normalen und eines ventrikulären Schlags
- Schrittmacherinduzierte Schläge (Q): Schläge infolge der Stimulation mit einem Schrittmacher, eine Fusion von schrittmacherinduziertem und normalem Schlag oder ein nicht klassifizierbarer Schlag

Die Norm EN60601-2-51 beinhaltet Anforderungen für die „Leistungsmerkmale von aufzeichnenden und interpretierenden Einkanal- und Mehrkanal-Elektrokardiographen“. Die Norm nimmt Langzeit-EKG-Systeme („Holter-Elektrokardiographen“) und Patientenüberwachungssysteme ausdrücklich aus dem Festlegungsbereich der Norm heraus, daher wurden die darin formulierten Anforderungen und die empfohlene Datenbasis zur Analyse der Klassifikationsalgorithmen im Rahmen dieser Arbeit nicht weiter beachtet.

## A.3 Medizinische Guidelines

Eine weitere Möglichkeit, Informationen über die Qualitätsansprüche an automatisch analysierende EKG-Systeme zu bekommen, sind medizinische Guidelines oder Statements. Diese werden durch (meist von Medizinern besetzten) Arbeitsgruppen („Task Forces“) erarbeitet und z.B. durch die American Heart Association (AHA) oder die American College of Cardiology Foundation (ACC) veröffentlicht. Für den Bereich des mobilen, dauerhaften Monitorings finden sich dort allerdings nur Veröffentlichungen, die unter medizinischen Standpunkten erläutern, wann eine Überwachung mit solchen Geräten sinnvoll ist. Weiterhin wird auf Grundlage verschiedener Untersuchungen empfohlen, automatisch erstellte EKG-Klassifikationen nur als vorläufig zu betrachten und die endgültige Beurteilung in jedem Fall einem medizinischen Experten zu überlassen.

Im Bereich der Elektrokardiographie und des ambulanten Monitorings existieren vor allem Guidelines, die das beste medizinische Vorgehen bei der Diagnostik und Therapie von Vorhofflimmern ([FRA<sup>+</sup>01]) oder der Implantierung von Herzschrittmachern und Kardioverttern/Defibrillatoren (ICDs) ([GAE<sup>+</sup>02]) beschreiben. [KBK<sup>+</sup>01] legt Anforderungen für die klinische Beurteilung von Elektrokardiogrammen (sowohl klinische 12-Kanal-Aufnahmen als auch Holter-EKGs) fest. Hier wird auch Bezug genommen auf zwei Studien, die die Qualität von automatischen Auswertesystemen im Vergleich zu erfahrenen menschlichen Befundern untersucht haben. Bei [Jos91] kann auf Grund des Alters nicht mehr davon ausgegangen werden, dass diese Untersuchung den Stand der Technik widerspiegelt. Aktueller ist [SKO99]: Hier wurde festgestellt, dass insbesondere bei der Diagnostik von Schenkelblöcken und bei der Analyse des QT-Intervalls die automatische Analyse deutlich unterlegen war. Wertvolle Anreize in Bezug auf die Zielstellung dieser Arbeit liefern diese Quellen jedoch nicht.

Im Bereich der VT-/VF-Detektion gibt es mehrere Guidelines und Statements der AHA aus dem Bereich der Automatischen Externen Defibrillatoren und Public Access Defibrillation. Der sog. Kerber-Report [KBB<sup>+</sup>97] macht auch Angaben darüber, welche Sensitivitäten, Spezifitäten und Genauigkeiten für die Beurteilung unterschiedlicher (nicht-)defibrillationspflichtiger Rhythmen mindestens erreicht werden sollten. Weiterhin werde darin Forderungen aufgestellt, auf wievielen Datensegmenten, die die unterschiedlichen Rhythmusklassen enthalten, dieser Nachweis erbracht werden soll. Beispielsweise wird für mindestens 200 Segmente mit einer groben VF eine Sensitivität von mehr als 90% oder für 100 NSR-Segmente eine Spezifität von mehr als 99% gefordert. Es werden allerdings keine verbindlichen Datenquellen genannt, die in diese Untersuchung in jedem Fall eingebunden werden sollten. Auch über die Länge der zu betrachtenden Segmente werden keine Angaben gemacht, sie soll nur ausreichend sein, um eine Diagnose zu stellen. Die Arbeitsgruppe fordert den Aufbau einer verbindlichen Datenbasis für diesen Zweck. Dies ist allerdings bisher noch nicht geschehen.



# B EKG-Datenbanken und Software

## B.1 Die Online-Ressource PhysioNet

PhysioNet [Phy05c] ist Teil der *Research Resource for Complex Physiologic Signals*, eines Gemeinschaftsprojekts des Boston's Beth Israel Deaconess Medical Center/Harvard Medical School, der Boston University, der McGill University und des Massachusetts Institute of Technology (MIT) unter der Federführung des National Center for Research Resources des National Institutes of Health. PhysioNet soll als Forum für die Verbreitung und den Austausch von physiologischen Datensätzen und von Open-Source-Software für deren Analyse dienen. Auf der Webseite des Projekts werden auch zahlreiche Tutorials und andere Hilfen angeboten, um den Umgang mit den zur Verfügung gestellten Ressourcen zu erleichtern.

## B.2 Das WFDB-Datenformat

In diesem Abschnitt wird das bei PhysioNet verwendete WFDB-Datenformat (WFDB steht für *Waveform Database*) mit seinen wesentlichen Eigenschaften erläutert. Auch die bei Physionet zur Verfügung gestellte Software zur Verarbeitung von EKG-Daten und zur standardkonformen Aufbereitung von selbst erstellten Ergebnissen wird kurz vorgestellt.

### B.2.1 Aufbau eines WFDB-Datensatzes

Zu einem vollständigen WFDB-Datensatz gehören folgende drei Dateien, die im Normalfall denselben Namen tragen und durch ihre Dateinamenerweiterungen unterschieden werden können:

1. **Headerdatei:** In ihr stehen die Meta-Informationen des Datensatzes. Dazu zählen Informationen wie die Namen und Anzahl der verwendeten Ableitungen, Format und Zahl der aufgenommenen Samples, die Samplingrate, die Auflösung und der Offset des AD-Wandlers, Checksummen der EKG-Daten, Medikation des Patienten etc. Meist wird `.hea` als Dateiendung verwendet.
2. **Datendatei:** In dieser Datei werden die eigentlichen EKG-Daten in einem binären Format abgespeichert. Häufig wird dabei das sog. 212-Format verwendet. Dabei werden zwei vorzeichenbehaftete 12bit-Werte des EKG in drei Byte abgespeichert. Die Datendateien werden normalerweise mit `.dat` erweitert.
3. **Annotationsdatei:** Diese Datei enthält die Annotationen (im Deutschen auch oft *Notationen*) zum Datensatz, also die Informationen, wo im Datensatz QRS-Komplexe, Rhythmussegmente etc. auftreten und welcher Art sie sind. Auch diese

Informationen werden binär gespeichert. Jede Einzelnotation ist in verschiedene Felder unterteilt, die folgende Bedeutung haben:

- **time**: Zeitliche Lokalisation der Annotation. Sie wird über den Sampleindex angegeben und kann mit Hilfe der Abtastfrequenz in eine echte Zeitangabe umgewandelt werden.
- **anntyp**: Klassifikationscode nach der WFDB-Konvention (siehe B.2.3 in diesem Anhang).
- **subtyp**: Numerischer Wert, der angibt, welche Signale von Rauschen oder Artefakten betroffen sind.
- **chan**: Numerischer Wert, der angibt, auf welchen Kanal sich die Annotation bezieht, falls sie nicht für alle Signale gilt.
- **num**: Numerischer Wert zur freien Verwendung.
- **aux**: Textfeld zur Eingabe von ergänzenden Kommentaren

Die Referenzannotationen sind auf Windows-Systemen meist in einer Datei mit der Endung `.atr` (für „*annotation truth*“) gespeichert. Durch die Verwendung unterschiedlicher Namenserverweiterungen für die Annotationsdateien können verschiedene Klassifikationen mit denselben EKG-Daten assoziiert werden. Auf diese Weise ist auch der Vergleich einer durch ein Verfahren erstellten Klassifikation mit der Referenz möglich. Im Rahmen dieser Arbeit wurde dazu für die selbst erstellten Annotationsdateien die Endung `.tst` verwendet.

## B.2.2 WFDB-Softwarebibliothek

PhysioTools [Phy05d] stellt eine Vielzahl von Funktionen und Programmen für die Verarbeitung von EKG-Datensätzen im WFDB-Format in Source-Form zur Verfügung. Der *WFDB Applications Guide* [Moo05a] und der *WFDB Programmer's Guide* [Moo05b] geben detailliert über die Software Auskunft, so dass an dieser Stelle nur die wesentlichen Punkte vorgestellt werden sollen.

Die WFDB-Bibliothek ist komplett in ANSI-C geschrieben und kann auf diese Weise einfach auf unterschiedliche Plattformen portiert werden. Für die verbreitetsten Betriebssysteme können unter [Phy05d] auch compilierte Binaries heruntergeladen werden. Im Rahmen dieser Arbeit wurde die Version 10.3.6 verwendet. Neben Funktionen und Programmen zum Datenmanagement wie Auslesen, Ändern und Speichern der verschiedenen Dateitypen sind auch verschiedene Signalverarbeitungsverfahren bis hin zu einem einfachen QRS-Detektor nach [EZ79] verfügbar. Die Applikationen sind fertige Programme, die nach dem Compilieren direkt von der Kommandozeile aufgerufen werden können. Die im Rahmen dieser Arbeit verwendeten Programme `bx`, `rx`, `mx` und `epic` zur standardkonformen Evaluation eigener Klassifikationsverfahren gehören zu dieser Kategorie. Die anderen Bibliotheksfunktionen stellen dagegen eine Schnittstelle dar, die den Umgang mit WFDB-Datensätzen und das Entwickeln eigener Software unterstützen soll.

Um EKG-Daten visualisieren und bearbeiten zu können, gibt es verschiedene Realisierungen auf Grundlage dieser Bibliothek, die ebenfalls auf den PhysioNet-Seiten zu finden sind.

Neben den C-Sourcen gibt es auch für andere Programmiersprachen Teilimplementierungen der Softwarebibliothek. Dabei sind besonders die Matlab-Routinen für das Einlesen von Datensätzen im WFDB-Format zu nennen, die die Grundlage für die im Rahmen dieser Arbeiten entwickelten Routinen zur Verarbeitung von WFDB-Daten bildeten.

### B.2.3 Annotationen nach WFDB-Konvention

Bei den Datensätzen von [Phy05c] werden Annotationen zur Bezeichnung der verschiedenen Schlagklassen nach Tabelle B.1 verwendet.

**Tabelle B.1:** Übersicht über die WFDB-Annotationscodes für QRS-Komplexe (aus [Moo05b])

<b>Schlagannotationen</b>	
<i>Code</i>	<i>Beschreibung</i>
N	Normalschlag
L	Linksbündelblock
R	Rechtsbündelblock
B	Unspezifizierter Schenkelblock
A	Atriale Extrasystole
a	Atriale Extrasystole mit aberrater Leitung
J	Nodale (junktionale) Extrasystole
S	Supraventrikuläre Extrasystole
V	Ventrikuläre Extrasystole
r	Ventrikuläre Extrasystole mit R-on-T-Systematik
F	Fusion von ventrikulärem und normalem Schlag
e	Atriale Ersatzsystole
j	Nodale (junktionale) Ersatzsystole
n	Supraventrikuläre Ersatzsystole
E	Ventrikuläre Ersatzsystole
/	Schrittmacherinduzierter Schlag
f	Fusion von schrittmacherinduziertem und normalem Schlag
Q	Unklassifizierbarer Schlag
?	Schlag, der während der Lernphase nicht klassifiziert wurde

Für die Kennzeichnung von Episoden, Ereignisse und Markierungen innerhalb der Messdaten stehen im WFDB-Format die Annotationen nach Tabelle B.2 zur Verfügung.

**Tabelle B.2:** Übersicht über WFDB-Annotationscodes zur Kennzeichnung von Episoden, Ereignissen, EKG-Nebenkomplexen und Messwerten [Moo05b])

<b>Weitere Annotationen</b>	
<i>Code</i>	<i>Beschreibung</i>
[	Beginn eines Segments mit ventrikulärem Flattern oder Flimmern
!	Ventrikuläre Flutterwelle
Fortsetzung auf nächster Seite	

**Tabelle B.2:** Übersicht über WFDB-Annotationscodes zur Kennzeichnung von Episoden, Ereignissen, EKG-Nebenkomplexen und Messwerten [Moo05b])

Weitere Annotationen	
Code	Beschreibung
	Ende eines Flimmersegments
x	Nicht übergeleitete P-Welle
(	Beginn einer EKG-Welle (P-/T-Welle, QRS-Komplex)
)	Ende einer EKG-Welle
p	Spitze der P-Welle
t	Spitze der T-Welle
u	Spitze der U-Welle
'	PQ-Übergang (O-Punkt)
,	J-Punkt
^	Schrittmacherspike
	Isolierter QRS-ähnlicher Artefakt
~	Wechsel der Signalqualität
+	Rhythmuswechsel (Rhythmenbeschreibung im Aux-Feld)
s	Änderung im ST-Segment
T	Änderung der T-Welle
*	Systole
D	Diastole
=	Annotation für Messwerte
"	Kommentar
@	Link zu externen Daten

## B.3 EKG-Datenbanken

Die im Rahmen dieser Arbeit vorrangig für die Entwicklung und Validierung eingesetzten EKG-Datenbanken werden in der Folge einzeln vorgestellt. Alle EKG-Datenbanken standen im WFDB-Datenformat zur Verfügung.

### B.3.1 MIT/BIH Arrhythmia Database

Die MIT/BIH Datenbank (MITDB) besteht aus insgesamt 48 Datensätzen mit einer Länge von 30 Minuten. Die Grundlage dafür bildeten 4000 Langzeit-EKG-Aufnahmen aus den Jahren 1975 bis 1979, die am Beth Israel Deaconess Medical Center in Boston (USA) aufgenommen wurden. Ca. 60% der Aufnahmen wurden während des Krankenhausaufenthaltes der Patienten, der Rest außerklinisch gewonnen. In Zusammenarbeit mit dem Massachusetts Institute of Technology wurden aus diesem Pool 23 Aufnahmen zufällig ausgewählt. Die restlichen 25 Datensätze stammen aus demselben Pool, wurden jedoch bewusst auf Grund des Vorkommens klinisch relevanter Arrhythmien ausgewählt. Die Datensätze stammen von insgesamt 47 Patienten, 22 Frauen im Alter von 23 bis 89 Jahren und von 25 Männern im Alter von 32 bis 89 Jahren.

Die Datensatznummern sind dreistellige Ziffercodes und reichen von 100–124 und

200–234 in nicht durchgängiger Nummerierung. In den meisten Datensätzen wird eine modifizierte EinthovenII-Ableitung für den ersten Kanal verwendet, bei der die Elektroden auf der Brust platziert wurden. Für den zweiten Kanal wurde meist eine modifizierte  $V_1$ -Ableitung nach Wilson verwendet, in einigen Fällen auch  $V_2$  oder  $V_5$ , in einem Fall  $V_4$ . Die gesamte Datenbank umfasst knapp 110.000 Schläge, die von mindestens zwei unabhängigen Kardiologen mit Schlagklassen und zusätzlichen Informationen wie z.B. Signalqualität, vorherrschende Rhythmen o.ä. versehen wurden. Strittigen Fällen wurde im Konsensverfahren eine endgültige Annotation zugewiesen. Die Datensätze 102, 104, 107 und 217 enthalten schrittmacherinduzierte QRS-Komplexe, wobei die für die Aufzeichnung verwendeten Rekorder nicht in der Lage waren, die Schrittmacherimpulse so aufzulösen, dass ihre genaue Lokalisierung im Signal möglich wäre. Seit der Erstveröffentlichung der Datenbank im Jahr 1980 musste bei insgesamt 18 Schlägen (Stand: August 2005) die Annotation korrigiert werden. Eine detaillierte Aufstellung über die Annotationsanzahl der verschiedenen Schlag- und Rhythmusklassen ist unter [Har05] zu finden.

Die Aufnahmen wurden mit einer Abtastrate von 360 Hz pro Kanal und einer Auflösung von 11 bit auf einer Amplitudenbandbreite von 10 mV zunächst auf Band digitalisiert. Seit 1989 war die MITDB auf CD verfügbar, seit Februar 2005 steht sie vollständig zum Download unter [Phy05a] zur Verfügung. Die durch das Überspielen der Daten von Band zu Band durch Schwankungen der Bandgeschwindigkeiten, Schlupf oder Hängen des Bandes induzierten Störungen im Subhertz-Bereich, die besonders die Untersuchungen der Herzratenvariabilität erschweren können, sind unter [Har05] detailliert aufgeführt.

### B.3.2 AHA Database for Evaluation of Ventricular Arrhythmia Detectors

Diese Datenbank (AHADB) [Ame05] wurde im Auftrag der American Heart Association (AHA) an der Washington University (St. Louis) in den späten 1970er und frühen 1980er Jahren erstellt und im Jahr 1985 endgültig veröffentlicht. Sie besteht aus 80 Datensätzen, die in zwei verschiedenen Versionen vorliegen: Die „langen“ Datensätze enthalten drei Stunden EKG-Signale, die „kurze“ Version nur deren letzten 35 Minuten. Bei beiden Versionen sind die letzten 30 Minuten des EKGs annotiert, d.h. bei den kurzen Datensätzen sind die ersten fünf Minuten nicht mit Schlagnotationen versehen. Im Rahmen dieser Arbeit wurden ausschließlich diese Datensätze verwendet. Abhängig von der Häufigkeit des Auftretens von ventrikulären Rhythmusstörungen wurden sie in acht verschiedene Gruppen á zehn Datensätzen eingeteilt. Die einzelnen Datensätze sind durch einen vierstelligen Zahlencode, der als Datensatzname verwendet wird, eindeutig identifizierbar. Die erste Stelle bezeichnet die Gruppe, die zweite Stelle ist mit einer „2“ als Kennzeichnung der kurzen Version versehen, die dritte und die vierte Stelle bezeichnen die Nummer des Datensatzes innerhalb der jeweiligen Gruppe (von 01 – 10). Tabelle B.3 zeigt die Gruppeneinteilung innerhalb dieser Datenbank.

Die Datensätze enthalten zwei Kanäle von ambulanten Langzeit-EKG-Aufnahmen, wobei nicht bekannt ist, welche Elektrodenkonfiguration bei der Aufzeichnung verwendet wurde. Die Aufnahmen wurden mit einer Abtastrate von 250 Hz und einer 12 bit-

**Tabelle B.3:** Übersicht über die vorherrschenden ventrikulären Ektopien in den einzelnen Gruppen der AHA-Datenbank

Gruppe	Datensätze	Klassifizierung
1	1201–1210	keine ventrikuläre Ektopie
2	2201–2210	isolierte unifokale vorzeitige ventrikuläre Kontraktionen (PVC)
3	3201–3210	isolierte multifokale PVC
4	4201–4210	ventrikuläre Bi- und Trigemini
5	5201–5210	R-on-T PVC
6	6201–6210	ventrikuläre Couplets
7	7201–7210	ventrikuläre Tachykardien
8	8201–8210	Kammerflattern/-flimmern

Auflösung bei einem Signalumfang von 10 mV digitalisiert.

Es existiert noch ein zweiter Satz ähnlicher Datensätze mit insgesamt 75 Aufnahmen, der ursprünglich zu Testzwecken konzipiert wurde, um eine zu starke Adaption der Verfahren an die ersten 80 Datensätze zu vermeiden. Dieser Teil ist erst seit relativ kurzer Zeit frei erhältlich und stand im Rahmen dieser Arbeit nicht zur Verfügung.

### B.3.3 European ST-T Database

Die European ST-T Database (EDB) [TDE<sup>+</sup>92] wurde für die Evaluierung von Algorithmen zur Analyse von ST-Strecken- und T-Wellen-Veränderungen entwickelt. Sie besteht aus 90 zweistündigen EKG-Datensätzen mit zwei Kanälen, die von 79 verschiedenen Patienten stammen, bei denen myokardiale Ischämie diagnostiziert oder vermutet wurde. Daneben sind auch andere Ursachen für Änderungen der ST-Strecke berücksichtigt worden, bspw. Bluthochdruck oder verwendete Medikamente. Als Elektrodenkonfiguration wurde oft eine modifizierte Einthoven-Ableitung in Verbindung mit einer Brustwandableitung verwendet. Die Header-Dateien (siehe B.2.1) jedes Datensatzes enthalten neben allgemeinen Patientendaten eine Übersicht über deren Status, Medikation und technische Informationen zur Aufnahme.

Die einzelnen Kanäle wurden mit einer Abtastrate von 250 Hz und einer Auflösung von 12 bit über einen nominellen Signalbereich von 20 mV digitalisiert. Die digitalisierten Werte wurden jedoch mit Hilfe von Kalibrierungssignalen so umskaliert, dass alle Datensätze identische Werte für die Amplitudenauflösung besitzen. Jeder Datensatz wurde von zwei Kardiologen unabhängig voneinander untersucht, die Schlagnotationen erstellt und die Änderungen in der ST- und T-Morphologie markiert. Strittige Annotationen zwischen den Befundern wurden von der für die Erstellung der Datenbasis verantwortlichen Forschungsgruppe in Pisa entschieden. Insgesamt enthält die Datenbank ca. 790.000 Schläge. Über die Hälfte der Datenbank steht bei Physionet [Phy05c] zum Download bereit, die komplette Datenbank kann auf CD bezogen werden.

### B.3.4 Creighton University Ventricular Tachyarrhythmia Database

Diese Datenbank (CUDB) [Phy04] besteht aus 35 Datensätzen von etwas über acht Minuten Länge mit einem aufgezeichneten EKG-Kanal. Sie enthält Daten von Patienten mit Episoden von ventrikulären Tachykardien, Flattern und Flimmern. Die Datensätze wurden ursprünglich von Floyd M. Nolle am Creighton University Cardiac Center gesammelt. Einer der Datensätze stammt aus einer EKG-Langzeitaufnahme, die anderen wurden direkt von klinischen Patientenmonitoren aufgenommen. Sie sind mit einer Abtastrate von 250 Hz und einer 12 bit-Auflösung über einen Signalbereich von 10 mV digitalisiert worden. Da die Annotation von Signalbereichen mit schweren ventrikulären tachykarden Rhythmusstörungen im Vordergrund standen, sind alle QRS-Komplexe unabhängig von ihrer Morphologie als Normalschläge annotiert, darunter auch schrittmacherinduzierte Schläge. Für die Kennzeichnung der VT-/VF-Episoden werden zum einen die WFDB-Notationen '[' und ']' verwendet, zum anderen die WFDB-Notation '+ ' in Verbindung mit einer Kennzeichnung '(VT' oder '(VF' im `aux`-Feld der Annotation. Innerhalb dieser Episoden sind keine Einzelschläge mehr annotiert. In den Datensätzen sind mehrere Defibrillationsversuche zu sehen.

Obwohl die Annotationen in dieser Datenbank explizit als „nicht definitiv“ bezeichnet werden und eine genaue Lokalisierung von Beginn und Ende der VT-/VF-Episoden schwierig ist, werden die Datensätze als Testmaterial in mehreren Normen und Standards vorgeschrieben. Teilweise müssen die vorhandenen Annotationen jedoch so stark in Zweifel gezogen werden, dass die betreffenden Datensätze besser aus den Analysen auszuschließen sind. Ein Beispiel ist der Datensatz `cu12`.

### B.3.5 MIT Noise Stress Database

Die MIT Noise Stress Database (NSTDB) [Phy05b] entstand durch Kombination der beiden Datensätze 118 und 119 der MITDB mit verschiedenen bei Freiwilligen aufgenommenen Störsignalen wie Muskelartefakten, Elektrodenartefakten und Nullliniendrift. Die einzelnen Störsignale werden in eigenen Datensätzen zusammen mit der Datenbank zum Download angeboten. Mit dem Skript `nstdbgen` von [Phy05d] ist es möglich, andere Datensätze im WFDB-Format mit diesen Störsignalen zu kombinieren. Der Einfluss der Störsignale lässt sich über eine Angabe des gewünschten Signal-Rausch-Abstands (engl. *Signal-to-Noise-Ratio*, *SNR*) festlegen. Für die NSTDB wurden nach den ersten fünf Minuten des Datensatzes im Wechsel zwei Minuten mit den Störsignalen beaufschlagt, danach folgen wieder zwei rauschfreie Minuten. Die Namen der Datensätze der NSTDB spiegeln die bei der Erzeugung verwendeten SNRs wider, wie Tabelle B.4 verdeutlicht.

Durch die Verwendung vorhandener Datensätze bleiben die Originalannotationen auch für diejenigen Signalabschnitte verfügbar, in denen für den menschlichen Befunder keine Detektion von QRS-Komplexen mehr möglich ist.

**Tabelle B.4:** Übersicht über die Datensätze der NSTDB und die bei ihrer Erzeugung verwendeten Signal-Rausch-Abstände.

Datensatz	SNR (dB)	Datensatz	SNR (dB)
118e24	24	119e24	24
118e18	18	119e18	18
118e12	12	119e12	12
118e06	6	119e06	6
118e00	0	119e00	0
118e_6	-6	119e_6	-6

## B.4 Verteilung der Schlagklassen in der MITDB

In der folgenden Tabelle ist aufgelistet, wie oft Normalschläge und ventrikuläre ektope Schläge (PVC) in der Standard-Datenbank MITDB vertreten sind. Zusätzlich wird noch der prozentuale Anteil der jeweiligen Schlagklasse auf Datensatzebene und für die gesamte Datenbank angegeben. Besonders bei der MITDB kann es vorkommen, dass nur sehr wenige Schläge beider Schlagklassen vorhanden sind. Dies ist darin begründet, dass in diesen Datensätzen vorrangig QRS-Komplexe einer der anderen Klassen SVPB, Paced, Fusion oder Block vorhanden ist. Beispiele sind die Datensätze 102, 104 (Paced) oder 109, 111 (Block).

**Tabelle B.5:** Übersicht über das Auftreten der Schlagklassen Normal und PVC in der MITDB

Record	# QRS	# Normal	# PVC	Normal [%]	PVC [%]
100	2273	2239	1	98.5	0.04
101	1865	1862	0	99.84	0
102	2187	99	4	4.53	0.18
103	2084	2082	0	99.9	0
104	2229	181	2	8.12	0.09
105	2572	2531	41	98.41	1.59
106	2027	1507	520	74.35	25.65
107	2137	0	59	0	2.76
108	1763	1741	16	98.75	0.91
109	2532	0	38	0	1.5
111	2124	0	1	0	0.05
112	2539	2537	0	99.92	0
113	1795	1789	0	99.67	0
114	1879	1820	43	96.86	2.29
115	1953	1953	0	100	0
116	2412	2302	109	95.44	4.52
117	1535	1534	0	99.93	0
118	2278	0	16	0	0.7

Fortsetzung auf nächster Seite

**Tabelle B.5:** Übersicht über das Auftreten der Schlagklassen Normal und PVC in der MITDB

Record	# QRS	# Normal	# PVC	Normal [%]	PVC [%]
119	1987	1543	444	77.65	22.35
121	1863	1861	1	99.89	0.05
122	2476	2476	0	100	0
123	1518	1515	3	99.8	0.2
124	1619	5	47	0.31	2.9
200	2601	1743	826	67.01	31.76
201	1963	1635	198	83.29	10.09
202	2136	2061	19	96.49	0.89
203	2980	2533	444	85	14.9
205	2656	2571	71	96.8	2.67
207	2332	0	682	0	29.25
208	2955	1588	992	53.74	33.57
209	3004	2621	1	87.25	0.03
210	2650	2423	195	91.43	7.36
212	2748	923	0	33.59	0
213	3251	2641	220	81.24	6.77
214	2261	2	256	0.09	11.32
215	3363	3196	164	95.03	4.88
217	2208	244	162	11.05	7.34
219	2154	2082	64	96.66	2.97
220	2048	1954	0	95.41	0
221	2427	2031	396	83.68	16.32
222	2483	2274	0	91.58	0
223	2605	2045	473	78.5	18.16
228	2053	1688	362	82.22	17.63
230	2256	2255	1	99.96	0.04
231	1571	314	2	19.99	0.13
232	1780	1	0	0.06	0
233	3079	2230	831	72.43	26.99
234	2753	2700	3	98.07	0.11
Total	109964	75332	7707	68.51	7.01



# C Details der Wavelet-Transformation

Dieser Abschnitt beinhaltet Details zu der für die QRS-Detektion und -Klassifikation verwendeten, auf [LZT95] basierenden Wavelet-Transformation.

## C.1 Skalenfilter bei einer Abtastfrequenz von 200 Hz

Die Koeffizienten der Skalenfilter lauten auf vier Nachkommastellen gerundet:

$$l_1 = (1.3750, -1.3750) \tag{C.1}$$

$$l_2 = (0.2500, 0.7861, -0.0029, -0.7754, -0.2746) \tag{C.2}$$

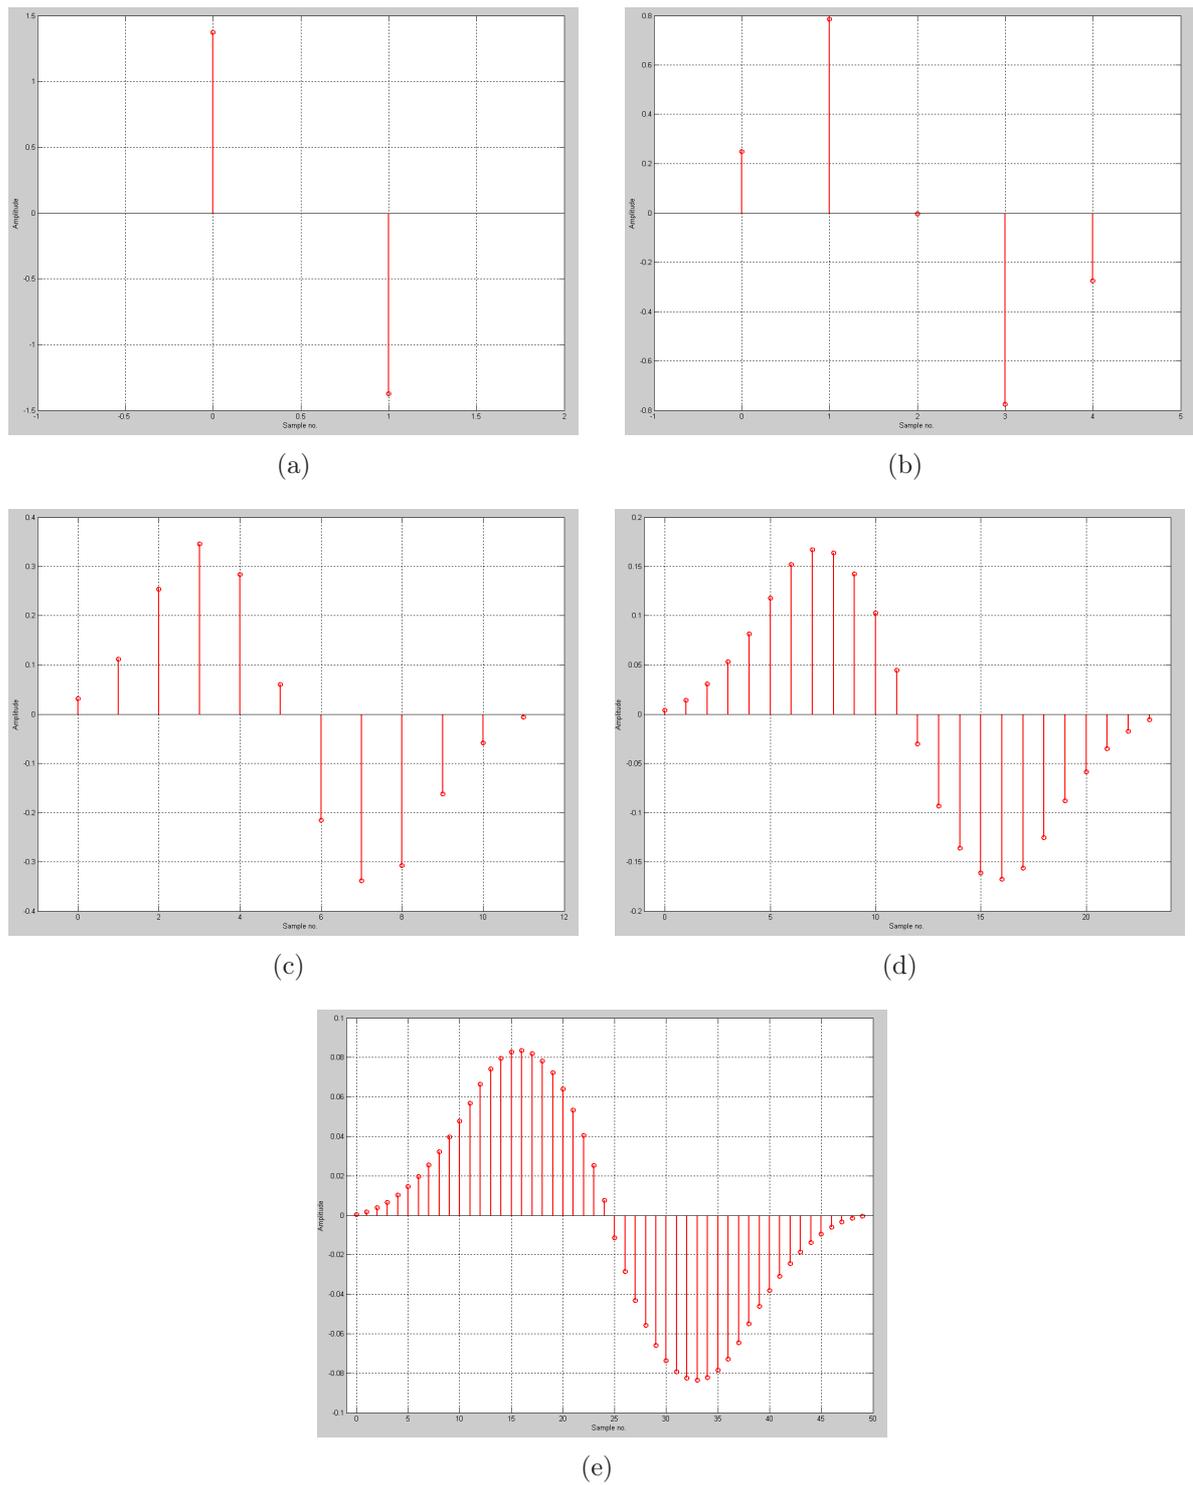
$$l_3 = (0.0313, 0.1119, 0.2536, 0.3459, 0.2838, 0.0608, -0.2160, -0.3381, -0.3080, -0.1622, -0.0578, -0.0054) \tag{C.3}$$

$$l_4 = (0.0039, 0.0143, 0.0308, 0.0534, 0.0817, 0.1177, 0.1519, 0.1670, 0.1640, 0.1426, 0.1031, 0.0448, -0.0304, -0.0931, -0.1361, -0.1612, -0.1678, -0.1566, -0.1254, -0.0882, -0.0586, -0.0348, -0.0171 - 0.0055) \tag{C.4}$$

$$l_5 = (0.0005, 0.0018, 0.0038, 0.0067, 0.0103, 0.0146, 0.0197, 0.0256, 0.0322, 0.0396, 0.0478, 0.0567, 0.0663, 0.0741, 0.0795, 0.0826, 0.0835, 0.0820, 0.0783, 0.0723, 0.0639, 0.0533, 0.0404, 0.0253, 0.0077, -0.0115, -0.0285, -0.0432, -0.0556, -0.0658, -0.0736, -0.0792, -0.0825, -0.0835, -0.0822, -0.0786, -0.0728, -0.0645, -0.0548, -0.0461, -0.0381, -0.0308, -0.0244, -0.0186, -0.0137, -0.0095, -0.0060, -0.0034, -0.0015, -0.0003) \tag{C.5}$$

Die Filterkoeffizienten für die Skala  $k = 1$  wurden nach Rücksprache mit dem Autor von [MAO<sup>+</sup>04] gewählt.

Die Impulsantworten dieser Filter sind in Abbildung C.1 dargestellt.



**Abbildung C.1:** Impulsantworten der Li-Wavelet-Filter für die Skalen 1 (a) bis 5 (e) für eine Abtastrate von 200 Hz.

# D Übersicht über VT-/VF-Detektionsalgorithmen

Dieser Abschnitt zeigt eine Übersicht über die Leistungsfähigkeit der in Kapitel 9.2.1 aufgeführten Verfahren zur Detektion von ventrikulärer Tachykardie und/oder ventrikulärem Flimmern.

**Tabelle D.1:** Leistungsfähigkeit verschiedener VF-Detektionsalgorithmen (SE = Sensitivität, SP = Spezifität, PP = pos. Prädiktivität, AC = Accuracy)

Methode	Testdatenbank	SE [%]	SP[%]	AC[%]	Anmerkungen
TCI [TZP90]	eigene	100	100	100	Parameter auf Daten optimiert.
[CMC93]	eigene	93	60	-	Test von [TZP90] mit Daten von Intensivmonitoren.
[CCF96]	MITDB	-	-	84	Test von [TZP90] mit MIT-Datenbank.
[CCF96]	MITDB	-	-	95	Verbesserung der Methode aus [TZP90].
[Jek00]	AHADB, MIT VFDB, CUDB	98	75	-	Test von [TZP90] mit 161 Episoden (71 NSR, 90 VF).
[ATU03]	MITDB, CUDB	72.1	82.8	-	
PTABT [TT97]	MITDB	99.3	99.8	-	
AKF [CT87]	eigene	-	-	-	
[CMC93]	eigene	87	0	-	Test von [CT87] mit Daten von Intensivmonitoren.
Fortsetzung auf nächster Seite					

**Tabelle D.1:** Leistungsfähigkeit verschiedener VF-Detektionsalgorithmen (SE = Sensitivität, SP = Spezifität, PP = pos. Prädiktivität, AC = Accuracy)

Methode	Testdatenbank	SE [%]	SP[%]	AC[%]	Anmerkungen
[Jek00]	AHADB, MIT VFDB, CUDB	78	32	-	Test mit 161 Episoden (71 NSR, 90 VF). p=95% in der Fisher- Distribution. p=99% in der Fisher- Distribution.
[ATU03]	MITDB, CUDB	43.1	47.0	-	
		59.8	31.6	-	
$C(n)$ [ZZTW99]	eigene, wie [TZP90]	100	100	100	Parameter auf Daten optimiert.
[Jek00]	AHADB, MIT VFDB, CUDB	66	75	-	Test von [ZZTW99] mit 161 Episoden (71 NSR, 90 VF).
[SCK05]	MIT VFDB	100	100	100	5076 Episoden (2588 NSR, 1390 VT, 1098 VF) mit 5.5s Länge.
Hurst-Index[SCK05]	MIT VFDB	100	100	100	5076 Episoden (2588 NSR, 1390 VT, 1098 VF) mit 5.5s Länge.
Leakage [KD78]	keine	-	-	-	Verbesserung der Fehlalarmquote von 44.3 auf 0.84 pro 1000 Stunden.
[CMC93]	eigene	93	20	-	Test von [KD78] mit Daten von Intensivmonito- ren.
[Jek00]	AHADB, MIT VFDB, CUDB	94	91	-	Test mit 161 Episoden (71 NSR, 90 VF).
Fortsetzung auf nächster Seite					

**Tabelle D.1:** Leistungsfähigkeit verschiedener VF-Detektionsalgorithmen (SE = Sensitivität, SP = Spezifität, PP = pos. Prädiktivität, AC = Accuracy)

Methode	Testdatenbank	SE [%]	SP[%]	AC[%]	Anmerkungen
[ATU03]	MITDB, CUDB	33.1	99.8	-	Test von [KD78] mit Standard-Datenbanken.
FFT [NBB+88]	AHA, u.a.	100	97.2	-	Vollständig beschriebener Algorithmus.
FFT [CMC93]	eigene	80	60	-	Test von [BRCM89] mit Daten von Intensivmonitoren.
[Jek00]	AHADB, MIT VFDB, CUDB	79	93	-	Test von [BRCM89] mit 161 Episoden (71 NSR, 90 VF).
[ATU03]	MITDB, CUDB	29.6	100	-	Test von [BRCM89] mit Standard-Datenbanken.
DE [CC96]	MITDB	-	-	98	Ergebnis für VF.
		-	-	96	Ergebnis für VT.
CKD [MRRIVC99]	MIT VFDB,	100	100	100	VF vs. NSR getestet.
	CUDB, eigene	97.17	98.37	97.82	NSR vs. VT getestet.
CWD [MRRIVC99]	MIT VFDB,	98.11	98.31	98.21	VF vs. NSR getestet.
	CUDB, eigene	100	100	100	NSR vs. VT getestet.
WT [MRLSM+98]	Auszüge aus AHA, MIT, u.a.	95.2	92.8	94.1	VT/VF vs. nicht-defibrillationspflichtig
IF [BDL04]	CUDB, QTDB	-	-	-	
Fuzzy [SHHK98]	eigene	-	-	-	Studie mit intrakardialen EKGs
Fortsetzung auf nächster Seite					

**Tabelle D.1:** Leistungsfähigkeit verschiedener VF-Detektionsalgorithmen (SE = Sensitivität, SP = Spezifität, PP = pos. Prädiktivität, AC = Accuracy)

Methode	Testdatenbank	SE [%]	SP[%]	AC[%]	Anmerkungen
SVM [MRVGC00]	MITDB, AHADAB, eigene	-	-	100	
STGD [WZTX01]	eigene, MIT AF DB	95.0 98.3	99.2 96.7	97.8 97.2	für VT für VF

# E Detaillierte Ergebnisse

## E.1 Ergebnisse der QRS-Detektion

Für die Analyse wurde die Applikation `bx` aus dem WFDB-Softwarepaket (siehe Anhang B.2.2) verwendet, die von den Standards [ans], [ans98] und [en602] vorgeschrieben wird. Die Analyse berücksichtigt jeweils die ersten fünf Minuten eines Datensatzes bei der Auswertung nicht. Für die QRS-Detektion werden alle Schläge berücksichtigt, die einer der in Anhang A.2 beschriebenen Klasse zugeordnet werden können. Besonderes Augenmerk wird auf die Fähigkeit der Verfahren gelegt, ventrikuläre ektope Schläge (V-Klasse) als QRS-Komplexe zu detektieren. Diese Detektionssensitivität ist in den Tabellen mit  $Se(V)$  angegeben.

Die Analyse des waveletbasierten Detektionsverfahren wurde unter Matlab vorgenommen, die Datensätze der Datenbanken wurden, sofern notwendig, vorher mit der WFDB-Applikation `xform` mit der gewünschten Frequenz neu abgetastet. Die modifizierten Implementierungen des MOBD- und Pan/Tompkins-Verfahren wurden innerhalb des TeDiaNet-Frameworks getestet. Die EKG-Daten wurden dazu in das von der Firma Medset [Med06] zur Verfügung gestellte Cardiolight-System, das ein Teil der Diagnosesoftware PADSYS ist, importiert. Für den Import wurde ebenfalls ein Resampling mit Hilfe von `xform` auf eine feste Abtastfrequenz von 200 Hz vorgenommen.

### E.1.1 MIT/BIH Arrhythmia Database

Für diesen Test wurden die 44 Datensätze der MITDB (siehe Anhang B.3.1) herangezogen, die keine schrittmacherinduzierten Schläge enthalten. Die Datensätze 102, 104, 107 und 217 wurden ausgelassen, da keine exakte Lokalisierung der Schrittmacherspikes vorliegt.

#### MOBD-Verfahren

**Tabelle E.1:** Ergebnisse der QRS-Detektion für das MOBD-Verfahren auf der MIT Database

Record	TP	FP	FN	TP(V)	FN(V)	SE	PP	SE(V)
100	1848	0	54	1	0	97,16%	100,00%	100,00%
101	1523	1	0	0	0	100,00%	99,93%	-
103	1729	0	0	0	0	100,00%	100,00%	-
105	2121	55	34	29	0	98,42%	97,47%	100,00%
106	1671	168	25	437	23	98,53%	90,86%	95,00%
108	1439	51	41	13	0	97,23%	96,58%	100,00%

Fortsetzung auf nächster Seite

**Tabelle E.1:** Ergebnisse der QRS-Detektion für das MOBD-Verfahren auf der MIT Database

Record	TP	FP	FN	TP(V)	FN(V)	SE	PP	SE(V)
109	2095	0	4	29	3	99,81%	100,00%	90,63%
111	1775	0	1	1	0	99,94%	100,00%	100,00%
112	2110	1	1	0	0	99,95%	99,95%	-
113	1504	45	2	0	0	99,87%	97,09%	-
114	1504	0	100	30	0	93,77%	100,00%	100,00%
115	1635	4	2	0	0	99,88%	99,76%	-
116	2011	15	6	98	0	99,70%	99,26%	100,00%
117	1284	2	0	0	0	100,00%	99,84%	-
118	1916	7	0	13	0	100,00%	99,64%	100,00%
119	1661	5	0	364	0	100,00%	99,70%	100,00%
121	1559	0	1	1	0	99,94%	100,00%	100,00%
122	2054	0	0	0	0	100,00%	100,00%	-
123	1269	1	0	3	0	100,00%	99,92%	100,00%
124	1367	0	0	47	0	100,00%	100,00%	100,00%
200	2160	5	8	697	3	99,63%	99,77%	99,57%
201	1495	0	26	198	0	98,29%	100,00%	100,00%
202	1870	3	1	15	0	99,95%	99,84%	100,00%
203	2331	64	150	299	74	93,95%	97,33%	80,16%
205	2190	0	11	64	1	99,50%	100,00%	98,46%
207	1585	5	7	105	4	99,56%	99,69%	96,33%
208	2388	121	49	820	4	97,99%	95,18%	99,51%
209	2510	4	8	1	0	99,68%	99,84%	100,00%
210	2185	2	19	159	6	99,14%	99,91%	96,36%
212	2284	2	1	0	0	99,96%	99,91%	-
213	2697	1	3	195	0	99,89%	99,96%	100,00%
214	1876	7	2	210	2	99,89%	99,63%	99,06%
215	2794	0	1	130	1	99,96%	100,00%	99,24%
219	1773	0	0	51	0	100,00%	100,00%	100,00%
220	1694	0	0	0	0	100,00%	100,00%	-
221	2010	0	10	306	10	99,50%	100,00%	96,84%
222	1800	0	316	0	0	85,07%	100,00%	-
223	2197	3	2	454	1	99,91%	99,86%	99,78%
228	1687	76	16	296	6	99,06%	95,69%	98,01%
230	1859	3	0	1	0	100,00%	99,84%	100,00%
231	1278	0	0	0	0	100,00%	100,00%	-
232	1481	6	4	0	0	99,73%	99,60%	-
233	2558	1	3	690	2	99,88%	99,96%	99,71%
234	2290	1	1	3	0	99,96%	99,96%	100,00%
Gesamt	83067	659	909	5760	140	98,92%	99,21%	97,63%

## Pan/Tompkins-Verfahren

Tabelle E.2: Ergebnisse der QRS-Detektion für das Pan/Tompkins-Verfahren auf der MIT Database

Record	TP	FP	FN	TP(V)	FN(V)	SE	PP	SE(V)
100	1902	0	0	1	0	100,00%	100,00%	100,00%
101	1523	2	0	0	0	100,00%	99,87%	-
103	1696	45	33	0	0	98,09%	97,42%	-
105	2138	40	17	28	1	99,21%	98,16%	96,55%
106	1688	10	8	453	7	99,53%	99,41%	98,48%
108	1469	16	11	8	5	99,26%	98,92%	61,54%
109	2094	0	5	27	5	99,76%	100,00%	84,38%
111	1776	0	0	1	0	100,00%	100,00%	100,00%
112	2111	0	0	0	0	100,00%	100,00%	-
113	1506	0	0	0	0	100,00%	100,00%	-
114	1604	1	0	30	0	100,00%	99,94%	100,00%
115	1637	0	0	0	0	100,00%	100,00%	-
116	2009	0	8	95	3	99,60%	100,00%	96,94%
117	1284	0	0	0	0	100,00%	100,00%	-
118	1916	0	0	13	0	100,00%	100,00%	100,00%
119	1661	1	0	364	0	100,00%	99,94%	100,00%
121	1559	0	1	0	1	99,94%	100,00%	0,00%
122	2054	0	0	0	0	100,00%	100,00%	-
123	1266	0	3	0	3	99,76%	100,00%	0,00%
124	1358	0	9	38	9	99,34%	100,00%	80,85%
200	2149	5	19	690	10	99,12%	99,77%	98,57%
201	1461	0	60	196	2	96,06%	100,00%	98,99%
202	1860	0	11	11	4	99,41%	100,00%	73,33%
203	2311	47	170	306	67	93,15%	98,01%	82,04%
205	2199	0	2	63	2	99,91%	100,00%	96,92%
207	1588	1	4	105	4	99,75%	99,94%	96,33%
208	2389	11	48	792	32	98,03%	99,54%	96,12%
209	2517	4	1	1	0	99,96%	99,84%	100,00%
210	2139	3	65	111	54	97,05%	99,86%	67,27%
212	2285	0	0	0	0	100,00%	100,00%	-
213	2697	0	3	192	3	99,89%	100,00%	98,46%
214	1861	1	17	195	17	99,09%	99,95%	91,98%
215	2792	0	3	128	3	99,89%	100,00%	97,71%
219	1761	0	12	43	8	99,32%	100,00%	84,31%
220	1694	0	0	0	0	100,00%	100,00%	-
221	2014	8	6	310	6	99,70%	99,60%	98,10%
222	2100	3	16	0	0	99,24%	99,86%	-
223	2195	0	4	451	4	99,82%	100,00%	99,12%

Fortsetzung auf nächster Seite

**Tabelle E.2:** Ergebnisse der QRS-Detektion für das Pan/Tompkins-Verfahren auf der MIT Database

Record	TP	FP	FN	TP(V)	FN(V)	SE	PP	SE(V)
228	1697	1	6	296	6	99,65%	99,94%	98,01%
230	1859	0	0	1	0	100,00%	100,00%	100,00%
231	1278	0	0	0	0	100,00%	100,00%	-
232	1396	8	89	0	0	94,01%	99,43%	-
233	2524	0	37	655	37	98,56%	100,00%	94,65%
234	2289	0	2	1	2	99,91%	100,00%	33,33%
Gesamt	83306	207	670	5605	295	99,20%	99,75%	95,00%

### Waveletbasiertes Verfahren

**Tabelle E.3:** Ergebnisse der QRS-Detektion für das waveletbasierte Verfahren bei einer Abtastfrequenz von 200 Hz und sechs Detektionsregeln auf der MIT Database

Record	TP	FP	FN	TP(V)	FN(V)	SE	PP	SE(V)
100	1901	0	1	1	0	99,95%	100,00%	100,00%
101	1523	0	0	0	0	100,00%	100,00%	-
103	1714	92	15	0	0	99,13%	94,91%	-
105	2145	85	10	29	0	99,54%	96,19%	100,00%
106	1695	11	1	459	1	99,94%	99,36%	99,78%
108	1473	23	7	13	0	99,53%	98,46%	100,00%
109	2099	0	0	32	0	100,00%	100,00%	100,00%
111	1776	0	0	1	0	100,00%	100,00%	100,00%
112	2109	0	2	0	0	99,91%	100,00%	-
113	1504	0	2	0	0	99,87%	100,00%	-
114	1604	1	0	30	0	100,00%	99,94%	100,00%
115	1636	5	1	0	0	99,94%	99,70%	-
116	2017	0	0	98	0	100,00%	100,00%	100,00%
117	1284	0	0	0	0	100,00%	100,00%	-
118	1916	4	0	13	0	100,00%	99,79%	100,00%
119	1661	0	0	364	0	100,00%	100,00%	100,00%
121	1560	1	0	1	0	100,00%	99,94%	100,00%
122	2054	0	0	0	0	100,00%	100,00%	-
123	1269	0	0	3	0	100,00%	100,00%	100,00%
124	1367	0	0	47	0	100,00%	100,00%	100,00%
200	2146	38	22	696	4	98,99%	98,26%	99,43%
201	1514	0	7	198	0	99,54%	100,00%	100,00%
202	1871	0	0	15	0	100,00%	100,00%	100,00%
203	2462	206	19	368	5	99,23%	92,28%	98,66%
205	2193	0	8	60	5	99,64%	100,00%	92,31%
207	1590	3	2	107	2	99,87%	99,81%	98,17%
208	2427	23	10	822	2	99,59%	99,06%	99,76%

Fortsetzung auf nächster Seite

**Tabelle E.3:** Ergebnisse der QRS-Detektion für das waveletbasierte Verfahren bei einer Abtastfrequenz von 200 Hz und sechs Detektionsregeln auf der MIT Database

Record	TP	FP	FN	TP(V)	FN(V)	SE	PP	SE(V)
209	2517	8	1	1	0	99,96%	99,68%	100,00%
210	2199	3	5	163	2	99,77%	99,86%	98,79%
212	2285	6	0	0	0	100,00%	99,74%	-
213	2699	5	1	195	0	99,96%	99,82%	100,00%
214	1877	5	1	211	1	99,95%	99,73%	99,53%
215	2795	0	0	131	0	100,00%	100,00%	100,00%
219	1773	1	0	51	0	100,00%	99,94%	100,00%
220	1694	0	0	0	0	100,00%	100,00%	-
221	2020	1	0	316	0	100,00%	99,95%	100,00%
222	2115	4	1	0	0	99,95%	99,81%	-
223	2198	1	1	455	0	99,95%	99,95%	100,00%
228	1701	4	2	302	0	99,88%	99,77%	100,00%
230	1859	3	0	1	0	100,00%	99,84%	100,00%
231	1278	0	0	0	0	100,00%	100,00%	-
232	1485	5	0	0	0	100,00%	99,66%	-
233	2561	4	0	692	0	100,00%	99,84%	100,00%
234	2291	0	0	3	0	100,00%	100,00%	100,00%
Gesamt	83857	542	119	5878	22	99,86%	99,36%	99,63%

**Tabelle E.4:** Ergebnisse der QRS-Detektion für das waveletbasierte Verfahren bei einer Abtastfrequenz von 250 Hz und sechs Detektionsregeln auf der MIT Database

Record	TP	FP	FN	TP(V)	FN(V)	SE	PP	SE(V)
100	1901	0	1	1	0	99,95%	100,00%	100,00%
101	1522	0	1	0	0	99,93%	100,00%	-
103	1716	99	13	0	0	99,25%	94,55%	-
105	2143	93	12	29	0	99,44%	95,84%	100,00%
106	1694	24	2	459	1	99,88%	98,60%	99,78%
108	1474	28	6	13	0	99,59%	98,14%	100,00%
109	2099	1	0	32	0	100,00%	99,95%	100,00%
111	1775	1	1	1	0	99,94%	99,94%	100,00%
112	2111	1	0	0	0	100,00%	99,95%	-
113	1505	4	1	0	0	99,93%	99,73%	-
114	1604	0	0	30	0	100,00%	100,00%	100,00%
115	1637	5	0	0	0	100,00%	99,70%	-
116	2017	0	0	98	0	100,00%	100,00%	100,00%
117	1284	1	0	0	0	100,00%	99,92%	-
118	1916	4	0	13	0	100,00%	99,79%	100,00%
119	1661	0	0	364	0	100,00%	100,00%	100,00%
121	1560	2	0	1	0	100,00%	99,87%	100,00%
122	2054	0	0	0	0	100,00%	100,00%	-

Fortsetzung auf nächster Seite

**Tabelle E.4:** Ergebnisse der QRS-Detektion für das waveletbasierte Verfahren bei einer Abtastfrequenz von 250 Hz und sechs Detektionsregeln auf der MIT Database

Record	TP	FP	FN	TP(V)	FN(V)	SE	PP	SE(V)
123	1269	0	0	3	0	100,00%	100,00%	100,00%
124	1367	0	0	47	0	100,00%	100,00%	100,00%
200	2146	45	22	696	4	98,99%	97,95%	99,43%
201	1514	0	7	198	0	99,54%	100,00%	100,00%
202	1871	0	0	15	0	100,00%	100,00%	100,00%
203	2460	307	21	366	7	99,15%	88,90%	98,12%
205	2196	0	5	61	4	99,77%	100,00%	93,85%
207	1591	3	1	108	1	99,94%	99,81%	99,08%
208	2427	31	10	821	3	99,59%	98,74%	99,64%
209	2518	12	0	1	0	100,00%	99,53%	100,00%
210	2202	7	2	165	0	99,91%	99,68%	100,00%
212	2285	7	0	0	0	100,00%	99,69%	-
213	2699	19	1	195	0	99,96%	99,30%	100,00%
214	1877	5	1	211	1	99,95%	99,73%	99,53%
215	2795	0	0	131	0	100,00%	100,00%	100,00%
219	1773	0	0	51	0	100,00%	100,00%	100,00%
220	1694	0	0	0	0	100,00%	100,00%	-
221	2020	10	0	316	0	100,00%	99,51%	100,00%
222	2115	2	1	0	0	99,95%	99,91%	-
223	2199	6	0	455	0	100,00%	99,73%	100,00%
228	1702	5	1	302	0	99,94%	99,71%	100,00%
230	1859	3	0	1	0	100,00%	99,84%	100,00%
231	1278	0	0	0	0	100,00%	100,00%	-
232	1485	9	0	0	0	100,00%	99,40%	-
233	2561	6	0	692	0	100,00%	99,77%	100,00%
234	2291	1	0	3	0	100,00%	99,96%	100,00%
Gesamt	83867	741	109	5879	21	99,87%	99,12%	99,64%

## E.1.2 AHA Database

In dieser Datenbank enthalten die Datensätze 2202 und 8205 schrittmacherinduzierte Schläge und wurden bei der Analyse ausgeschlossen. Die Ergebnisse wurden dann auf den verbleibenden 78 Datensätzen erzielt.

### MOBD-Verfahren

**Tabelle E.5:** Ergebnisse der QRS-Detektion für das MOBD-Verfahren auf der AHA Database

Record	TP	FP	FN	TP(V)	FN(V)	SE	PP	SE(V)
1201	1621	344	2	0	0	99,88%	82,49%	-
1202	2595	4	1	0	0	99,96%	99,85%	-
1203	2180	2	1	0	0	99,95%	99,91%	-
1204	2944	29	31	0	0	98,96%	99,02%	-
1205	2554	1	0	0	0	100,00%	99,96%	-
1206	2123	2	0	0	0	100,00%	99,91%	-
1207	1536	0	0	0	0	100,00%	100,00%	-
1208	2448	0	0	0	0	100,00%	100,00%	-
1209	3580	5	3	0	0	99,92%	99,86%	-
1210	1949	158	44	0	0	97,79%	92,50%	-
2201	2876	0	0	73	0	100,00%	100,00%	100,00%
2203	2413	2	1	12	1	99,96%	99,92%	92,31%
2204	3473	20	38	38	0	98,92%	99,43%	100,00%
2205	1606	28	22	37	22	98,65%	98,29%	62,71%
2206	1613	1	0	269	0	100,00%	99,94%	100,00%
2207	3288	0	0	276	0	100,00%	100,00%	100,00%
2208	2854	65	1	309	0	99,96%	97,77%	100,00%
2209	2414	1	1	144	0	99,96%	99,96%	100,00%
2210	2514	124	23	77	2	99,09%	95,30%	97,47%
3201	2176	2	0	26	0	100,00%	99,91%	100,00%
3202	2943	1	1	59	0	99,97%	99,97%	100,00%
3203	1947	28	3	35	0	99,85%	98,58%	100,00%
3204	1877	13	1	79	0	99,95%	99,31%	100,00%
3205	1752	1	32	14	0	98,21%	99,94%	100,00%
3206	3246	0	0	113	0	100,00%	100,00%	100,00%
3207	2322	2	3	26	1	99,87%	99,91%	96,30%
3208	2424	3	1	115	0	99,96%	99,88%	100,00%
3209	2580	5	5	62	0	99,81%	99,81%	100,00%
3210	2459	11	13	81	0	99,47%	99,55%	100,00%
4201	1932	0	1	441	0	99,95%	100,00%	100,00%
4202	2370	9	7	117	3	99,71%	99,62%	97,50%
4203	2582	0	0	474	0	100,00%	100,00%	100,00%
4204	2258	3	0	109	0	100,00%	99,87%	100,00%
4205	1447	6	5	142	4	99,66%	99,59%	97,26%

Fortsetzung auf nächster Seite

**Tabelle E.5:** Ergebnisse der QRS-Detektion für das MOBD-Verfahren auf der AHA Database

Record	TP	FP	FN	TP(V)	FN(V)	SE	PP	SE(V)
4206	1945	1	2	155	1	99,90%	99,95%	99,36%
4207	3517	2	3	641	1	99,91%	99,94%	99,84%
4208	1871	27	7	25	0	99,63%	98,58%	100,00%
4209	2370	3	2	826	1	99,92%	99,87%	99,88%
4210	2902	5	5	682	2	99,83%	99,83%	99,71%
5201	2225	1	32	203	32	98,58%	99,96%	86,38%
5202	2352	0	0	164	0	100,00%	100,00%	100,00%
5203	2373	0	0	4	0	100,00%	100,00%	100,00%
5204	2253	135	35	357	3	98,47%	94,35%	99,17%
5205	1787	171	19	316	0	98,95%	91,27%	100,00%
5206	1796	436	272	44	1	86,85%	80,47%	97,78%
5207	2923	4	1	46	0	99,97%	99,86%	100,00%
5208	1834	692	12	34	1	99,35%	72,60%	97,14%
5209	2164	2	1	11	0	99,95%	99,91%	100,00%
5210	1950	518	67	294	61	96,68%	79,01%	82,82%
6201	2501	0	0	46	0	100,00%	100,00%	100,00%
6202	1952	388	2	235	2	99,90%	83,42%	99,16%
6203	2698	0	1	157	0	99,96%	100,00%	100,00%
6204	2250	3	1	136	0	99,96%	99,87%	100,00%
6205	2249	199	46	178	26	98,00%	91,87%	87,25%
6206	1522	1263	1261	317	43	54,69%	54,65%	88,06%
6207	2042	6	3	463	0	99,85%	99,71%	100,00%
6208	2359	11	0	51	0	100,00%	99,54%	100,00%
6209	2500	2	1	750	0	99,96%	99,92%	100,00%
6210	3251	23	39	362	32	98,81%	99,30%	91,88%
7201	3147	5	17	633	17	99,46%	99,84%	97,38%
7202	2128	0	0	219	0	100,00%	100,00%	100,00%
7203	2527	8	6	165	5	99,76%	99,68%	97,06%
7204	1924	0	3	40	2	99,84%	100,00%	95,24%
7205	2425	26	13	158	10	99,47%	98,94%	94,05%
7206	3109	0	0	1884	0	100,00%	100,00%	100,00%
7207	2338	10	3	93	0	99,87%	99,57%	100,00%
7208	1565	0	1	40	1	99,94%	100,00%	97,56%
7209	2867	62	30	1612	26	98,96%	97,88%	98,41%
7210	1743	2	11	17	1	99,37%	99,89%	94,44%
8201	1438	13	20	10	20	98,63%	99,10%	33,33%
8202	1743	9	42	63	42	97,65%	99,49%	60,00%
8203	1387	91	179	0	1	88,57%	93,84%	0,00%
8204	887	33	31	29	1	96,62%	96,41%	96,67%
8206	1097	66	37	133	21	96,74%	94,33%	86,36%
8207	1052	342	303	784	158	77,64%	75,47%	83,23%

Fortsetzung auf nächster Seite

**Tabelle E.5:** Ergebnisse der QRS-Detektion für das MOBD-Verfahren auf der AHA Database

Record	TP	FP	FN	TP(V)	FN(V)	SE	PP	SE(V)
8208	474	29	68	63	41	87,45%	94,23%	60,58%
8209	1982	3	42	101	42	97,92%	99,85%	70,63%
8210	2143	0	1	0	0	99,95%	100,00%	-
Gesamt	174458	5461	2859	15669	627	98,39%	96,96%	96,15%

## Pan/Tompkins-Verfahren

**Tabelle E.6:** Ergebnisse der QRS-Detektion für das Pan/Tompkins-Verfahren auf der AHA Database

Record	TP	FP	FN	TP(V)	FN(V)	SE	PP	SE(V)
1201	1622	0	1	0	0	99,94%	100,00%	-
1202	2596	0	0	0	0	100,00%	100,00%	-
1203	2181	0	0	0	0	100,00%	100,00%	-
1204	2973	2	2	0	0	99,93%	99,93%	-
1205	2534	467	20	0	0	99,22%	84,44%	-
1206	2122	0	1	0	0	99,95%	100,00%	-
1207	1536	0	0	0	0	100,00%	100,00%	-
1208	2448	0	0	0	0	100,00%	100,00%	-
1209	3560	79	23	0	0	99,36%	97,83%	-
1210	1988	14	5	0	0	99,75%	99,30%	-
2201	2875	0	1	73	0	99,97%	100,00%	100,00%
2203	2412	0	2	13	0	99,92%	100,00%	100,00%
2204	3510	2	1	38	0	99,97%	99,94%	100,00%
2205	1628	57	0	59	0	100,00%	96,62%	100,00%
2206	1613	0	0	269	0	100,00%	100,00%	100,00%
2207	3288	0	0	276	0	100,00%	100,00%	100,00%
2208	2854	0	1	309	0	99,96%	100,00%	100,00%
2209	2392	692	23	128	16	99,05%	77,56%	88,89%
2210	2537	0	0	79	0	100,00%	100,00%	100,00%
3201	2176	2	0	26	0	100,00%	99,91%	100,00%
3202	2942	0	2	58	1	99,93%	100,00%	98,31%
3203	1950	1	0	35	0	100,00%	99,95%	100,00%
3204	1862	0	16	63	16	99,15%	100,00%	79,75%
3205	1783	0	1	13	1	99,94%	100,00%	92,86%
3206	3245	0	1	112	1	99,97%	100,00%	99,12%
3207	2323	0	2	26	1	99,91%	100,00%	96,30%
3208	2424	0	1	115	0	99,96%	100,00%	100,00%
3209	2523	0	62	1	61	97,60%	100,00%	1,61%
3210	2450	0	22	70	11	99,11%	100,00%	86,42%

Fortsetzung auf nächster Seite

**Tabelle E.6:** Ergebnisse der QRS-Detektion für das Pan/Tompkins-Verfahren auf der AHA Database

Record	TP	FP	FN	TP(V)	FN(V)	SE	PP	SE(V)
4201	1932	0	1	441	0	99,95%	100,00%	100,00%
4202	2363	1	14	108	12	99,41%	99,96%	90,00%
4203	2581	5	1	473	1	99,96%	99,81%	99,79%
4204	2238	0	20	89	20	99,11%	100,00%	81,65%
4205	1439	1	13	134	12	99,10%	99,93%	91,78%
4206	1945	0	2	154	2	99,90%	100,00%	98,72%
4207	3519	0	1	641	1	99,97%	100,00%	99,84%
4208	1871	0	7	18	7	99,63%	100,00%	72,00%
4209	2322	0	50	823	4	97,89%	100,00%	99,52%
4210	2884	0	23	661	23	99,21%	100,00%	96,64%
5201	2062	0	195	40	195	91,36%	100,00%	17,02%
5202	2350	0	2	163	1	99,91%	100,00%	99,39%
5203	2373	3	0	4	0	100,00%	99,87%	100,00%
5204	2287	0	1	360	0	99,96%	100,00%	100,00%
5205	1806	0	0	316	0	100,00%	100,00%	100,00%
5206	2068	0	0	45	0	100,00%	100,00%	100,00%
5207	2915	0	9	46	0	99,69%	100,00%	100,00%
5208	1845	0	1	34	1	99,95%	100,00%	97,14%
5209	2164	0	1	11	0	99,95%	100,00%	100,00%
5210	1850	0	167	188	167	91,72%	100,00%	52,96%
6201	2495	0	6	40	6	99,76%	100,00%	86,96%
6202	1941	0	13	225	12	99,33%	100,00%	94,94%
6203	2687	0	12	146	11	99,56%	100,00%	92,99%
6204	2251	0	0	136	0	100,00%	100,00%	100,00%
6205	2198	0	97	108	96	95,77%	100,00%	52,94%
6206	2732	57	51	349	11	98,17%	97,96%	96,94%
6207	2034	8	11	453	10	99,46%	99,61%	97,84%
6208	2359	0	0	51	0	100,00%	100,00%	100,00%
6209	2496	1	5	746	4	99,80%	99,96%	99,47%
6210	3279	0	11	384	10	99,67%	100,00%	97,46%
7201	3158	0	6	644	6	99,81%	100,00%	99,08%
7202	2116	0	12	207	12	99,44%	100,00%	94,52%
7203	2533	0	0	170	0	100,00%	100,00%	100,00%
7204	1925	3	2	41	1	99,90%	99,84%	97,62%
7205	2352	0	86	83	85	96,47%	100,00%	49,40%
7206	2939	0	170	1719	165	94,53%	100,00%	91,24%
7207	2335	0	6	89	4	99,74%	100,00%	95,70%
7208	1559	0	7	35	6	99,55%	100,00%	85,37%
7209	2841	2	56	1582	56	98,07%	99,93%	96,58%

Fortsetzung auf nächster Seite

**Tabelle E.6:** Ergebnisse der QRS-Detektion für das Pan/Tompkins-Verfahren auf der AHA Database

Record	TP	FP	FN	TP(V)	FN(V)	SE	PP	SE(V)
7210	1746	0	8	11	7	99,54%	100,00%	61,11%
8201	1443	1	15	15	15	98,97%	99,93%	50,00%
8202	1770	118	15	90	15	99,16%	93,75%	85,71%
8203	1560	0	6	1	0	99,62%	100,00%	100,00%
8204	911	1	7	28	2	99,24%	99,89%	93,33%
8206	1089	41	45	123	31	96,03%	96,37%	79,87%
8207	1148	14	207	764	178	84,72%	98,80%	81,10%
8208	533	0	9	95	9	98,34%	100,00%	91,35%
8209	1993	3	31	113	30	98,47%	99,85%	79,02%
8210	2142	316	2	0	0	99,91%	87,14%	-
Gesamt	175726	1891	1591	14960	1336	99,10%	98,94%	91,80%

### Waveletbasiertes Verfahren

**Tabelle E.7:** Ergebnisse der QRS-Detektion für das waveletbasierte Verfahren bei einer Abtastfrequenz von 200 Hz und sechs Detektionsregeln auf der AHA Database

Record	TP	FP	FN	TP(V)	FN(V)	SE	PP	SE(V)
1201	1623	0	0	0	0	100,00%	100,00%	-
1202	2596	1	0	0	0	100,00%	99,96%	-
1203	2181	0	0	0	0	100,00%	100,00%	-
1204	2975	3	0	0	0	100,00%	99,90%	-
1205	2554	0	0	0	0	100,00%	100,00%	-
1206	2123	0	0	0	0	100,00%	100,00%	-
1207	1536	0	0	0	0	100,00%	100,00%	-
1208	2448	0	0	0	0	100,00%	100,00%	-
1209	3581	17	2	0	0	99,94%	99,53%	-
1210	1975	169	18	0	0	99,10%	92,12%	-
2201	2876	0	0	73	0	100,00%	100,00%	100,00%
2203	2414	4	0	13	0	100,00%	99,83%	100,00%
2204	3509	4	2	38	0	99,94%	99,89%	100,00%
2205	1626	6	2	59	0	99,88%	99,63%	100,00%
2206	1613	0	0	269	0	100,00%	100,00%	100,00%
2207	3287	0	1	276	0	99,97%	100,00%	100,00%
2208	2854	0	1	309	0	99,96%	100,00%	100,00%
2209	2415	1	0	144	0	100,00%	99,96%	100,00%
2210	2537	4	0	79	0	100,00%	99,84%	100,00%
3201	2176	2	0	26	0	100,00%	99,91%	100,00%
3202	2944	0	0	59	0	100,00%	100,00%	100,00%

Fortsetzung auf nächster Seite

**Tabelle E.7:** Ergebnisse der QRS-Detektion für das waveletbasierte Verfahren bei einer Abtastfrequenz von 200 Hz und sechs Detektionsregeln auf der AHA Database

Record	TP	FP	FN	TP(V)	FN(V)	SE	PP	SE(V)
3203	1949	54	1	35	0	99,95%	97,30%	100,00%
3204	1878	0	0	79	0	100,00%	100,00%	100,00%
3205	1784	0	0	14	0	100,00%	100,00%	100,00%
3206	3246	0	0	113	0	100,00%	100,00%	100,00%
3207	2324	4	1	27	0	99,96%	99,83%	100,00%
3208	2425	2	0	115	0	100,00%	99,92%	100,00%
3209	2585	2	0	62	0	100,00%	99,92%	100,00%
3210	2470	9	2	80	1	99,92%	99,64%	98,77%
4201	1933	0	0	441	0	100,00%	100,00%	100,00%
4202	2374	26	3	119	1	99,87%	98,92%	99,17%
4203	2582	1	0	474	0	100,00%	99,96%	100,00%
4204	2257	3	1	109	0	99,96%	99,87%	100,00%
4205	1451	4	1	145	1	99,93%	99,73%	99,32%
4206	1947	1	0	156	0	100,00%	99,95%	100,00%
4207	3511	24	9	638	4	99,74%	99,32%	99,38%
4208	1878	19	0	25	0	100,00%	99,00%	100,00%
4209	2372	0	0	827	0	100,00%	100,00%	100,00%
4210	2907	2	0	684	0	100,00%	99,93%	100,00%
5201	2146	2	111	124	111	95,08%	99,91%	52,77%
5202	2351	0	1	164	0	99,96%	100,00%	100,00%
5203	2372	1	1	4	0	99,96%	99,96%	100,00%
5204	2288	0	0	360	0	100,00%	100,00%	100,00%
5205	1806	0	0	316	0	100,00%	100,00%	100,00%
5206	2067	8	1	45	0	99,95%	99,61%	100,00%
5207	2922	0	2	46	0	99,93%	100,00%	100,00%
5208	1846	4	0	35	0	100,00%	99,78%	100,00%
5209	2161	2	4	9	2	99,82%	99,91%	81,82%
5210	2017	64	0	355	0	100,00%	96,92%	100,00%
6201	2500	1	1	46	0	99,96%	99,96%	100,00%
6202	1954	0	0	237	0	100,00%	100,00%	100,00%
6203	2697	14	2	157	0	99,93%	99,48%	100,00%
6204	2251	0	0	136	0	100,00%	100,00%	100,00%
6205	2287	2	8	198	6	99,65%	99,91%	97,06%
6206	2774	20	9	356	4	99,68%	99,28%	98,89%
6207	2044	8	1	463	0	99,95%	99,61%	100,00%
6208	2359	3	0	51	0	100,00%	99,87%	100,00%
6209	2499	7	2	749	1	99,92%	99,72%	99,87%
6210	3288	2	2	393	1	99,94%	99,94%	99,75%
7201	3160	0	4	646	4	99,87%	100,00%	99,38%
7202	2128	0	0	219	0	100,00%	100,00%	100,00%

Fortsetzung auf nächster Seite

**Tabelle E.7:** Ergebnisse der QRS-Detektion für das waveletbasierte Verfahren bei einer Abtastfrequenz von 200 Hz und sechs Detektionsregeln auf der AHA Database

Record	TP	FP	FN	TP(V)	FN(V)	SE	PP	SE(V)
7203	2533	1	0	170	0	100,00%	99,96%	100,00%
7204	1924	1	3	40	2	99,84%	99,95%	95,24%
7205	2436	1	2	166	2	99,92%	99,96%	98,81%
7206	3107	0	2	1882	2	99,94%	100,00%	99,89%
7207	2339	2	2	93	0	99,91%	99,91%	100,00%
7208	1566	0	0	41	0	100,00%	100,00%	100,00%
7209	2894	10	3	1635	3	99,90%	99,66%	99,82%
7210	1753	1	1	18	0	99,94%	99,94%	100,00%
8201	1448	0	10	20	10	99,31%	100,00%	66,67%
8202	1773	10	12	93	12	99,33%	99,44%	88,57%
8203	1565	1	1	0	1	99,94%	99,94%	0,00%
8204	909	1	9	27	3	99,02%	99,89%	90,00%
8206	1108	45	26	133	21	97,71%	96,10%	86,36%
8207	1324	97	31	911	31	97,71%	93,17%	96,71%
8208	537	2	5	100	4	99,08%	99,63%	96,15%
8209	1983	0	41	102	41	97,97%	100,00%	71,33%
8210	2144	40	0	0	0	100,00%	98,17%	-
Gesamt	176976	712	341	16028	268	99,81%	99,60%	98,36%

**Tabelle E.8:** Ergebnisse der QRS-Detektion für das waveletbasierte Verfahren bei einer Abtastfrequenz von 250 Hz und sechs Detektionsregeln auf der AHA Database

Record	TP	FP	FN	TP(V)	FN(V)	SE	PP	SE(V)
1201	1623	0	0	0	0	100,00%	100,00%	-
1202	2596	2	0	0	0	100,00%	99,92%	-
1203	2181	0	0	0	0	100,00%	100,00%	-
1204	2975	17	0	0	0	100,00%	99,43%	-
1205	2554	1	0	0	0	100,00%	99,96%	-
1206	2123	0	0	0	0	100,00%	100,00%	-
1207	1536	0	0	0	0	100,00%	100,00%	-
1208	2448	0	0	0	0	100,00%	100,00%	-
1209	3581	4	2	0	0	99,94%	99,89%	-
1210	1977	184	16	0	0	99,20%	91,49%	-
2201	2876	0	0	73	0	100,00%	100,00%	100,00%
2203	2414	4	0	13	0	100,00%	99,83%	100,00%
2204	3508	5	3	38	0	99,91%	99,86%	100,00%
2205	1623	7	5	55	4	99,69%	99,57%	93,22%
2206	1613	0	0	269	0	100,00%	100,00%	100,00%
2207	3288	3	0	276	0	100,00%	99,91%	100,00%

Fortsetzung auf nächster Seite

**Tabelle E.8:** Ergebnisse der QRS-Detektion für das waveletbasierte Verfahren bei einer Abtastfrequenz von 250 Hz und sechs Detektionsregeln auf der AHA Database

Record	TP	FP	FN	TP(V)	FN(V)	SE	PP	SE(V)
2208	2854	13	1	309	0	99,96%	99,55%	100,00%
2209	2415	23	0	144	0	100,00%	99,06%	100,00%
2210	2537	3	0	79	0	100,00%	99,88%	100,00%
3201	2176	4	0	26	0	100,00%	99,82%	100,00%
3202	2944	0	0	59	0	100,00%	100,00%	100,00%
3203	1947	36	3	35	0	99,85%	98,18%	100,00%
3204	1878	6	0	79	0	100,00%	99,68%	100,00%
3205	1784	1	0	14	0	100,00%	99,94%	100,00%
3206	3246	0	0	113	0	100,00%	100,00%	100,00%
3207	2324	26	1	27	0	99,96%	98,89%	100,00%
3208	2425	3	0	115	0	100,00%	99,88%	100,00%
3209	2585	2	0	62	0	100,00%	99,92%	100,00%
3210	2471	58	1	80	1	99,96%	97,71%	98,77%
4201	1933	0	0	441	0	100,00%	100,00%	100,00%
4202	2372	34	5	119	1	99,79%	98,59%	99,17%
4203	2582	1	0	474	0	100,00%	99,96%	100,00%
4204	2257	3	1	109	0	99,96%	99,87%	100,00%
4205	1451	10	1	145	1	99,93%	99,32%	99,32%
4206	1945	4	2	156	0	99,90%	99,79%	100,00%
4207	3518	11	2	642	0	99,94%	99,69%	100,00%
4208	1878	19	0	25	0	100,00%	99,00%	100,00%
4209	2372	0	0	827	0	100,00%	100,00%	100,00%
4210	2907	2	0	684	0	100,00%	99,93%	100,00%
5201	2184	2	73	162	73	96,77%	99,91%	68,94%
5202	2351	0	1	164	0	99,96%	100,00%	100,00%
5203	2373	162	0	4	0	100,00%	93,61%	100,00%
5204	2288	0	0	360	0	100,00%	100,00%	100,00%
5205	1806	0	0	316	0	100,00%	100,00%	100,00%
5206	2065	4	3	45	0	99,85%	99,81%	100,00%
5207	2922	0	2	46	0	99,93%	100,00%	100,00%
5208	1846	16	0	35	0	100,00%	99,14%	100,00%
5209	2162	5	3	8	3	99,86%	99,77%	72,73%
5210	2017	459	0	355	0	100,00%	81,46%	100,00%
6201	2501	1	0	46	0	100,00%	99,96%	100,00%
6202	1954	1	0	237	0	100,00%	99,95%	100,00%
6203	2697	10	2	156	1	99,93%	99,63%	99,36%
6204	2251	0	0	136	0	100,00%	100,00%	100,00%
6205	2289	2	6	200	4	99,74%	99,91%	98,04%
6206	2774	21	9	357	3	99,68%	99,25%	99,17%
6207	2044	5	1	463	0	99,95%	99,76%	100,00%

Fortsetzung auf nächster Seite

**Tabelle E.8:** Ergebnisse der QRS-Detektion für das waveletbasierte Verfahren bei einer Abtastfrequenz von 250 Hz und sechs Detektionsregeln auf der AHA Database

Record	TP	FP	FN	TP(V)	FN(V)	SE	PP	SE(V)
6208	2359	10	0	51	0	100,00%	99,58%	100,00%
6209	2500	7	1	750	0	99,96%	99,72%	100,00%
6210	3288	2	2	393	1	99,94%	99,94%	99,75%
7201	3160	2	4	646	4	99,87%	99,94%	99,38%
7202	2128	0	0	219	0	100,00%	100,00%	100,00%
7203	2533	1	0	170	0	100,00%	99,96%	100,00%
7204	1924	1	3	40	2	99,84%	99,95%	95,24%
7205	2434	1	4	165	3	99,84%	99,96%	98,21%
7206	3108	0	1	1883	1	99,97%	100,00%	99,95%
7207	2337	5	4	93	0	99,83%	99,79%	100,00%
7208	1566	0	0	41	0	100,00%	100,00%	100,00%
7209	2887	25	10	1630	8	99,65%	99,14%	99,51%
7210	1751	3	3	18	0	99,83%	99,83%	100,00%
8201	1449	2	9	21	9	99,38%	99,86%	70,00%
8202	1769	7	16	89	16	99,10%	99,61%	84,76%
8203	1565	1	1	0	1	99,94%	99,94%	0,00%
8204	910	12	8	27	3	99,13%	98,70%	90,00%
8206	1104	58	30	131	23	97,35%	95,01%	85,06%
8207	1315	99	40	902	40	97,05%	93,00%	95,75%
8208	534	4	8	97	7	98,52%	99,26%	93,27%
8209	1976	0	48	95	48	97,63%	100,00%	66,43%
8210	2144	29	0	0	0	100,00%	98,67%	-
Gesamt	176982	1443	335	16039	257	99,81%	99,19%	98,42%

### E.1.3 European ST-T Database

Diese Datenbank enthält keine durch Schrittmacher induzierte Schläge, es konnten also alle 90 Datensätze berücksichtigt werden.

#### MOBD-Verfahren

**Tabelle E.9:** Ergebnisse der QRS-Detektion für das MOBD-Verfahren auf der European ST-T Database

Record	TP	FP	FN	TP(V)	FN(V)	SE	PP	SE(V)
e0103	6988	4	0	78	4	100,00%	99,94%	95,12%
e0104	7334	6	13	10	0	99,82%	99,92%	100,00%
e0105	6328	26	10	0	0	99,84%	99,59%	-
e0106	6557	301	0	0	0	100,00%	95,61%	-
e0107	6763	13	188	8	0	97,30%	99,81%	100,00%
e0108	6330	0	11	4	0	99,83%	100,00%	100,00%
e0110	6670	7	8	0	0	99,88%	99,90%	-
e0111	6859	372	22	0	0	99,68%	94,86%	-
e0112	5262	37	139	7	0	97,43%	99,30%	100,00%
e0113	8622	17	5	10	0	99,94%	99,80%	100,00%
e0114	5322	3	5	0	2	99,91%	99,94%	0,00%
e0115	10855	0	0	0	0	100,00%	100,00%	-
e0116	4267	23	133	0	0	96,98%	99,46%	-
e0118	6752	10	27	0	0	99,60%	99,85%	-
e0119	7411	13	60	0	0	99,20%	99,82%	-
e0121	10239	11	5	6	2	99,95%	99,89%	75,00%
e0122	10903	1	1	2	0	99,99%	99,99%	100,00%
e0123	8791	1	4	3	0	99,95%	99,99%	100,00%
e0124	8835	3	11	3	0	99,88%	99,97%	100,00%
e0125	8708	1	4	0	0	99,95%	99,99%	-
e0126	7933	1	6	3	0	99,92%	99,99%	100,00%
e0127	9027	0	0	0	0	100,00%	100,00%	-
e0129	5337	6	8	0	0	99,85%	99,89%	-
e0133	6301	11	7	0	0	99,89%	99,83%	-
e0136	6720	43	38	0	0	99,44%	99,36%	-
e0139	9767	473	40	0	0	99,59%	95,38%	-
e0147	6071	35	3	0	0	99,95%	99,43%	-
e0148	6363	59	94	9	1	98,54%	99,08%	90,00%
e0151	7263	2	3	0	0	99,96%	99,97%	-
e0154	6357	130	23	0	0	99,64%	98,00%	-
e0155	7098	672	204	0	0	97,21%	91,35%	-
e0159	8201	675	598	24	0	93,20%	92,40%	100,00%
e0161	8518	0	2	0	0	99,98%	100,00%	-
e0162	10209	21	68	10	0	99,34%	99,79%	100,00%
e0163	7285	15	24	9	0	99,67%	99,79%	100,00%

Fortsetzung auf nächster Seite

**Tabelle E.9:** Ergebnisse der QRS-Detektion für das MOBD-Verfahren auf der European ST-T Database

Record	TP	FP	FN	TP (V)	FN (V)	SE	PP	SE(V)
e0166	6144	2	72	0	0	98,84%	99,97%	-
e0170	8419	8	259	1	0	97,02%	99,91%	100,00%
e0202	9414	10	15	28	2	99,84%	99,89%	93,33%
e0203	9750	2	0	1	1	100,00%	99,98%	50,00%
e0204	11017	12	3	0	0	99,97%	99,89%	-
e0205	11406	14	14	0	0	99,88%	99,88%	-
e0206	10406	32	30	143	15	99,71%	99,69%	90,51%
e0207	6914	3	4	30	0	99,94%	99,96%	100,00%
e0208	8311	7	21	0	0	99,75%	99,92%	-
e0210	8427	17	0	0	1	100,00%	99,80%	0,00%
e0211	14365	2	1	14	1	99,99%	99,99%	93,33%
e0212	10380	4	1	0	0	99,99%	99,96%	-
e0213	10570	9	12	270	2	99,89%	99,91%	99,26%
e0302	8745	1172	58	0	0	99,34%	88,18%	-
e0303	7976	568	8	4	0	99,90%	93,35%	100,00%
e0304	7518	507	72	51	4	99,05%	93,68%	92,73%
e0305	8293	791	1146	7	1	87,86%	91,29%	87,50%
e0306	7606	5	18	186	2	99,76%	99,93%	98,94%
e0403	8919	3	0	3	2	100,00%	99,97%	60,00%
e0404	6660	1	3	0	0	99,95%	99,98%	-
e0405	10745	4	3	0	0	99,97%	99,96%	-
e0406	8589	64	47	0	0	99,46%	99,26%	-
e0408	8708	2	1	0	0	99,99%	99,98%	-
e0409	12517	1	0	1	0	100,00%	99,99%	100,00%
e0410	7210	4	5	0	0	99,93%	99,94%	-
e0411	9518	12	27	442	3	99,72%	99,87%	99,33%
e0413	7776	47	1005	608	30	88,55%	99,40%	95,30%
e0415	10259	754	533	16	1	95,06%	93,15%	94,12%
e0417	8849	1	0	22	0	100,00%	99,99%	100,00%
e0418	11252	0	0	0	0	100,00%	100,00%	-
e0501	7397	8	23	0	0	99,69%	99,89%	-
e0509	7758	1	5	133	0	99,94%	99,99%	100,00%
e0515	10300	5	6	0	0	99,94%	99,95%	-
e0601	8481	6	6	0	0	99,93%	99,93%	-
e0602	10469	222	16	261	68	99,85%	97,92%	79,33%
e0603	7582	12	1	16	1	99,99%	99,84%	94,12%
e0604	7472	5	1	1	0	99,99%	99,93%	100,00%
e0605	10888	4	2	713	0	99,98%	99,96%	100,00%
e0606	9264	4	5	23	0	99,95%	99,96%	100,00%
e0607	9915	1	1	2	0	99,99%	99,99%	100,00%
e0609	8956	1	0	18	0	100,00%	99,99%	100,00%

Fortsetzung auf nächster Seite

**Tabelle E.9:** Ergebnisse der QRS-Detektion für das MOBD-Verfahren auf der European ST-T Database

Record	TP	FP	FN	TP (V)	FN (V)	SE	PP	SE (V)
e0610	7694	2	3	1	1	99,96%	99,97%	50,00%
e0611	5572	13	130	0	0	97,72%	99,77%	-
e0612	6636	1	1	26	0	99,98%	99,98%	100,00%
e0613	7488	4	15	0	0	99,80%	99,95%	-
e0614	10575	75	173	844	21	98,39%	99,30%	97,57%
e0615	6883	6	283	139	0	96,05%	99,91%	100,00%
e0704	9353	26	37	0	0	99,61%	99,72%	-
e0801	9069	0	2	2	0	99,98%	100,00%	100,00%
e0808	10521	102	306	0	0	97,17%	99,04%	-
e0817	7078	192	812	0	0	89,71%	97,36%	-
e0818	9770	0	0	0	0	100,00%	100,00%	-
e1301	8482	47	19	7	2	99,78%	99,45%	77,78%
e1302	7990	18	2	3	0	99,97%	99,78%	100,00%
e1304	7188	383	24	5	1	99,67%	94,94%	83,33%
Gesamt	751690	8188	6995	4207	168	99,08%	98,92%	96,16%

### Pan/Tompkins-Verfahren

**Tabelle E.10:** Ergebnisse der QRS-Detektion für das Pan/Tompkins-Verfahren auf der European ST-T Database

Record	TP	FP	FN	TP (V)	FN (V)	SE	PP	SE (V)
e0103	6979	13	2	69	13	99,97%	99,81%	84,15%
e0104	7338	2	1	10	0	99,99%	99,97%	100,00%
e0105	6354	0	0	0	0	100,00%	100,00%	-
e0106	6857	1	0	0	0	100,00%	99,99%	-
e0107	6775	1	0	7	1	100,00%	99,99%	87,50%
e0108	6329	1	86	4	0	98,66%	99,98%	100,00%
e0110	6660	17	74	0	0	98,90%	99,75%	-
e0111	7220	11	20	0	0	99,72%	99,85%	-
e0112	5289	10	51	5	2	99,04%	99,81%	71,43%
e0113	8638	1	0	10	0	100,00%	99,99%	100,00%
e0114	5325	0	0	2	0	100,00%	100,00%	100,00%
e0115	10855	0	0	0	0	100,00%	100,00%	-
e0116	4256	34	348	0	0	92,44%	99,21%	-
e0118	6448	314	2951	0	0	68,60%	95,36%	-
e0119	7152	272	628	0	0	91,93%	96,34%	-
e0121	10244	6	1	3	5	99,99%	99,94%	37,50%
e0122	10904	0	0	2	0	100,00%	100,00%	100,00%
e0123	8789	3	13	2	1	99,85%	99,97%	66,67%
e0124	8832	6	7	3	0	99,92%	99,93%	100,00%

Fortsetzung auf nächster Seite

**Tabelle E.10:** Ergebnisse der QRS-Detektion für das Pan/Tompkins-Verfahren auf der European ST-T Database

Record	TP	FP	FN	TP(V)	FN(V)	SE	PP	SE(V)
e0125	8707	2	8	0	0	99,91%	99,98%	-
e0126	7933	1	0	3	0	100,00%	99,99%	100,00%
e0127	9027	0	6	0	0	99,93%	100,00%	-
e0129	5332	11	186	0	0	96,63%	99,79%	-
e0133	6300	12	3	0	0	99,95%	99,81%	-
e0136	6758	5	29	0	0	99,57%	99,93%	-
e0139	10221	19	4	0	0	99,96%	99,81%	-
e0147	6105	1	0	0	0	100,00%	99,98%	-
e0148	6410	12	8	10	0	99,88%	99,81%	100,00%
e0151	7262	3	1	0	0	99,99%	99,96%	-
e0154	6486	1	2	0	0	99,97%	99,98%	-
e0155	7767	3	3	0	0	99,96%	99,96%	-
e0159	8864	12	29	24	0	99,67%	99,86%	100,00%
e0161	8518	0	0	0	0	100,00%	100,00%	-
e0162	10229	1	1	10	0	99,99%	99,99%	100,00%
e0163	7300	0	0	9	0	100,00%	100,00%	100,00%
e0166	6145	1	1	0	0	99,98%	99,98%	-
e0170	8426	1	0	1	0	100,00%	99,99%	100,00%
e0202	9414	10	3	20	10	99,97%	99,89%	66,67%
e0203	9750	2	0	2	0	100,00%	99,98%	100,00%
e0204	11025	4	0	0	0	100,00%	99,96%	-
e0205	11406	14	5	0	0	99,96%	99,88%	-
e0206	10394	44	0	125	33	100,00%	99,58%	79,11%
e0207	6909	8	3	30	0	99,96%	99,88%	100,00%
e0208	8316	2	2	0	0	99,98%	99,98%	-
e0210	8444	0	0	1	0	100,00%	100,00%	100,00%
e0211	14365	2	0	14	1	100,00%	99,99%	93,33%
e0212	10383	1	0	0	0	100,00%	99,99%	-
e0213	10542	37	3	270	2	99,97%	99,65%	99,26%
e0302	9917	0	0	0	0	100,00%	100,00%	-
e0303	8541	3	0	1	3	100,00%	99,96%	25,00%
e0304	8023	2	702	55	0	91,95%	99,98%	100,00%
e0305	8918	166	4971	7	1	64,21%	98,17%	87,50%
e0306	7610	1	0	188	0	100,00%	99,99%	100,00%
e0403	8920	2	0	3	2	100,00%	99,98%	60,00%
e0404	6661	0	0	0	0	100,00%	100,00%	-
e0405	10747	2	0	0	0	100,00%	99,98%	-
e0406	8652	1	0	0	0	100,00%	99,99%	-
e0408	8709	1	1	0	0	99,99%	99,99%	-
e0409	12517	1	0	0	1	100,00%	99,99%	0,00%

Fortsetzung auf nächster Seite

**Tabelle E.10:** Ergebnisse der QRS-Detektion für das Pan/Tompkins-Verfahren auf der European ST-T Database

Record	TP	FP	FN	TP(V)	FN(V)	SE	PP	SE(V)
e0410	7213	1	0	0	0	100,00%	99,99%	-
e0411	9527	3	4	445	0	99,96%	99,97%	100,00%
e0413	7805	18	9	621	17	99,88%	99,77%	97,34%
e0415	11005	8	5	17	0	99,95%	99,93%	100,00%
e0417	8849	1	0	22	0	100,00%	99,99%	100,00%
e0418	11251	1	0	0	0	100,00%	99,99%	-
e0501	7404	1	0	0	0	100,00%	99,99%	-
e0509	7738	21	0	114	19	100,00%	99,73%	85,71%
e0515	10302	3	5	0	0	99,95%	99,97%	-
e0601	8485	2	0	0	0	100,00%	99,98%	-
e0602	10650	41	0	290	39	100,00%	99,62%	88,15%
e0603	7593	1	0	17	0	100,00%	99,99%	100,00%
e0604	7472	5	238	1	0	96,91%	99,93%	100,00%
e0605	10869	23	0	700	13	100,00%	99,79%	98,18%
e0606	9267	1	0	22	1	100,00%	99,99%	95,65%
e0607	9914	2	1	2	0	99,99%	99,98%	100,00%
e0609	8943	14	0	12	6	100,00%	99,84%	66,67%
e0610	7694	2	0	0	2	100,00%	99,97%	0,00%
e0611	5581	4	152	0	0	97,35%	99,93%	-
e0612	6633	4	0	23	3	100,00%	99,94%	88,46%
e0613	7490	2	1	0	0	99,99%	99,97%	-
e0614	10578	72	17	793	72	99,84%	99,32%	91,68%
e0615	6881	8	0	132	7	100,00%	99,88%	94,96%
e0704	9377	2	2	0	0	99,98%	99,98%	-
e0801	9066	3	0	0	2	100,00%	99,97%	0,00%
e0808	10590	33	32	0	0	99,70%	99,69%	-
e0817	7162	108	38	0	0	99,47%	98,51%	-
e0818	9770	0	0	0	0	100,00%	100,00%	-
e1301	8519	10	0	5	4	100,00%	99,88%	55,56%
e1302	8008	0	0	3	0	100,00%	100,00%	100,00%
e1304	7570	1	3	5	1	99,96%	99,99%	83,33%
<b>Gesamt</b>	<b>758403</b>	<b>1475</b>	<b>10660</b>	<b>4114</b>	<b>261</b>	<b>98,61%</b>	<b>99,81%</b>	<b>94,03%</b>

## Waveletbasiertes Verfahren

**Tabelle E.11:** Ergebnisse der QRS-Detektion für das waveletbasierte Verfahren bei einer Abtastfrequenz von 200 Hz und sechs Detektionsregeln auf der European ST/T Database

Record	TP	FP	FN	TP (V)	FN (V)	SE	PP	SE (V)
e0103	6989	2	3	81	1	99,96%	99,97%	98,78%
e0104	7339	2	1	10	0	99,99%	99,97%	100,00%
e0105	6354	0	0	0	0	100,00%	100,00%	-
e0106	6857	0	1	0	0	99,99%	100,00%	-
e0107	6776	107	0	8	0	100,00%	98,45%	100,00%
e0108	6330	1	0	4	0	100,00%	99,98%	100,00%
e0110	6675	2	2	0	0	99,97%	99,97%	-
e0111	7230	6	1	0	0	99,99%	99,92%	-
e0112	5292	57	7	6	1	99,87%	98,93%	85,71%
e0113	8639	1	0	10	0	100,00%	99,99%	100,00%
e0114	5325	1	0	2	0	100,00%	99,98%	100,00%
e0115	10855	0	0	0	0	100,00%	100,00%	-
e0116	4257	155	33	0	0	99,23%	96,49%	-
e0118	6622	389	140	0	0	97,93%	94,45%	-
e0119	7219	462	205	0	0	97,24%	93,99%	-
e0121	10248	17	2	8	0	99,98%	99,83%	100,00%
e0122	10898	4	6	2	0	99,94%	99,96%	100,00%
e0123	8790	3	2	3	0	99,98%	99,97%	100,00%
e0124	8835	0	3	3	0	99,97%	100,00%	100,00%
e0125	8706	1	3	0	0	99,97%	99,99%	-
e0126	7934	0	0	3	0	100,00%	100,00%	100,00%
e0127	9027	1	0	0	0	100,00%	99,99%	-
e0129	5342	2	1	0	0	99,98%	99,96%	-
e0133	6309	1	3	0	0	99,95%	99,98%	-
e0136	6760	12	3	0	0	99,96%	99,82%	-
e0139	10231	9	9	0	0	99,91%	99,91%	-
e0147	6106	1	0	0	0	100,00%	99,98%	-
e0148	6415	60	7	10	0	99,89%	99,07%	100,00%
e0151	7265	2	0	0	0	100,00%	99,97%	-
e0154	6487	6	0	0	0	100,00%	99,91%	-
e0155	7769	22	1	0	0	99,99%	99,72%	-
e0159	8806	314	70	24	0	99,21%	96,56%	100,00%
e0161	8516	3	2	0	0	99,98%	99,96%	-
e0162	10229	23	1	10	0	99,99%	99,78%	100,00%
e0163	7299	17	1	9	0	99,99%	99,77%	100,00%
e0166	6144	274	2	0	0	99,97%	95,73%	-
e0170	8427	18	0	1	0	100,00%	99,79%	100,00%

Fortsetzung auf nächster Seite

**Tabelle E.11:** Ergebnisse der QRS-Detektion für das waveletbasierte Verfahren bei einer Abtastfrequenz von 200 Hz und sechs Detektionsregeln auf der European ST/T Database

Record	TP	FP	FN	TP(V)	FN(V)	SE	PP	SE(V)
e0202	9420	14	4	26	4	99,96%	99,85%	86,67%
e0203	9752	0	0	2	0	100,00%	100,00%	100,00%
e0204	11029	4	0	0	0	100,00%	99,96%	-
e0205	11412	32	8	0	0	99,93%	99,72%	-
e0206	10434	20	4	157	1	99,96%	99,81%	99,37%
e0207	6916	4	1	29	1	99,99%	99,94%	96,67%
e0208	8317	37	1	0	0	99,99%	99,56%	-
e0210	8441	2	3	1	0	99,96%	99,98%	100,00%
e0211	14367	0	0	15	0	100,00%	100,00%	100,00%
e0212	10383	2	1	0	0	99,99%	99,98%	-
e0213	10573	21	6	271	1	99,94%	99,80%	99,63%
e0302	9853	8	64	0	0	99,35%	99,92%	-
e0303	8541	34	3	4	0	99,96%	99,60%	100,00%
e0304	8024	78	1	55	0	99,99%	99,04%	100,00%
e0305	9073	46	11	7	1	99,88%	99,50%	87,50%
e0306	7608	17	3	187	1	99,96%	99,78%	99,47%
e0403	8922	1	0	5	0	100,00%	99,99%	100,00%
e0404	6660	0	1	0	0	99,98%	100,00%	-
e0405	10739	7	10	0	0	99,91%	99,93%	-
e0406	8652	68	1	0	0	99,99%	99,22%	-
e0408	8710	0	0	0	0	100,00%	100,00%	-
e0409	12518	0	0	1	0	100,00%	100,00%	100,00%
e0410	7214	2	0	0	0	100,00%	99,97%	-
e0411	9530	19	0	445	0	100,00%	99,80%	100,00%
e0413	7822	8	1	637	1	99,99%	99,90%	99,84%
e0415	11001	104	12	17	0	99,89%	99,06%	100,00%
e0417	8850	141	0	22	0	100,00%	98,43%	100,00%
e0418	11252	0	0	0	0	100,00%	100,00%	-
e0501	7405	1	0	0	0	100,00%	99,99%	-
e0509	7758	1	1	132	1	99,99%	99,99%	99,25%
e0515	10302	6	3	0	0	99,97%	99,94%	-
e0601	8486	7	1	0	0	99,99%	99,92%	-
e0602	10687	16	4	329	0	99,96%	99,85%	100,00%
e0603	7593	3	1	17	0	99,99%	99,96%	100,00%
e0604	7471	18	6	1	0	99,92%	99,76%	100,00%
e0605	10887	2	5	713	0	99,95%	99,98%	100,00%
e0606	9267	1	1	23	0	99,99%	99,99%	100,00%
e0607	9916	4	0	2	0	100,00%	99,96%	100,00%
e0609	8930	50	27	18	0	99,70%	99,44%	100,00%

Fortsetzung auf nächster Seite

**Tabelle E.11:** Ergebnisse der QRS-Detektion für das waveletbasierte Verfahren bei einer Abtastfrequenz von 200 Hz und sechs Detektionsregeln auf der European ST/T Database

Record	TP	FP	FN	TP(V)	FN(V)	SE	PP	SE(V)
e0610	7695	5	1	2	0	99,99%	99,94%	100,00%
e0611	5584	19	1	0	0	99,98%	99,66%	-
e0612	6631	13	6	26	0	99,91%	99,80%	100,00%
e0613	7490	219	2	0	0	99,97%	97,16%	-
e0614	10611	46	39	826	39	99,63%	99,57%	95,49%
e0615	6889	8	0	139	0	100,00%	99,88%	100,00%
e0704	9377	214	2	0	0	99,98%	97,77%	-
e0801	9069	97	0	2	0	100,00%	98,94%	100,00%
e0808	10612	127	11	0	0	99,90%	98,82%	-
e0817	7240	103	30	0	0	99,59%	98,60%	-
e0818	9770	73	0	0	0	100,00%	99,26%	-
e1301	8518	21	11	9	0	99,87%	99,75%	100,00%
e1302	8007	1	1	3	0	99,99%	99,99%	100,00%
e1304	7568	11	3	6	0	99,96%	99,85%	100,00%
Gesamt	759078	3710	800	4323	52	99,89%	99,51%	98,81%

**Tabelle E.12:** Ergebnisse der QRS-Detektion für das waveletbasierte Verfahren bei einer Abtastfrequenz von 250 Hz und sechs Detektionsregeln auf der European ST/T Database

Record	TP	FP	FN	TP(V)	FN(V)	SE	PP	SE(V)
e0103	6990	3	2	81	1	99,97%	99,96%	98,78%
e0104	7337	1	3	10	0	99,96%	99,99%	100,00%
e0105	6354	3	0	0	0	100,00%	99,95%	-
e0106	6857	0	1	0	0	99,99%	100,00%	-
e0107	6775	11	1	8	0	99,99%	99,84%	100,00%
e0108	6330	4	0	4	0	100,00%	99,94%	100,00%
e0110	6675	1	2	0	0	99,97%	99,99%	-
e0111	7230	19	1	0	0	99,99%	99,74%	-
e0112	5292	56	7	7	0	99,87%	98,95%	100,00%
e0113	8639	1	0	10	0	100,00%	99,99%	100,00%
e0114	5325	1	0	2	0	100,00%	99,98%	100,00%
e0115	10855	0	0	0	0	100,00%	100,00%	-
e0116	4260	185	30	0	0	99,30%	95,84%	-
e0118	6608	396	154	0	0	97,72%	94,35%	-
e0119	7226	468	198	0	0	97,33%	93,92%	-
e0121	10248	21	2	7	1	99,98%	99,80%	87,50%
e0122	10902	8	2	2	0	99,98%	99,93%	100,00%
e0123	8792	5	0	3	0	100,00%	99,94%	100,00%

Fortsetzung auf nächster Seite

**Tabelle E.12:** Ergebnisse der QRS-Detektion für das waveletbasierte Verfahren bei einer Abtastfrequenz von 250 Hz und sechs Detektionsregeln auf der European ST/T Database

Record	TP	FP	FN	TP(V)	FN(V)	SE	PP	SE(V)
e0124	8838	8	0	3	0	100,00%	99,91%	100,00%
e0125	8709	2	0	0	0	100,00%	99,98%	-
e0126	7934	2	0	3	0	100,00%	99,97%	100,00%
e0127	9027	2	0	0	0	100,00%	99,98%	-
e0129	5343	1	0	0	0	100,00%	99,98%	-
e0133	6308	1	4	0	0	99,94%	99,98%	-
e0136	6762	11	1	0	0	99,99%	99,84%	-
e0139	10233	15	7	0	0	99,93%	99,85%	-
e0147	6105	2	1	0	0	99,98%	99,97%	-
e0148	6417	48	5	10	0	99,92%	99,26%	100,00%
e0151	7265	3	0	0	0	100,00%	99,96%	-
e0154	6484	14	3	0	0	99,95%	99,78%	-
e0155	7770	42	0	0	0	100,00%	99,46%	-
e0159	8825	281	51	24	0	99,43%	96,91%	100,00%
e0161	8518	3	0	0	0	100,00%	99,96%	-
e0162	10226	43	4	10	0	99,96%	99,58%	100,00%
e0163	7297	16	3	9	0	99,96%	99,78%	100,00%
e0166	6144	769	2	0	0	99,97%	88,88%	-
e0170	8427	33	0	1	0	100,00%	99,61%	100,00%
e0202	9422	13	2	28	2	99,98%	99,86%	93,33%
e0203	9752	0	0	2	0	100,00%	100,00%	100,00%
e0204	11029	5	0	0	0	100,00%	99,95%	-
e0205	11408	50	12	0	0	99,89%	99,56%	-
e0206	10432	20	6	157	1	99,94%	99,81%	99,37%
e0207	6915	4	2	29	1	99,97%	99,94%	96,67%
e0208	8315	30	3	0	0	99,96%	99,64%	-
e0210	8443	0	1	1	0	99,99%	100,00%	100,00%
e0211	14366	2	1	15	0	99,99%	99,99%	100,00%
e0212	10384	1	0	0	0	100,00%	99,99%	-
e0213	10572	14	7	271	1	99,93%	99,87%	99,63%
e0302	9894	5	23	0	0	99,77%	99,95%	-
e0303	8541	28	3	4	0	99,96%	99,67%	100,00%
e0304	8022	170	3	55	0	99,96%	97,92%	100,00%
e0305	9017	131	67	7	1	99,26%	98,57%	87,50%
e0306	7608	19	3	187	1	99,96%	99,75%	99,47%
e0403	8922	1	0	5	0	100,00%	99,99%	100,00%
e0404	6660	0	1	0	0	99,98%	100,00%	-
e0405	10741	6	8	0	0	99,93%	99,94%	-
e0406	8652	88	1	0	0	99,99%	98,99%	-

Fortsetzung auf nächster Seite

**Tabelle E.12:** Ergebnisse der QRS-Detektion für das waveletbasierte Verfahren bei einer Abtastfrequenz von 250 Hz und sechs Detektionsregeln auf der European ST/T Database

Record	TP	FP	FN	TP(V)	FN(V)	SE	PP	SE(V)
e0408	8710	0	0	0	0	100,00%	100,00%	-
e0409	12518	1	0	1	0	100,00%	99,99%	100,00%
e0410	7214	2	0	0	0	100,00%	99,97%	-
e0411	9529	35	1	445	0	99,99%	99,63%	100,00%
e0413	7821	24	2	636	2	99,97%	99,69%	99,69%
e0415	11005	90	8	16	1	99,93%	99,19%	94,12%
e0417	8850	319	0	22	0	100,00%	96,52%	100,00%
e0418	11252	3	0	0	0	100,00%	99,97%	-
e0501	7405	1	0	0	0	100,00%	99,99%	-
e0509	7759	1	0	133	0	100,00%	99,99%	100,00%
e0515	10304	6	1	0	0	99,99%	99,94%	-
e0601	8485	18	2	0	0	99,98%	99,79%	-
e0602	10687	14	4	329	0	99,96%	99,87%	100,00%
e0603	7594	2	0	17	0	100,00%	99,97%	100,00%
e0604	7472	19	5	1	0	99,93%	99,75%	100,00%
e0605	10889	0	3	713	0	99,97%	100,00%	100,00%
e0606	9267	6	1	23	0	99,99%	99,94%	100,00%
e0607	9916	4	0	2	0	100,00%	99,96%	100,00%
e0609	8928	47	29	18	0	99,68%	99,48%	100,00%
e0610	7694	3	2	2	0	99,97%	99,96%	100,00%
e0611	5585	16	0	0	0	100,00%	99,71%	-
e0612	6630	16	7	26	0	99,89%	99,76%	100,00%
e0613	7490	236	2	0	0	99,97%	96,95%	-
e0614	10584	86	66	801	64	99,38%	99,19%	92,60%
e0615	6888	10	1	139	0	99,99%	99,86%	100,00%
e0704	9377	285	2	0	0	99,98%	97,05%	-
e0801	9069	96	0	2	0	100,00%	98,95%	100,00%
e0808	10614	158	9	0	0	99,92%	98,53%	-
e0817	7234	166	36	0	0	99,50%	97,76%	-
e0818	9768	81	2	0	0	99,98%	99,18%	-
e1301	8524	14	5	9	0	99,94%	99,84%	100,00%
e1302	8006	1	2	3	0	99,98%	99,99%	100,00%
e1304	7567	12	4	6	0	99,95%	99,84%	100,00%
<b>Gesamt</b>	<b>759057</b>	<b>4838</b>	<b>821</b>	<b>4299</b>	<b>76</b>	<b>99,89%</b>	<b>99,37%</b>	<b>98,26%</b>

## E.1.4 MIT Noise Stress Database

Alle 12 Datensätze der Datenbank wurden bei der Analyse berücksichtigt.

### MOBD-Verfahren

**Tabelle E.13:** Ergebnisse des modifizierten MOBD-Verfahrens auf der MIT NSTDB

Record	TP	FP	FN	TP(V)	FN(V)	SE	PP	SE(V)
118e_6	1222	344	694	10	3	63,78%	78,03	
118e00	1530	501	386	9	4	79,85%	75,33%	69,23%
118e06	1727	539	189	11	2	90,14%	76,21%	84,62%
118e12	1841	415	75	11	2	96,09%	81,60%	84,62%
118e18	1894	126	22	13	0	98,85%	93,76%	100,00%
118e24	1912	17	4	13	0	99,79%	99,12%	100,00%
119e_6	1163	637	498	247	117	70,02%	64,61%	67,86%
119e00	1402	712	259	298	66	84,41%	66,32%	81,87%
119e06	1536	637	125	327	37	92,47%	70,69%	89,84%
119e12	1502	600	159	350	14	90,43%	71,46%	96,15%
119e18	1586	232	75	357	7	95,48%	87,24%	98,08%
119e24	1628	89	33	364	0	98,01%	94,82%	100,00%
Gesamt	18943	4849	2519	2010	252	88,26%	79,62%	88,86%

### Pan/Tompkins-Verfahren

**Tabelle E.14:** Ergebnisse des modifizierten Pan/Tompkins-Verfahrens auf der MIT NSTDB

Record	TP	FP	FN	TP(V)	FN(V)	SE	PP	SE(V)
118e_6	1506	742	410	11	2	78,60%	66,99%	84,62%
118e00	1746	655	170	8	5	91,13%	72,72%	61,54%
118e06	1875	380	41	11	2	97,86%	83,15%	84,62%
118e12	1915	12	1	12	1	99,95%	99,38%	92,31%
118e18	1915	0	1	12	1	99,95%	100,00%	92,31%
118e24	1916	0	0	13	0	100,00%	100,00%	100,00%
119e_6	1305	839	356	300	64	78,57%	60,87%	82,42%
119e00	1507	762	154	343	21	90,73%	66,42%	94,23%
119e06	1619	489	42	355	9	97,47%	76,80%	97,53%
119e12	1653	78	8	362	2	99,52%	95,49%	99,45%
119e18	1661	0	0	364	0	100,00%	100,00%	100,00%
119e24	1661	0	0	364	0	100,00%	100,00%	100,00%
Gesamt	20279	3957	1183	2155	107	94,49%	83,67%	95,27%

## Waveletbasiertes Verfahren

**Tabelle E.15:** Ergebnisse des waveletbasierten Verfahrens bei 200 Hz und sechs Klassifikationsregeln auf der MIT NSTDB

Record	TP	FP	FN	TP(V)	FN(V)	SE	PP	SE(V)
118e_6	1664	897	252	10	3	86,85%	64,97%	76,92%
118e00	1769	802	147	11	2	92,33%	68,81%	84,62%
118e06	1884	589	32	12	1	98,33%	76,18%	92,31%
118e12	1915	342	1	13	0	99,95%	84,85%	100,00%
118e18	1916	68	0	13	0	100,00%	96,57%	100,00%
118e24	1916	6	0	13	0	100,00%	99,69%	100,00%
119e_6	1476	939	185	321	43	88,86%	61,12%	88,19%
119e00	1563	813	98	325	39	94,10%	65,78%	89,29%
119e06	1642	612	19	349	15	98,86%	72,85%	95,88%
119e12	1660	374	1	363	1	99,94%	81,61%	99,73%
119e18	1661	76	0	364	0	100,00%	95,62%	100,00%
119e24	1661	1	0	364	0	100,00%	99,94%	100,00%
Gesamt	20727	5519	735	2158	104	96,58%	78,97%	95,40%

**Tabelle E.16:** Ergebnisse des waveletbasierten Verfahrens bei 250 Hz und sechs Klassifikationsregeln auf der MIT NSTDB

Record	TP	FP	FN	TP(V)	FN(V)	SE	PP	SE(V)
118e_6	1660	906	256	10	3	86,64%	64,69%	76,92%
118e00	1766	797	150	11	2	92,17%	68,90%	84,62%
118e06	1890	605	26	12	1	98,64%	75,75%	92,31%
118e12	1915	398	1	13	0	99,95%	82,79%	100,00%
118e18	1916	118	0	13	0	100,00%	94,20%	100,00%
118e24	1916	7	0	13	0	100,00%	99,64%	100,00%
119e_6	1478	938	183	318	46	88,98%	61,18%	87,36%
119e00	1555	829	106	323	41	93,62%	65,23%	88,74%
119e06	1637	660	24	347	17	98,56%	71,27%	95,33%
119e12	1660	442	1	363	1	99,94%	78,97%	99,73%
119e18	1661	119	0	364	0	100,00%	93,31%	100,00%
119e24	1661	10	0	364	0	100,00%	99,40%	100,00%
Gesamt	20715	5829	747	2151	111	96,52%	78,04%	95,09%

## E.2 Ergebnisse der VT-/VF-Klassifikation

Im Folgenden werden die Ergebnisse der VT-/VF-Klassifikation für die verschiedenen in Kapitel 9 angesprochenen Ansätze vorgestellt. In den meisten Fällen wurden die Tabelle und Ergebnisse auf Grundlage der sekundenbasierten Klassifikation ermittelt, da dies die beste Näherung der Größen „Duration Sensitivity“ und „Duration positive Predictivity“ des Standardtools *epic* aus der WFDB-Bibliothek darstellt.

**Tabelle E.17:** Statistische Auswertung der Parameter „SAV“ und „WAL“ aus den Skalen 3 und 4 mit ANFIS

Record	TN	FN	TP	FP	SE [%]	SP [%]	PP [%]	NP [%]	AC [%]
cu01	214	22	272	0	92,5	100,0	100,0	90,7	95,7
cu03	465	9	34	0	79,1	100,0	100,0	98,1	98,2
cu04	233	113	155	0	57,8	100,0	100,0	67,3	77,4
cu05	419	27	61	0	69,3	100,0	100,0	93,9	94,7
cu06	364	66	69	6	51,1	98,4	92,0	84,7	85,7
cu07	182	98	227	0	69,8	100,0	100,0	65,0	80,7
cu09	451	14	42	0	75,0	100,0	100,0	97,0	97,2
cu10	316	84	107	0	56,0	100,0	100,0	79,0	83,4
cu11	371	14	122	0	89,7	100,0	100,0	96,4	97,2
cu13	443	5	48	11	90,6	97,6	81,4	98,9	96,8
cu14	496	0	0	13	—	97,4	0	100,0	97,4
cu15	405	44	59	0	57,3	100,0	100,0	90,2	91,3
cu16	392	38	72	3	65,5	99,2	96,0	91,2	91,9
cu17	458	18	20	11	52,6	97,7	64,5	96,2	94,3
cu18	479	6	20	2	76,9	99,6	90,9	98,8	98,4
cu19	421	57	28	0	32,9	100,0	100,0	88,1	88,7
cu20	244	237	27	0	10,2	100,0	100,0	50,7	53,3
cu21	334	70	63	34	47,4	90,8	64,9	82,7	79,2
cu22	394	14	95	4	87,2	99,0	96,0	96,6	96,4
cu23	395	20	81	11	80,2	97,3	88,0	95,2	93,9
cu24	427	29	38	13	56,7	97,0	74,5	93,6	91,7
cu25	466	30	8	3	21,1	99,4	72,7	94,0	93,5
cu26	370	27	45	63	62,5	85,5	41,7	93,2	82,2
cu28	495	8	4	1	33,3	99,8	80,0	98,4	98,2
cu29	378	63	67	0	51,5	100,0	100,0	85,7	87,6
cu30	124	237	134	9	36,1	93,2	93,7	34,3	51,2
cu31	355	7	7	139	50,0	71,9	4,8	98,1	71,3
cu32	460	13	33	1	71,7	99,8	97,1	97,3	97,2
cu33	420	30	57	0	65,5	100,0	100,0	93,3	94,1
cu34	451	35	19	0	35,2	100,0	100,0	92,8	93,1
cu35	461	16	9	22	36,0	95,4	29,0	96,6	92,5
Summe	11883	1451	2023	346	58,2	97,2	85,4	89,1	88,6

**Tabelle E.18:** Sekundenbasierte Ergebnisse der Evaluation für Test 3 auf der CUDB. Die Segmentlänge für die Parameterextraktion beträgt vier Sekunden, die Mindestlänge für die endgültigen VT-/VF-Episoden acht Sekunden.

Record	TN	FN	TP	FP	SE [%]	SP [%]	PP [%]	NP [%]	AC [%]
cu01	213	0	294	1	100,0	99,5	99,7	100,0	99,8
cu03	465	13	30	0	69,8	100,0	100,0	97,3	97,4
cu04	229	47	221	4	82,5	98,3	98,2	83,0	89,8
cu05	412	3	85	7	96,6	98,3	92,4	99,3	98,0
cu06	370	46	89	0	65,9	100,0	100,0	88,9	90,9
cu07	182	29	296	0	91,1	100,0	100,0	86,3	94,3
cu08	426	74	7	0	8,6	100,0	100,0	85,2	85,4
cu09	434	24	32	17	57,1	96,2	65,3	94,8	91,9
cu10	304	43	148	12	77,5	96,2	92,5	87,6	89,2
cu11	371	78	58	0	42,6	100,0	100,0	82,6	84,6
cu13	446	35	18	8	34,0	98,2	69,2	92,7	91,5
cu14	509	0	0	0	—	100,0	—	100,0	100,0
cu15	405	41	62	0	60,2	100,0	100,0	90,8	91,9
cu16	383	4	106	12	96,4	97,0	89,8	99,0	96,8
cu17	469	30	8	0	21,1	100,0	100,0	94,0	94,1
cu18	481	0	26	0	100,0	100,0	100,0	100,0	100,0
cu19	304	64	21	117	24,7	72,2	15,2	82,6	64,2
cu20	244	248	14	0	5,3	100,0	100,0	49,6	51,0
cu21	330	34	99	38	74,4	89,7	72,3	90,7	85,6
cu22	398	15	94	0	86,2	100,0	100,0	96,4	97,0
cu23	406	38	63	0	62,4	100,0	100,0	91,4	92,5
cu24	432	1	66	0	98,5	100,0	100,0	99,8	99,8
cu25	469	31	7	0	18,4	100,0	100,0	93,8	93,9
cu26	433	21	51	0	70,8	100,0	100,0	95,4	95,8
cu27	483	22	0	2	0,0	99,6	0,0	95,6	95,3
cu28	414	6	6	82	50,0	83,5	6,8	98,6	82,7
cu29	378	80	50	0	38,5	100,0	100,0	82,5	84,3
cu30	124	326	40	0	10,9	100,0	100,0	27,6	33,5
cu31	494	0	14	0	100,0	100,0	100,0	100,0	100,0
cu32	461	2	44	0	95,7	100,0	100,0	99,6	99,6
cu33	415	18	69	5	79,3	98,8	93,2	95,8	95,5
cu34	451	4	50	0	92,6	100,0	100,0	99,1	99,2
cu35	475	8	17	8	68,0	98,3	68,0	98,3	96,9
Summe	12810	1385	2185	313	61,2	97,6	87,5	90,2	89,8

**Tabelle E.19:** Ergebnisse der Evaluation für Test 3 auf der CUDB mit *epic*. Die Segmentlänge für die Parameterextraktion beträgt vier Sekunden, die Mindestlänge für die endgültigen VT-/VF-Episoden acht Sekunden.

Record	TN	FN	TP	FP	ESe [%]	E+P [%]	DSe [%]	D+P [%]
cu01	1	0	1	0	100	100	100	100
cu03	1	0	2	0	100	100	69	100
cu04	4	0	11	0	100	100	82	97
cu05	1	0	1	1	100	50	96	92
cu06	1	1	3	0	50	100	65	100
cu07	1	0	8	0	100	100	91	100
cu08	1	0	1	0	100	100	8	100
cu09	1	0	2	1	100	67	57	66
cu10	1	0	4	0	100	100	77	92
cu11	1	0	3	0	100	100	43	100
cu13	1	0	2	1	100	67	33	69
cu14	0	0	0	0	-	-	-	-
cu15	1	0	4	0	100	100	60	100
cu16	2	0	2	1	100	67	95	89
cu17	1	0	1	0	100	100	21	100
cu18	1	0	1	0	100	100	99	98
cu19	2	0	4	11	100	27	25	16
cu20	1	0	1	0	100	100	5	100
cu21	4	1	5	1	80	83	64	69
cu22	1	0	3	0	100	100	85	100
cu23	1	0	2	0	100	100	61	100
cu24	1	0	1	0	100	100	98	100
cu25	1	0	1	0	100	100	18	100
cu26	1	1	2	0	50	100	70	99
cu27	0	1	0	1	0	0	0	0
cu28	1	0	2	2	100	50	47	7
cu29	1	0	3	0	100	100	39	100
cu30	2	1	3	0	67	100	11	100
cu31	1	0	1	0	100	100	96	100
cu32	1	0	1	0	100	100	93	100
cu33	1	0	2	2	100	50	78	93
cu34	2	0	3	0	100	100	91	100
cu35	1	0	1	1	100	50	67	68
Mittelwert					92	85	61	86

# Literaturverzeichnis

- [Ame05] AMERICAN HEART ASSOCIATION: *AHA Database for Evaluation of Ventricular Arrhythmia Detectors*. 2005. URL <http://www.ecri.org>
- [Ana06] ANALOG DEVICES: *Technical Data Sheet ADUC7026 Rev. A*, 2006
- [ans] NORM ANSI /AAMI EC38:1998. *Ambulatory electrocardiographs*
- [ans98] NORM ANSI/AAMI EC57:1998 10 1998. *Testing and reporting performance results of cardiac rhythm and ST segment measurement algorithms*
- [AT95] AFONSO, V. X. ; TOMPKINS, W. J.: Detecting Ventricular Fibrillation. In: *IEEE Engineering in Medicine and Biology* 14 (1995), Nr. 2, S. 152–159
- [ATNL99] AFONSO, V.X. ; TOMPKINS, W.J. ; NGUYEN, T.Q. ; LUO, S.: ECG Beat Detection Using Filter Banks. In: *IEEE Transactions on Biomedical Engineering* 46 (1999), Nr. 2, S. 192–202
- [ATU03] AMANN, A. ; TRATNIG, R. ; UNTERKOFLE, K.: Reliability of Fibrillation Detection Algorithms in Automatic External Defibrillators (AEDs). In: *Biomedizinische Technik* 48 (2003), Nr. 1, S. 216–217
- [BDL04] BOVBEL, E. ; DASHOUK, M. ; LAZAREVA, I.: Detecting Of Shockable Rhythms in ECGs Using A Novel Fast Continuous Wavelet Transform Algorithm. In: *Proceedings of the xth Biosignal*, 2004, S. 109–111
- [BG93] BANDEMER, H. ; GOTTWALD, S.: *Einführung in Fuzzy-Methoden: Theorie und Anwendung unscharfer Mengen*. Akademie Verlag, 1993
- [BHH97] BAHOURA, M. ; HASSANI, M. ; HUBIN, M.: DSP implementation of a wavelet transform for real time ECG. In: *Computer Methods and Programs in Biomedicine* 52 (1997), Nr. 20, S. 35–44
- [BKKN03] BORGELT, C. ; KLAWONN, F. ; KRUSE, R. ; NAUCK, D.: *Neuro-Fuzzy-Systeme: von den Grundlagen künstlicher Neuronaler Netze zur Kopplung mit Fuzzy-Systemen*. 3. Auflage. Vieweg, 2003
- [BMTB04] BRÄCKLEIN, M. ; MOOR, C. ; TCHOUDOVSKI, I. ; BOLZ, A.: Erprobung eines automatischen Systems zur kontinuierlichen häuslichen Überwachung von kardiologischen Risikopatienten. In: *Biomedizinische Technik* 49 (2004), Nr. 2, S. 234–235

- [Bot98] BOTHE, H.-H.: *Neuro -Fuzzy-Methoden: Einführung in Theorie und Anwendungen*. Springer, 1998
- [BRCM89] BARRO, S. ; RUIZ, R. ; CABELLO, R. ; MIRA, J.: Algorithmic sequential decision-making in the frequency domain for life threatening ventricular arrhythmias and imitative artifacts: a diagnostic system. In: *J. Biomed. Eng.* 11 (1989), S. 320–328
- [BSMM93] BRONSTEIN, I. N. ; SEMENDJAJEW, A. ; MUSIOL, G. ; MÜHLIG, H.: *Taschenbuch der Mathematik*. Verlag Harri Deutsch, 1993
- [BU02] BOLZ, A. ; URBASZEK, W.: *Technik in der Kardiologie*. Springer, 2002
- [Car05] CARDGUARD: *Produktreihe King of Hearts Event-Recorder*. 2005. URL <http://www.cardguard.com>. – Zugriffsdatum 2005-08-05
- [CB04] CHRISTOV, I. ; BORTOLAN, G.: Ranking of pattern recognition parameters for premature ventricular contractions classification by neural networks. In: *Physiological Measurement* 25 (2004), S. 1281–1290
- [CC95] CHEN, S.-W. ; CLARKSON, P.M.: Prony Residual Analysis for the Identification of Cardiac Arrhythmias. 2 (1995), S. 1177–1180
- [CC96] CHEN, S.-W. ; CLARKSON, P. M.: Detection of Cardiac Arrhythmias Using a Damped Exponential Modeling Algorithm. In: *IEEE* (1996), S. 1775–1778
- [CC98] CHENG, W. T. ; CHAN, K. L.: Classification of Electrocardiogram Using Hidden Markov Models. In: *Proceedings of the 20th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 1998, S. 143–146
- [CCF96] CHEN, S.-W. ; CLARKSON, P. M. ; FAN, Q.: A Robust Sequential Detection Algorithm for Cardiac Arrhythmia Classification. In: *IEEE Transactions on Biomedical Engineering* 43 (1996), November, Nr. 11, S. 1120–1125
- [Chr04] CHRISTOV, I.: Real time electrocardiogram QRS detection using combined adaptive threshold. In: *Biomed Eng Online* 3 (2004), Aug, Nr. 1, S. 28
- [CJB05] CHRISTOV, I. ; JEKOVA, I. ; BORTOLAN, G.: Premature ventricular contraction classification by the Kth nearest-neighbours rule. In: *Physiological Measurement* 26 (2005), S. 123–130
- [CMC93] CLAYTON, R.H. ; MURRAY, A. ; CAMPBELL, R.W.F.: Comparison of four Techniques for Recognition of Ventricular Fibrillation from the Surface ECG. In: *Medical and Biological Engineering and Computing* 31 (1993), March, S. 111–117

- [CMC95] CLAYTON, R.H. ; MURRAY, A. ; CAMPBELL, R.W.F.: Frequency Analysis of Ventricular Fibrillation. In: *IEEE Transactions on Bio-medical Engineering* (1995)
- [CT87] CHEN, S. ; THAKOR, N.V.: Ventricular Fibrillation Detection by a Regression Test on the Autocorrelation Function. In: *Medical and Biological Engineering and Computing* 25 (1987), May, S. 241–249
- [Dan05] DANICA BIOMEDICAL: *TELEGUARD Telemetry system*. 2005. URL <http://www.danica-biomedical.dk>. – Zugriffsdatum 2005-08-04
- [Del05] DELMAR REYNOLDS: *Event-Recorder CardioCall ST80*. 2005. URL <http://www.delmarreynolds.com>. – Zugriffsdatum 2005-08-05
- [DMO80] DOWER, G. E. ; MACHADO, H. B. ; OSBORNE, M. D.: On Deriving the Electrocardiogram from Vectorcardiographic Leads. In: *Clin. Cardiol.* 3 (1980), S. 87–95
- [Dow87] DOWER, G. E.: Method and Apparatus for Sensing and Analyzing Electrical Activity of the Human Heart. 1987. – US Patent No. 4,850,370
- [DS04] DOTSINSKY, I. A. ; STOYANOV, T. V.: Ventricular beat detection in single channel electrocardiograms. In: *BioMedical Engineering OnLine* 3 (2004)
- [DYN+88] DOWER, G. E. ; YAKUSH, A. ; NAZZAL, S. B. ; JUTZY, R. V. ; RUIZ, C. E.: Deriving the 12-lead Electrocardiogram From Four (EASI) Electrodes. In: *Journal of Electrocardiography* Supplemental Issue (1988), S. S182–S187
- [en696] NORM DIN EN60601-1 1996. *Medizinische elektrische Geräte Teil 1: Allgemeine Festlegungen für die Sicherheit*
- [en602] NORM DIN EN60601-2-47 2002. *Besondere Festlegungen für die Sicherheit einschließlich wesentlicher Leistungsmerkmale von ambulanten elektrokardiographischen Systemen*
- [en604] NORM DIN EN60601-2-51 2004. *Besondere Festlegungen für die Sicherheit, einschließlich wesentlicher Leistungsmerkmale von aufzeichnenden und interpretierenden Einkanal- und Mehrkanal-Elektrokardiographen*
- [Eng04] ENGIN, M.: ECG beat classification using neuro-fuzzy network. In: *Pattern Recognition Letters* 25 (2004), S. 1715–1722
- [EZ79] ENGELSE, W. A. H. ; ZEELLENBERG, C.: A Single Scan Algorithm for QRS-Detection and Feature Extraction. In: *Computers in Cardiology* (1979), S. 37–42

- [FJJ+90] FRIESEN, G. M. ; JANNETT, T. C. ; JADALLAH, M. A. ; YATES, S. L. ; QUINT, S. R. ; NAGLE, H. T.: A Comparison of the Noise Sensitivity of Nine QRS Detection Algorithms. In: *IEEE Transactions on Biomedical Engineering* 37 (1990), Nr. 1, S. 85–99
- [FKJ05] FINNBERG, T. ; KARILAINEN, A. ; J., Müller: Mobile Interrogation Unit for Passive SAW-Sensors in Long-Term ECG Monitoring. In: *Biomedizinische Technik* 50 (2005), Nr. Suppl. 1, S. 439–440
- [FRA+01] FUSTER, V. ; RYDÉN, L.E. ; ASINGER, R.W. ; CANNOM, D.S. ; CRIJNS, H.J. ; FRYE, R.L. ; HALPERIN, J.L. ; KAY, G.N. ; KLEIN, W.W. ; LÉVY, S. ; MCNAMARA, R.L. ; PRYSTOWSKY, E.N. ; WANN, L.S. ; WYSE, D.G.: ACC/AHA/ESC guidelines for the management of patients with atrial fibrillation: a report of the American College of Cardiology/American Heart Association Task Force on Practice Guidelines and the European Society of Cardiology Committee for Practice Guidelines and Policy Conferences (Committee to Develop Guidelines for the Management of Patients With Atrial Fibrillation). In: *Journal of the American College of Cardiology* 38 (2001), Nr. 4, S. 1266i–lxx
- [FZI06] FZI FORSCHUNGSZENTRUM INFORMATIK AN DER UNIVERSITÄT KARLSRUHE: *Homepage*. 2006. URL <http://www.fzi.de>. – Zugriffsdatum 2006-02-08
- [GAE+02] GREGORATOS, G. ; ABRAMS, J. ; EPSTEIN, A. E. ; FREEDMAN, R. A. ; HAYES, D. L. ; HLATKY, M. A. ; KERBER, R. E. ; NACCARELLI, G. V. ; SCHOENFELD, M. H. ; SILKA, M. J. ; L., Winters S.: *ACC/AHA/NASPE 2002 guideline update for implantation of cardiac pacemakers and antiarrhythmia devices: a report of the American College of Cardiology/American Heart Association Task Force on Practice Guidelines (ACC/AHA/NASPE Committee on Pacemaker Implantation)*. 2002. URL [www.acc.org/clinical/guidelines/pacemaker/pacemaker.pdf](http://www.acc.org/clinical/guidelines/pacemaker/pacemaker.pdf). – Zugriffsdatum 2003-03-03
- [GH99] GONSKA, B.-D. ; HEINECKER, R.: *EKG in Klinik und Praxis*. 14. Aufl. -. Stuttgart, New York: Thieme, 1999
- [GSK02] GE, D. ; SRINIVASAN, N. ; KRISHNAN, S. M.: Cardiac arrhythmia classification using autoregressive modeling. In: *Biomedical Engineering Online* 1 (2002), Nov, S. 5
- [Haa05a] HAAS, M.: *QRS-Schlagklassifikation mit Zeitbereichsverfahren unter Java*, Institut für Technik der Informationsverarbeitung, Universität Karlsruhe, Studienarbeit, 2005
- [Haa05b] HAASE, D.: *Erweiterung eines Neuro-Fuzzy-Trainingsalgorithmus zur automatischen Signalklassifikation*, Universität Karlsruhe, Institut für Technik der Informationsverarbeitung, Studienarbeit, 2005

- [Ham02] HAMILTON, P. S.: *Open Source ECG Analysis Software Documentation*. 2002. URL <http://www.eplimited.com/osea13.pdf>. – Zugriffsdatum 2005-08-11
- [Har05] HARVARD-MIT DIVISION OF HEALTH SCIENCES AND TECHNOLOGY BIOMEDICAL ENGINEERING CENTER: *MIT-BIH Arrhythmia Database Directory*. 2005. URL <http://www.physionet.org/physiobank/database/html/mitdbdir/mitdbdir.htm>. – Zugriffsdatum 2005-08-08
- [Hew98a] HEWLETT PACKARD. *White Paper: 12-Lead ECG Monitoring*. 1998
- [Hew98b] HEWLETT PACKARD. *White Paper: Viridia*. 1998
- [Hew98c] HEWLETT-PACKARD COMPANY: Verfahren und Vorrichtung zum Erfassen eines Kammerflimmerns. 1998. – Forschungsbericht. Offenlegungsschrift/Patent, Deutschland DE 198 30 316 A 1
- [HGCE05] HERRERO, G. G. ; GOTCHEV, A. ; CHRISTOV, I. ; EGIAZARIAN, K.: Feature Extraction for Heartbeat Classification Using Independent Component Analysis and Matching Pursuit. In: *Proceedings of the IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP '05)*, 2005, S. IV-725 – IV-728
- [HL65] HON, E. H. ; LEE, S. T.: Electronic evaluations of the fetal heart rate patterns preceding fetal death, further observations. In: *Am J Obstet Gynec* 87 (1965), S. 814–826
- [Hor98] HORACEK, T.: *Der EKG-Trainer*. 1. Auflage. Stuttgart, New York: Thieme, 1998
- [HPT97] HU, Y. H. ; PALREDDY, S. ; TOMPKINS, W. J.: A Patient-Adaptable ECG Beat Classifier Using a Mixture of Experts Approach. In: *IEEE Transactions on Biomedical Engineering* 44 (1997), Nr. 9, S. 891–901
- [HT86] HAMILTON, P. S. ; TOMPKINS, W. J.: Quantitative Investigation of QRS Detection Rules Using the MIT/BIH Arrhythmia Database. In: *IEEE Transactions on Biomedical Engineering* 33 (1986), Nr. 12, S. 1157–1165
- [Ins05] INSTITUT FÜR TECHNIK DER INFORMATIONSVERRARBEITUNG (ITIV), UNIVERSITÄT KARLSRUHE: *PHMon - Personal Health Monitoring*. 2005. URL <http://www.phmon.de>. – Zugriffsdatum 2005-08-01
- [Ins06a] INSTITUT FÜR TECHNIK DER INFORMATIONSVERRARBEITUNG (ITIV), UNIVERSITÄT KARLSRUHE: *GeneralStore - Integrationsplattform für einen durchgängigen Systementwurf*. 2006. URL [http://www.itiv.uni-karlsruhe.de/opencms/opencms/de/research/projects/se\\_emb/gS.html](http://www.itiv.uni-karlsruhe.de/opencms/opencms/de/research/projects/se_emb/gS.html). – Zugriffsdatum 2006-02-08

- [Ins06b] INSTITUT FÜR TECHNIK DER INFORMATIONSVERRARBEITUNG (ITIV), UNIVERSITÄT KARLSRUHE: *Homepage*. 2006. URL <http://www.itiv.uni-karlsruhe.de>. – Zugriffsdatum 2006-02-08
- [JBC04] JEKOVA, I. ; BORTOLAN, G. ; CHRISTOV, I.: Pattern Recognition and Optimal Parameter Selection in Premature Ventricular Contraction Classification. In: *Computers in Cardiology* 31 (2004), S. 357–360
- [JCD01] JEKOVA, I. ; CANSELL, A. ; DOTSINSKI, I.: Noise sensitivity of three surface ECG fibrillation detection algorithms. In: *Physiological Measurement* 22 (2001), S. 287–297
- [JCF97] JULIAN, D. G. ; CAMM, A. J. ; FRANGIN, G.: Randomised trial of effect of amiodarone on mortality in patients with left-ventricular dysfunction after recent myocardial infarction: EMIAT. In: *Lancet* 349 (1997), S. 667–674
- [Jek00] JEKOVA, I.: Comparison of five algorithms for the detection of ventricular fibrillation from the surface ECG. In: *Physiological Measurement* 21 (2000), S. 429–439
- [JK04] JEKOVA, I. ; KRASTEVA, V.: Real time detection of ventricular fibrillation and tachycardia. In: *Physiological Measurement* 25 (2004), S. 1167–1178
- [Jos91] JOS, W.: The diagnostic performance of computer programs for the interpretation of electrocardiograms. In: *The New England Journal of Medicine* 25 (1991), Nr. 325, S. 1767–1773
- [JR93] JANG R., Shing J.: ANFIS: Adaptive-Network-Based Fuzzy Inference Systems. In: *IEEE Transactions on Systems, Man and Cybernetics* 23 (1993), Nr. 3, S. 665–685
- [KBB<sup>+</sup>97] KERBER, R. E. ; BECKER, L. B. ; BOURLAND, J. D. ; CUMMINS, R. O. ; HALLSTROM, A. P. ; MICHOS, M. B. ; NICHOL, G. ; ORNATO, J. P. ; THIES, W. H. ; WHITE, R. D. ; ZUCKERMAN, B. D.: Automatic external defibrillators for public access defibrillation: recommendations for specifying and reporting arrhythmia analysis algorithm performance, incorporating new waveforms, and enhancing safety. A statement for health professionals from the American Heart Association Task Force on Automatic External Defibrillation, Subcommittee on AED Safety and Efficacy. In: *Circulation* 95 (1997), Mar, Nr. 6, S. 1677–1682
- [KBK<sup>+</sup>01] KADISH, A.H. ; BUXTON, A.E. ; KENNEDY, H.L. ; KNIGHT, B.P. ; MASON, J.W. ; SCHUGER, C.D. ; TRACY, C.M.: ACC/AHA clinical competence statement on electrocardiography and ambulatory electrocardiography: a report of the American College of Cardiology/American Heart Association/American College

- of Physicians-American Society of Internal Medicine Task Force on Clinical Competence (ACC/AHA Committee to Develop a Clinical Competence Statement on Electrocardiography and Ambulatory Electrocardiography). In: *Journal of the American College of Cardiology* 38 (2001), Nr. 7, S. 2091–2100
- [KD78] KUO, S. ; DILLMAN, R.: Computer Detection of Ventricular Fibrillation. In: *IEEE Computer Society Press* (1978), S. 347–349
- [KFM05] KARILAINEN, A. ; FINNBERG, T. ; MÜLLER, J.: ECG Sensor Based on Impedance Loaded SAW Transponder. In: *Biomedizinische Technik* 50 (2005), Nr. 1, S. 433–434
- [KHO02] KÖHLER, B.-U. ; HENNIG, C. ; ORGLMEISTER, R.: The Principles of Software QRS Detection. In: *IEEE Engineering in Medicine and Biology Magazine* 21 (2002), Jan-Feb, Nr. 1, S. 42–57
- [KNB98] KUNDU, M. ; NASIPURI, M. ; BASU, D. K.: A Knowledge-Based Approach to ECG Interpretation Using Fuzzy Logic. In: *IEEE Transactions on Systems, Man and Cybernetics - Part B: Cybernetics* 28 (1998), Nr. 2, S. 237–243
- [KRW03] KONECNY, E. (Hrsg.) ; ROELCKE, V. (Hrsg.) ; WEISS, B. (Hrsg.): *Medizintechnik im 20. Jahrhundert: Mechanik - Elektrotechnik - Informationssysteme*. VDE Verlag, 2003
- [KS87] KASPAR, F. ; SCHUSTER, H. G.: Easily calculable measure for the complexity of spatiotemporal patterns. In: *Physical Review A* 36 (1987), Nr. 2, S. 842–848
- [Kun02] KUNZMANN, U.: *Verfahren zur Parameterextraktion aus dem EKG-Signal im Zeitbereich*, Universität Karlsruhe, Diplomarbeit, 2002
- [LCG+00] LAGERHOLM, M. ; C., Peterson ; G., Braccini ; EDENBRANDT, L. ; SÖRNMO, L.: Clustering ECG Complexes Using Hermite Functions and Self-Organizing Maps. In: *IEEE Transactions on Biomedical Engineering* 47 (2000), S. 838–848
- [LJYM96] LEE, J. ; JEONG, K. ; YOON, J. ; M., Lee: A simple real-time QRS detection algorithm. In: *Proceedings of the 18th International Conference of the IEEE Engineering in Medicine and Biology Society*, 1996, S. 1396–1398
- [LK83] LIGTENBERG, A. ; KUNT, J.: A Robust Digital QRS-Detection Algorithm for Arrhythmia Monitoring. In: *Computers and Biomedical Research* 16 (1983), S. 273–286
- [Lö199] LÖLLGEN, H.: Herzfrequenzvariabilität. In: *Deutsches Ärzteblatt* 96 (1999), Nr. Heft 31-32, S. A2029–2032

- [LOS03] LINH, T. H. ; OSOWSKI, S. ; STODOLSKI, M.: On-Line Heart Beat Recognition Using Hermite Polynomials and Neuro-Fuzzy Network. In: *IEEE Transactions on Instrumentation and Measurement* 52 (2003), Nr. 4, S. 1224–1231
- [LZT95] LI, C. ; ZHENG, C. ; TAI, C.: Detection of ECG Characteristic Points Using Wavelet Transforms. In: *IEEE Transactions on Biomedical Engineering* 42 (1995), Nr. 1, S. 21–29
- [Mal01] MALLAT, S.: *A wavelet tour of signal processing*. 2. Aufl. -. San Diego, San Francisco, New York, Boston, London, Sydney, Tokyo: Academic Press, 2001
- [MAO<sup>+</sup>04] MARTÍNEZ, J.P. ; ALMEIDA, R. ; OLMOS, S. ; ROCHA, A.P. ; LAGUNA, P.: A wavelet-based delineator: evaluation on standard databases. In: *IEEE Transactions on biomedical engineering* 51 (2004), S. 570–581
- [Mat00] MATHWORKS: *Fuzzy Logic Toolbox for Use with Matlab*. 2. Auflage. Mathwork, Inc., 2000
- [Mat05] MATHWORKS: *Homepage*. 2005. URL <http://www.mathworks.com>. – Zugriffsdatum 2005-08-27
- [Med06] MEDSET MEDIZINTECHNIK GMBH: *Homepage*. 2006. URL <http://www.medset.com/>. – Zugriffsdatum 2006-01-12
- [MFVC02] MORAES, J. ; FREITAS, M. ; VILANI, F. ; COSTA, E.: A QRS complex detection algorithm using electrocardiogram leads. In: *Computers in Cardiology* 29 (2002), S. 205–208
- [Mob05] MOBIHEALTH: *Innovative GPRS/UMTS mobile services for applications in healthcare*. 2005. URL <http://www.mobihealth.org/>. – Zugriffsdatum 2005-12-31
- [Moo05a] MOODY, G. B.: *WFDB Applications Guide*. Tenth Edition. Harvard-MIT Division of Health Sciences and Technology, 13.06. 2005
- [Moo05b] MOODY, G. B.: *WFDB Programmer's Guide*. Tenth Edition. Harvard-MIT Division of Health Sciences and Technology, 13.06. 2005
- [MP05] MALMIVUO, J. ; PLONSEY, R.: *Webseite*. 2005. URL <http://butler.cc.tut.fi/malmivuo/bem/bembook/index.htm>. – Zugriffsdatum 2005-04-17. – Web-version of the book: Jaakko Malmivuo and Robert Plonsey: *Bioelectromagnetism - Principles and Applications of Bioelectric and Biomagnetic Fields*, Oxford University Press, New York, 1995
- [MPJ<sup>+</sup>97] MILLET, J. ; PÉREZ, M. A. ; JOSEPH, G. ; MOCHOLÍ, A. ; CHORRO, J.: Previous Identification of QRS Onset and Offset is not Essential for Classifying QRS Complexes in a Single Lead. In: *Computers in Cardiology* 24 (1997), S. 299–302

- [MRLSM<sup>+</sup>98] MILLET-ROIG, J. ; LOPEZ-SORIANO, J.J. ; MOCHOLI, A. ; RUIZ-GRANELL, R. ; CHORRO, F.J.: Study of Frequency and Time Domain Parameters Extracted by Means of Wavelet Transform Applied to ECG to Distinguish between VF and other Arrhythmias. In: *Computers in Cardiology* 25 (1998), S. 17–20
- [MRRIVC99] MILLET-ROIG, J. ; RIETA-IBANEZ, J.J. ; VILANOVA, E. ; CHORRO, F.J.: Time-Frequency Analysis of a Single ECG to Discriminate between Ventricular Tachycardia and Ventricular Fibrillation. In: *Computers in Cardiology* 26 (1999), S. 711–714
- [MRVGC00] MILLET-ROIG, J. ; VENTURA-GALIANO, R. ; CHORRO-GASCÓ, F. J. ; CEBRIÁN, A.: Support Vector Machine for Arrhythmia Discrimination with Wavelet-Transform-Based Feature Selection. In: *Computers in Cardiology* 27 (2000), S. 407–410
- [MSD<sup>+</sup>98] MAGLAVERAS, N. ; STAMKOPOULOS, T. ; DIAMATARAS, K. ; PAPPAS, C. ; STRINTZIS, M.: ECG pattern recognition and classification using non-linear transformations and neural networks: A review. In: *International Journal of Medical Informatics* 52 (1998), S. 191–208
- [Mul82] MULTICENTER POSTINFARCTIONS RESEARCH GROUP: Risk stratification and survival after myocardial infarction. In: *New England Journal of Medicine* 306 (1982), S. 1065–1070
- [MyH05] MYHEART: *MyHeart Projekt - IST507816*. 2005. URL <http://www.hitech-projects.com/euprojects/myheart/>. – Zugriffsdatum 2005-12-31
- [NBB<sup>+</sup>88] NOLLE, F.M. ; BOWSER, R.W. ; BADURA, F.K. ; CATLETT, J.M. ; GUADAPATI, R.R. ; HEE, T.T. ; MOOSS, A.N. ; SKETCH, M.H.: Evaluation of a Frequency-Domain Algorithm to Detect Ventricular Fibrillation in the Surface Electrocardiogram. In: *Computers in Cardiology* (1988), S. 337–340
- [NK95] NAUCK, D. ; KRUSE, R.: NEFCLASS - A Neuro-Fuzzy Approach for the Classification of Data. In: *ACM Symposium on Applied Computing* (1995), S. 461–465
- [NK99] NAUCK, D. ; KRUSE, R.: Obtaining interpretable fuzzy classification rules from medical data. In: *Artificial Intelligence in Medicine* 16 (1999), S. 149–169
- [NNK99] NAUCK, D. ; NAUCK, U. ; KRUSE, R.: NEFCLASS for JAVA - New Learning Algorithms. In: *Proc. 18th Int. Conf. of the North American Fuzzy Information Processing Society (NAFIPS'99, New York, NY)* (1999), S. 472–476

- [Nov05] NOVACOR: *Event-Recorder R.Test Evolution 3*. 2005. URL <http://www.novacor.com>. – Zugriffsdatum 2005-08-05
- [OKGS04] OTTENBACHER, J. ; KUNZE, C. ; GROSSMANN, U. ; STORK, W.: Integration of a Bluetooth Based ECG System into Clothing. In: *8th International Symposium on Wearable Computers (ISWC)* 1 (2004), S. 186–187
- [OL00] OSOWSKI, S. ; LINH, T. H.: Fuzzy clustering neural network for classification of ECG beats. In: *IEEE* (2000), S. 26–30
- [OL01] OSOWSKI, S. ; LINH, T. H.: ECG Beat Recognition Using Fuzzy Hybrid Neural Network. In: *IEEE Transactions on Biomedical Engineering* 48 (2001), Nr. 11, S. 1265
- [PCV95] POLI, R. ; CAGNONI, S. ; VALLI, G.: Genetic design of optimum linear and nonlinear QRS detectors. In: *IEEE Transactions on Biomedical Engineering* 42 (1995), Nr. 11, S. 1137–1141
- [Per05] PERPEET, D.: *Verbesserung eines QRS-Detektionsverfahrens unter Java*. Institut für Technik der Informationsverarbeitung, Universität Karlsruhe, Studienarbeit, 2005
- [Phi04a] PHILIPS MEDICAL SYSTEMS: *Philips Telemetry System*. 2004. URL [http://www.medical.philips.com/main/products/patient\\_monitoring/assets/docs/Telemetry\\_nonUS\\_11.pdf](http://www.medical.philips.com/main/products/patient_monitoring/assets/docs/Telemetry_nonUS_11.pdf). – Zugriffsdatum 2005-12-09
- [Phi04b] PHILIPS MEDICAL SYSTEMS: *ST/AR ST segment and arrhythmia monitoring*. 2004. URL [http://www.medical.philips.com/main/products/patient\\_monitoring/assets/docs/ST\\_AR\\_20June2004\\_brochure.pdf](http://www.medical.philips.com/main/products/patient_monitoring/assets/docs/ST_AR_20June2004_brochure.pdf). – Zugriffsdatum 2005-12-09
- [Phy04] PHYSIONET: *The Creighton University Ventricular Tachyarrhythmia Database*. 2004. URL <http://www.physionet.org/physiobank/database/cudb/>. – Zugriffsdatum 2004-09-14
- [Phy05a] PHYSIONET: *MIT-BIH Arrhythmia Database*. 2005. URL <http://www.physionet.org/physiobank/database/mitdb/>. – Zugriffsdatum 2005-06-20
- [Phy05b] PHYSIONET: *The MIT-BIH Noise Stress Test Database*. 2005. URL <http://www.physionet.org/physiobank/database/nstdb/>. – Zugriffsdatum 2005-08-08
- [Phy05c] PHYSIONET: *Research resource for complex physiologic signals*. 2005. URL <http://www.physionet.org>. – Zugriffsdatum 2005-07-29

- [Phy05d]      PHYSIOTOOLS: *Open source software for biomedical science and engineering*. 2005. URL <http://www.physionet.org/physiotools/>. – Zugriffsdatum 2005-06-13
- [Pie00]      PIETZSCH, J.B.: *Rahmenbedingungen und Erfolgsfaktoren telemedizinischer Innovationen*, Universität Karlsruhe, Diplomarbeit, 2000
- [psc98]      *Psyhyrembel Klinisches Wörterbuch*. 258. Aufl. -. Berlin: de Gruyter, 1998
- [PT85]      PAN, J. ; TOMPKINS, W. J.: A Real-Time QRS Detection Algorithm. In: *IEEE Transactions on Biomedical Engineering* 32 (1985), Nr. 3, S. 230–235
- [Rak05]      RAKOTOMALALA, R.: TANAGRA: a free software for research and academic purposes. In: *Proceedings of EGC'2005, RNTI-E-3* Bd. 2, 2005, S. 697–702
- [RGMG03]      REICHMANN, C. ; GRAF, P. ; MÜLLER-GLASER, K. D.: Ein durchgängiger Ansatz vom Systementwurf zur Codegeneration auf Basis eines objektorientierten Modells für eingebettete heterogene Systeme. In: *atp Automatisierungstechnische Praxis* 45 (2003), S. 45–52
- [RGnI05]      RODRÍGUEZ, J. ; GOÑI, A. ; ILLARRAMENDI, A.: Real-Time Classification of ECGs on a PDA. In: *IEEE Transactions on Information Technology in Biomedicine* 9 (2005), Nr. 1, S. 23–34
- [RSBL02]      REUCHLEIN, H. ; SANDNER, S. ; BERNLOCHNER, J. C. ; LEHNER, R.: Der Schock für's Leben: Frühdefibrillation durch Ersthelfer und Betriebsanitäter. In: *Biomedizinische Technik* 47 (2002), Nr. 9-10, S. 215–218
- [Sal99]      SALTYKOVA, M. M.: Physiological Data Analysis and Classification Using Local Assessment of Distribution Density (by the Example of ECG Data). In: *Human Physiology* 25 (1999), S. 239–244
- [Sch05]      SCHILLER AG: *Teletransmitter MT120*. 2005. URL <http://www.schiller-ag.ch>. – Zugriffsdatum 2005-08-05
- [SCK05]      SUN, Y. ; CHAN, K. L. ; KRISHNAN, S. M.: Life-threatening ventricular arrhythmia recognition by nonlinear descriptor. In: *Biomed Eng Online* 4 (2005), Jan, Nr. 1, S. 6
- [SD91]      SILBERNAGL, S. ; DESPOPOULOS, A.: *Taschenatlas der Physiologie*. 4. Aufl. -. Stuttgart; New York: Thieme ; München: Dt. Taschenbuch Verl., 1991

- [SHHK98] SUGIURA, T. ; HIRATA, H. ; HARADA, Y. ; KAZUI, T.: Automatic Discrimination of Arrhythmia Waveforms Using Fuzzy Logic. In: *Proceedings of the 20th Annual International Conference of the IEEE Engineering in Medicine and Biology Society* Bd. 20, 1998, S. 108–111
- [SKO99] SEKIGUCHI, K. ; KANDA, T. ; OSADA, M. et a.: Comparative accuracy of automated computer analysis versus physicians in training in the interpretation of electrocardiograms. In: *J Med* 30 (1999), S. 75–81
- [SMB<sup>+</sup>99] SCHMIDT, G. ; MALIK, M. ; BARTHEL, P. ; SCHNEIDER, R. ; ULM, K. ; ROLNITZKY, L. ; CAMM, A. J. ; BIGGER, J. T. j. ; SCHÖMIG, A.: Heart-rate turbulence after ventricular premature beats as a predictor of mortality after acute myocardial infarction. In: *Lancet* 353 (1999), Nr. 9162, S. 1390–1396
- [So97] SO, H.H.: Development of QRS Detection methods for real-time ambulatory cardiac monitor. In: *Proceedings-19th International Conference EMBS* (1997), S. 289–293
- [Som02] SOMMERMEYER, D.: *Gezieltes, wissensoptimiertes Lernen für Neuro-Fuzzy-Systeme*, Universität Karlsruhe, Institut für Biomedizinische Technik, Studienarbeit, 2002
- [SS90] SUPPAPPOLA, S. ; SUN, Y.: Nonlinear Transforms in QRS Detection Algorithms. In: *Annual International Conference of the IEEE Engineering in Medicine and Biology Society* 12 (1990), Nr. 2, S. 815–816
- [SS91] SUPPAPPOLA, S. ; SUN, Y.: A Comparison of Three QRS Detection Algorithms Using the AHA ECG Database. In: *Annual International Conference of the IEEE Engineering in Medicine and Biology Society* 13 (1991), Nr. 2, S. 586–537
- [SS94] SUPPAPPOLA, S. ; SUN, Y.: Nonlinear Transforms of ECG Signals for Digital QRS Detection. A Quantitative Analysis. In: *IEEE Transactions on Biomedical Engineering* 41 (1994), Nr. 4, S. 397–400
- [SSB03] SOMMERMEYER, D. ; SCHWAIBOLD, M. ; BOLZ, A.: Gezieltes, wissensoptimiertes Lernen für Neuro-Fuzzy-Systeme. In: *Biomedizinische Technik* 48 (2003), Nr. 1, S. 262–263
- [SSC97] SAXENA, S. C. ; SHARMA, A. ; CHAUDHARY, S. C.: Data compression and feature extraction of ECG signals. In: *International Journal of System Science* 28 (1997), Nr. 5, S. 483–498
- [ST95] SCHMIDT, R. F. ; THEWS, G.: *Physiologie des Menschen*. 26. Aufl. Berlin;Heidelberg;New York: Springer, 1995
- [Sta06] STATISTISCHES BUNDESAMT DEUTSCHLAND: *Gesundheitswesen - Gestorbene nach Todesursachen*. 2006. URL <http://www.destatis.de/>. – Zugriffsdatum 2006-02-19

- [SWH<sup>+</sup>05] SCHÄFER, D. ; VON WAGNER, G. ; HEY, S. ; MÜLLER-GLASER, K.-D. ; MEFFERT, B.: Comparative Study of Different Methods and Constraints in Heart Rate Variability Spectrum Estimation. In: *Bio-medizinische Technik* 50 (2005), Nr. Suppl. 1, S. 143–44
- [Tas96] TASK FORCE OF THE EUROPEAN SOCIETY OF CARDIOLOGY AND THE NORTH AMERICAN SOCIETY OF PACING AND ELECTROPHYSIOLOGY: Heart rate variability. Standards of measurement, physiological interpretation, and clinical use. In: *European Heart Journal* 17 (1996), S. 354–381
- [TDE<sup>+</sup>92] TADDEI, A. ; DISTANTE, G. ; EMDIN, M. ; PISANI, P. ; MOODY, G. B. ; ZEELENBERG, C. ; MARCHESI, C.: The European ST-T database: standard for evaluating systems for the analysis of ST-T changes in ambulatory electrocardiography. In: *Eur Heart J* 13 (1992), Sep, Nr. 9, S. 1164–72
- [TeD05a] TEDIANET: *Förderprojekt „Telemetrisches Diagnose-Netzwerk“ des Bundesministeriums für Bildung und Forschung*. 2005. URL <http://www.tedianet.org>. – Zugriffsdatum 2005-08-13
- [TeD05b] TEDIANET: *Förderprojekt „Telemetrisches Diagnose-Netzwerk“ des Bundesministeriums für Bildung und Forschung, Teilprojekt: Früherkennung kardialer Störungen*. 2005. URL <http://www.tedianet.org>. – Zugriffsdatum 2005-08-10
- [TT97] TIAN, L. ; TOMPKINS, W. J.: Time Domain Based Algorithm for Detection of Ventricular Fibrillation. In: *Proceedings - 19th International Conference IEEE/EMBS*, 1997, S. 374–377
- [TWT84] THAKOR, N.V. ; WEBSTER, J. G. ; TOMPKINS, W. J.: Estimation of QRS Complex Power Spectra for Design of a QRS Filter. In: *IEEE Transactions on Biomedical Engineering* 31 (1984), November, Nr. 11, S. 702–705
- [TZP90] THAKOR, N.V. ; ZHU, Y.i-Sh. ; PAN, K.-Y.: Ventricular Tachycardia and Fibrillation Detection by a Sequential Hypothesis Testing Algorithm. In: *IEEE Transactions on Biomedical Engineering* 37 (1990), September, Nr. 9, S. 837–843
- [VI05] VDI/VDE-IT: *MST-Online*. 2005. URL <http://www.mst-online.de>. – Zugriffsdatum 2005-12-31
- [Vit05a] VITAPHONE: *Vitaphone 2300 HerzHandy*. 2005. URL <http://www.vitaphone.de/de/kontrolle/vitaphone2300/>. – Zugriffsdatum 2005-08-05
- [Vit05b] VITAPHONE: *Vitaphone Loop 3300 BT*. 2005. URL <http://www.vitaphone.de/de/kontrolle/vitaphone3300bt/>. – Zugriffsdatum 2005-08-11

- [Wil06] WILHELM-SCHICKARD-INSTITUTE FOR COMPUTER SCIENCE UNIVERSITÄT TÜBINGEN: *JavaNNS*. 2006. URL [http://www-ra.informatik.uni-tuebingen.de/software/JavaNNS/welcome\\_e.html](http://www-ra.informatik.uni-tuebingen.de/software/JavaNNS/welcome_e.html). – Zugriffsdatum 2006-02-22
- [WRF03] WAIBEL, A. ; RODE, J. ; FORNEFETT, M.: Internet-Produktrecherche über Tele-EKG-Event-Rekorder / Medset Medizintechnik GmbH. 2003. – Forschungsbericht
- [WSB89] WRUBLEWSKI, T. A. ; SUN, Y. ; BEYER, J. A.: Real-Time Early Detection of R Waves of ECG Signals. In: *Annual International Conference of the IEEE Engineering in Medicine and Biology Society* (1989), S. 38–39
- [WSMG03] VON WAGNER, G. ; STORK, W. ; MÜLLER-GLASER, K.-D.: Model-Based Evaluation of Different QRS Detection Algorithms for Use in Mobile Systems. In: *Biomedizinische Technik* 48 (2003), S. 210–211
- [WTA97] WIEBEN, O. ; TOMPKINS, W. J. ; AFONSO, V. X.: Classification of PVCs with a fuzzy logic system. In: *Proceedings of the 19th International Conference of the IEEE Engineering in Medicine and Biology Society* 1 (1997), S. 65–68
- [WVHS78] WOLF, M. M. ; VARIGOS, G. A. ; HUNT, D. ; SLOMAN, J. G.: Sinus arrhythmia in acute myocardial infarction. In: *Med J Australia* 2 (1978), S. 52–53
- [WZTX01] WANG, Y. ; ZHU, Y.-S. ; THAKOR, N. V. ; XU, Y.-H.: A Short-Time Multifractal Approach for Arrhythmia Detection Based on Fuzzy Neural Network. In: *IEEE Transactions on Biomedical Engineering* 48 (2001), Nr. 9, S. 989–995
- [XTRA98] XUE, Q. ; TAHA, B. ; REDDY, S. ; AUFDERHEIDE, T.: An Adaptive Fuzzy Model for ECG Interpretation. In: *Proceedings of the 20th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 1998, S. 131–134
- [Zad65] ZADEH, L. A.: Fuzzy Sets. In: *Information and Control* 8 (1965), S. 338–353
- [Zho05] ZHOU, L.: *Umsetzung von EKG-Klassifikationsverfahren auf einer mobilen Plattform*, Institut für Technik der Informationsverarbeitung, Universität Karlsruhe, Diplomarbeit, 2005
- [ZJ98] ZONG, W. ; JIANG, D.: Automated ECG Rhythm Analysis Using Fuzzy Reasoning. In: *Computers in Cardiology* 25 (1998), S. 69–72

- [ZLRT98] ZAKHARIAN, S. ; LADEWIG-RIEBLER, P. ; THOER, S.: *Neuronale Netze für Ingenieure: Arbeits- und Übungsbuch für regelungstechnische Anwendungen*. Vieweg, 1998
- [ZZTW99] ZHANG, X.-Sh. ; ZHU, Y.-Sh. ; THAKOR, N. V. ; WANG, Z.-Z.: Detecting Ventricular Tachycardia and Fibrillation by Complexity Measure. In: *IEEE Transactions on Biomedical Engineering* 46 (1999), May, Nr. 5, S. 548–555



# Danksagungen

Diese Arbeit wurde am Forschungszentrum Informatik an der Universität Karlsruhe (FZI) im Forschungsbereich Medizinische Informationstechnik durchgeführt.

Mein besonderer Dank gilt Herrn Prof. Dr.-Ing. K. D. Müller-Glaser für die hervorragenden Arbeitsbedingungen und das große Interesse, das er dieser Arbeit entgegen brachte.

Frau Prof. Dr.-Ing. B. Meffert danke ich herzlich für die Übernahme des Koreferates und die wertvollen inhaltlichen Rückmeldungen.

Einen herzlichen Dank an Herr Dr. W. Stork und Herr Dr. S. Hey für ihre wertvollen Beiträge und die stetige Diskussionsbereitschaft.

Allen Mitarbeitern des Forschungsbereichs Medizinische Informationstechnik am FZI und der Arbeitsgruppe Mikrosystemtechnik am Institut für Technik der Informationsverarbeitung (ITIV) der Universität Karlsruhe danke ich äußerst herzlich für die kollegiale Zusammenarbeit und viele Stunden interessanter fachlicher Diskussionen, die zum Gelingen dieser Arbeit beigetragen haben.

Dank auch an Herrn Dr. rer. nat. M. Fornefett für die gute Zusammenarbeit im Projekt TeDiaNet, in dem wesentliche Teile dieser Arbeit entstanden sind.

Frau E. Mainz danke ich für ihre Mitarbeit bei der Durchsicht des Manuskripts und ihre tägliche Unterstützung.

Diese Arbeit wäre ohne den großen Rückhalt, den ich durch meine Familie erfahren durfte, nicht möglich gewesen. Meinen Eltern danke ich für die Möglichkeit, mein Studium als Voraussetzung für die vorliegende Arbeit nach meinen Gesichtspunkten zu gestalten. Ein besonders herzlicher Dank gilt meiner Frau Christine für die stetige Unterstützung.



# Lebenslauf

- 17.08.1971 geboren in Heilbronn am Neckar
- 1978-1982 Besuch der Johann-Dietz-Grundschule in Ellhofen
- 1982-1991 Besuch des Justinus-Kerner-Gymnasiums in Weinsberg
- 1991-1992 Zivildienst beim Roten Kreuz, Kreisverband Heilbronn
- 1992-1993 Mitarbeit im Rettungsdienst beim Roten Kreuz, Kreisverband Heilbronn
- 1993-2000 Studium der Elektrotechnik an der Universität Karlsruhe (TH),  
Fachrichtung Biomedizinische Technik
- 2000-2006 Wissenschaftlicher Mitarbeiter im Forschungszentrum Informatik  
an der Universität Karlsruhe (FZI), Forschungsbereich  
Medizinische Informationstechnik