

Verbesserung der automatischen EKG-Analyse durch Hinzunahme von Kontextinformationen

Zur Erlangung des akademischen Grades eines

DOKTOR-INGENIEURS

von der Fakultät für
Elektrotechnik und Informationstechnik
des Karlsruher Instituts für Technologie (KIT)
genehmigte

DISSERTATION

von

Dipl.-Ing. Malte Kirst
geb. in Freiburg im Breisgau

Tag der mündlichen Prüfung: 23. Januar 2012
Hauptreferent: Prof. Dr. rer. nat. Wilhelm Stork
Korreferent: Prof. Dr. med. Axel Bauer

Danksagung

Diese Dissertation entstand während meiner Zeit als wissenschaftlicher Mitarbeiter am FZI Forschungszentrum Informatik. Für die Möglichkeit der Promotion bedanke ich mich bei meinem Doktorvater Prof. Dr. rer. nat. Wilhelm Stork, der nicht nur mit gutem Rat zur Seite stand, sondern mir auch die Freiräume für ein selbstständiges Arbeiten verschaffte.

Prof. Dr. med. Axel Bauer danke ich für die Übernahme des Korreferats sowie für die wertvollen Diskussionen über medizinische Aspekte der Arbeit. Seiner Arbeitsgruppe möchte ich für die Unterstützung bei der Aufzeichnung physiologischer Daten, die einem Teil dieser Arbeit zu Grunde liegen, einen Dank aussprechen.

Meinen Kollegen am FZI und innerhalb der Arbeitsgruppe danke ich für die vielen Fachgespräche und Ratschläge, dies gilt insbesondere für Jörg, Stefan, Silvo, Lu und Jürgen. Ohne ihre Unterstützung hätten viele Grundlagen für diese Arbeit gefehlt. Ebenso möchte ich den von mir betreuten Studierenden danken, die zu dieser Arbeit beigetragen haben. Bei Stephan und Chris bedanke ich mich für das Rücken freihalten – nicht nur während der heißen Phase des Zusammenschreibens. Bei Nora, Kerstin, Kristina und meinem Vater für das Korrekturlesen.

Ein ganz besonderer Dank gilt meiner Frau Claudia, die mich in meiner Arbeit immer unterstützt hat. Die vielen Stunden, an denen wir gemeinsam an unseren Doktorarbeiten geschrieben haben, werde ich nicht vergessen.

Karlsruhe, den 6. Januar 2013

Inhaltsverzeichnis

1	Einleitung	1
1.1	Motivation	1
1.2	Eigener Beitrag	3
1.3	Gliederung dieser Arbeit	5
2	Medizinische und technische Grundlagen	7
2.1	Medizinische Grundlagen	7
2.1.1	Anatomie und Physiologie des Herzens	7
2.1.2	Herzrhythmusstörungen	9
2.1.3	Gangphysiologie	10
2.1.4	Eigenschaften der Haut	11
2.2	Messung physiologischer Signale	14
2.2.1	EKG-Ableitungen	14
2.2.2	Elektroden für die EKG-Messung	17
2.2.3	Artefakte im EKG	19
2.2.4	Anwendungsszenarien	23
2.2.5	Bewegungserfassung	25
2.2.6	Impedanzmessung	25
2.3	Mathematische Grundlagen	26
2.3.1	Adaptive Filter	27
2.3.2	Bewertung von Analysealgorithmen	29
3	Telemedizin und EKG-Monitoring	33
3.1	Telemedizin	33
3.1.1	Definition und Begriffe	33
3.1.2	Telemedizin in Deutschland	34
3.1.3	Grenzen der Telemedizin	35
3.2	EKG-Analyse	36
3.2.1	QRS-Erkennung	36

3.2.2	Kanalentscheidung	37
3.2.3	Schlagklassifikation	38
3.2.4	Rhythmusanalyse	38
3.2.5	Zusammenfassung	40
3.3	Artefaktbehandlung	40
3.3.1	Artefakterkennung	41
3.3.2	Artefaktunterdrückung	43
3.3.3	Zusammenfassung	47
3.4	Bewegungserkennung	49
3.4.1	Aktivitätserkennung	49
3.4.2	Energieumsatzschätzung	50
3.4.3	Sturzerkennung	50
3.4.4	EKG im Aktivitätskontext	51
3.4.5	Zusammenfassung	51
3.5	Geräte und deren Anwendungsszenarien	52
3.5.1	Medizinprodukte	52
3.5.2	Studiengeräte	55
4	Framework zur Entwicklung von Analysealgorithmen	57
4.1	Systemkonzept	57
4.1.1	Problemstellung und Ansatz	58
4.1.2	Auswahl der Kontextsignale	60
4.1.3	Entwicklungswerkzeuge und Werkzeugketten	66
4.1.4	Spezifikation eines universellen Datenformats	68
4.2	Unisens-Datenformat	69
4.2.1	Datenformatspezifikation	69
4.2.2	EKG-Editor	73
4.2.3	UnisensViewer	79
4.2.4	Datenbankanbindung	83
4.3	EKG-Datenbanken	88
4.3.1	ITIV_KFA	88
4.3.2	Holtervergleich	89
4.3.3	careMon	90
5	Artefaktbehandlung mit Hilfe von Kontextsignalen	93
5.1	Ziele der Artefaktbehandlung	93

5.2	Artefakterkennung	94
5.2.1	Artefaktdefinition	95
5.2.2	Artefaktschätzung mit adaptivem Filter	97
5.2.3	Artefakterkennung aus dem EKG	101
5.2.4	Zusammenfassung	104
5.3	Artefaktreduktion	105
5.3.1	Artefaktreduktion ohne Kontextsignale	105
5.3.2	Adaptive Störsignalunterdrückung	108
5.3.3	Zeit- und frequenzselektive Artefaktreduktion	112
6	Kontextsensitive Signalanalyse	121
6.1	Aktivitätsmonitoring	121
6.1.1	Ziele des Aktivitätsmonitoring	121
6.1.2	Ruheerkennung	122
6.1.3	Aktivitätserkennung	128
6.1.4	Eventerkennung	135
6.2	EKG-Analyse	139
6.2.1	Artefaktinformationen für die QRS-Erkennung	140
6.2.2	Bewegungsinformationen für die VT/VF-Erkennung	142
6.3	Kontextbezogene Interpretation	146
6.3.1	Autoregulation der Herzfrequenz nach dem Aufstehen	146
6.3.2	Rhythmusstörungen im Aktivitätskontext	148
6.3.3	Chronotrope Inkompetenz	149
6.3.4	Stürze und Synkopen	150
6.3.5	Ruhephasen und Ruhepuls	151
6.4	Berichte und Darstellungsformen	152
6.4.1	Analyse-Framework	153
6.4.2	Berichte	155
6.4.3	Softwaregestützte Darstellung	159
7	Diskussion der Ergebnisse	163
7.1	Framework	163
7.2	Artefaktbehandlung	164
7.3	Kontextsensitive Signalanalyse	165
8	Zusammenfassung und Ausblick	167
8.1	Zusammenfassung	167

8.2	Ausblick	169
	Literaturverzeichnis	171
	Eigene Veröffentlichungen	185
	Betreute studentische Arbeiten	189
	Abbildungsverzeichnis	191
	Tabellenverzeichnis	197
	Abkürzungsverzeichnis	199
A	Unisens 2.0	203
	A.1 Anforderungen	203
	A.2 Begriffe	205

1 Einleitung

Seit der Einführung des Langzeit-EKG durch Norman Holter [Hol61] vor etwa 50 Jahren hat sich die Technik stetig weiter entwickelt. Wog das erste kommerziell erhältliche Gerät bei entsprechender Größe noch 1 kg, haben moderne Systeme die Größe einer Streichholzschachtel und können nahezu unsichtbar unter der Haut implantiert werden. Auch bei der Aufnahmedauer sind die Unterschiede gravierend: Eine Kassette für Holters „Elektrocardiocorder“ reichte für zehn Stunden Aufnahme, die Batterie versorgte das Gerät bis zu 100 Stunden mit Energie. Heutige EKG-Geräte können problemlos das EKG von mehreren Wochen speichern. Dank dieser Eigenschaften konnte sich das Langzeit-EKG zu einem unverzichtbaren Gerät für die Diagnostik und Therapiekontrolle von Herzrhythmusstörungen entwickeln [Gri97].

Zeichnet man lange EKG-Sequenzen auf, müssen diese auch analysiert und befundet werden. Die automatische EKG-Analyse bildet aber einen ernstzunehmenden Engpass: Der AVSEP-Arrhythmiagraph von Norman Holter konnte mit Hilfe audio-visueller EKG-Darstellung das EKG in 60-facher Geschwindigkeit bearbeiten und auf Arrhythmien hinweisen. Heutzutage wird das EKG entweder online auf dem Gerät analysiert oder einer retrospektiven Analyse auf einem PC unterzogen. Dabei ist es wichtig, alle relevanten EKG-Passagen zu detektieren, ohne den Mediziner mit falschen Informationen zu überfluten. Mit steigender Aufnahmedauer und damit steigender Datenflut wird also die zuverlässige automatische EKG-Analyse immer relevanter und wird letztendlich über die Akzeptanz des 24/7-EKG-Monitorings entscheiden [Suc06].

1.1 Motivation

Telemedizin ist ein bereits in vielen Bereichen der klinischen Medizin erfolgreich eingesetztes Werkzeug [Mül09b]. Sie ist dabei als Ergänzung zur ärztlichen Behandlung anzusehen und bietet somit weitere Vorteile: Durch die bessere

Therapiekontrolle werden Anzahl und Zeitpunkte der Klinikaufenthalte optimiert, dadurch entfallen Anfahrtswege und Wartezeiten beim Klinikbesuch. Dies spart Kosten im Gesundheitswesen und erhöht die Lebensqualität von Patienten, die an telemedizinischen Programmen teilnehmen [vW06].

Die demographische Entwicklung in den westlichen Industrieländern zeigt, wie wichtig neue Wege in der Gesundheitsbranche sein werden: Schon heute sind Herz-Kreislauf-Erkrankungen die häufigste Todesursache in Deutschland (Abbildung 1.1), bis zum Jahr 2030 wird die Zahl der Herz-Kreislauf-bedingten Krankenhausaufenthalte um ein Drittel ansteigen [Spi09]. Mit Hilfe von neuen, telemedizinischen Versorgungskonzepten kann die Hospitalisierungsrate verringert werden.

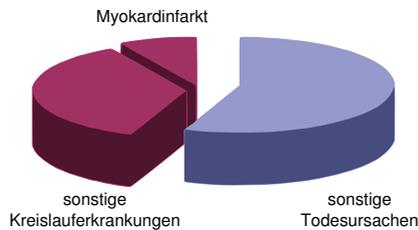


Abbildung 1.1: Herzkreislauferkrankungen sind die häufigste Todesursache in Deutschland [Sta06]

In der Kardiologie werden telemedizinische Dienste insbesondere für die Diagnostik und Überwachung von Herzrhythmusstörungen und zum Monitoring von Patienten mit chronischer Herzinsuffizienz oder mit Implantaten (Herzschrittmacher oder implantierbare Kardioverter/Defibrillatoren, ICD) eingesetzt. Für diese Aufgaben ist das Elektrokardiogramm die zentrale Untersuchungsmethode.

Mit dem angestrebten Langzeit-Monitoring über Tage, Wochen oder gar Monate wachsen die Anforderungen an die eingesetzten EKG-Geräte: Sie müssen in der Lage sein, das EKG über einen langen Zeitraum aufzuzeichnen, ohne den Patienten maßgeblich zu beeinträchtigen. In telemedizinischen Szenarien muss das aufgezeichnete EKG darüber hinaus bereits auf dem Gerät zuverlässig analysiert werden, um bei Auffälligkeiten den behandelnden Arzt automatisch benachrichtigen zu können. Die EKG-Aufnahme eines reinen Rekorders, wie er z. B. zur Synkopenerkennung eingesetzt werden kann, kann retrospektiv auf einem PC ausgewertet werden. Auch in diesem Fall ist eine zuverlässige, automatische

EKG-Analyse der großen Datenmengen notwendig, um die Finanzierbarkeit bei gleicher oder besserer Qualität zu gewährleisten. Die Gerätehersteller versuchen diesen Anforderungen gerecht zu werden, jedoch hat sich bislang noch keine Geräteklasse für die Aufnahme eines 24/7-EKGs durchgesetzt.

Die verschiedenen Faktoren, die die automatische EKG-Analyse beeinflussen, sind in Abbildung 1.2 als Tag-Cloud dargestellt. Sie lassen sich in zwei Gruppen einteilen: Hautdehnung, Elektrodenbewegungen und externe Störquellen, wie z. B. 50 Hz-Einkopplungen, sorgen für Artefakte, die die Signalanalyse erschweren oder gar unmöglich machen. Diese Signalanteile sind durch das Aufnahmesystem verursacht. Körperliche Aktivität, organische Veränderungen, Körperlage, Emotionen und Medikamente beeinflussen den Herzrhythmus und die Morphologie des EKGs. Wenn eine EKG-Veränderung vorliegt, kann nicht immer gesagt werden, welche Ursache zu Grunde liegt.



Abbildung 1.2: Änderungen der Herzaktivität (blau) und des Aufnahmesystems (grau) beeinflussen die automatische EKG-Analyse

Mit der Aufzeichnung von Kontextsignalen wie Aktivitätsdaten und der Elektrode-Haut-Impedanz können viele der zuvor genannten Quellen identifiziert werden. Auf diese Weise wird der Fokus neben emotional und medikamentös bedingten EKG-Veränderungen auf die organischen Ursachen (wie z. B. Durchblutungsstörungen) gelenkt, die für die Befundung von besonderer Bedeutung sind.

1.2 Eigener Beitrag

Das Ziel dieser Arbeit ist die Untersuchung, inwieweit sich die automatische Analyse mobil aufgezeichneter EKG-Signale verbessern lässt, wenn – neben dem

EKG – zusätzliche Informationen in die Analyse mit einfließen. Im Fokus stehen hierbei sowohl konventionelle Holter- und Event-Rekorder als auch textilintegrierte Aufnahmesysteme, die für die 24/7-Anwendung im telemedizinischen Kontext bestimmt sind.

Um den Umgang mit sogenannten Multisensordaten zu erleichtern, die verschiedene Signale aus unterschiedlichen Quellen bzw. Sensoren enthalten, wurde ein eigenes, darauf abgestimmtes Datenformat spezifiziert. Darauf aufbauend wurde ein umfangreiches Framework für die Darstellung, Analyse und Bearbeitung von Datensätzen entwickelt.

Bei aktuellen Geräten zum Langzeit-EKG-Monitoring wird meist nur das reine EKG-Signal aufgezeichnet. Es ist keine Information darüber vorhanden, welchen Aktivitäten der Patient gerade nachgeht. Für die richtige Interpretation und Befundung eines EKGs ergeben sich aber genau daraus durchaus interessante Fragestellungen: Passt sich die Herzfrequenz der körperlichen Belastung an? Ändert sich die Herzfrequenz ohne körperliche Belastung? Gibt es einen Zusammenhang zwischen Herzrhythmusstörungen und körperlicher Aktivität?

Mit der parallelen Registrierung eines Aktivitätsprofils kann man auf diese Fragen Antworten geben. In dieser Arbeit soll gezeigt werden, wie man solche Aktivitäten aufzeichnen und auswerten kann. Darauf aufbauend soll der Bezug zwischen EKG und Aktivität hergestellt werden. Durch die Kombination von Bewegungs- und EKG-Informationen konnten neue Parameter für die EKG-Befundung gewonnen werden, die ein gewöhnliches Langzeit-EKG zur Zeit noch nicht bietet. Erstmals wird auch gezeigt, wie man diese Informationen sinnvoll darstellen kann, um die Befundung zu vereinfachen.

Bewegungsartefakte stellen eine große Schwierigkeit bei der automatischen Analyse von Langzeit-EKG-Aufnahmen dar: Damit Analysealgorithmen nicht zur Fehlklassifikation neigen, müssen solche Sequenzen im EKG automatisch erkannt und von der Analyse ausgeschlossen werden. Für diesen Zweck bieten sich Kontextinformationen an, die zusätzlich ausgewertet werden. Mit Hilfe von Beschleunigungssensoren kann die aktuelle Bewegung geschätzt werden und somit Hinweise auf evtl. vorhandene Bewegungsartefakte geben. Die Elektroden-Haut-Impedanz ist ein weiterer geeigneter Parameter zur Bestimmung der Signalqualität und kann sogar für das Herausrechnen von Störungen genutzt werden.

Diese Arbeit stellt neue Algorithmen zur Artefaktbehandlung mit Hilfe von aufgezeichneten Kontextinformationen vor und diskutiert die Grenzen von

bereits veröffentlichten Verfahren. Erstmals werden die Algorithmen auch bei 24/7-EKG-Aufnahmen eingesetzt, die mit praxistauglichen Aufnahmesystemen im Alltag erfasst wurden.

Die Dissertation von JÖRG OTTENBACHER bildete die Grundlage für diese Arbeit [Ott10]. Viele Untersuchungen in dieser Arbeit beziehen sich auf Messdaten, die mit dem von ihm entwickelten Messsystem aufgenommen worden sind. Auch der in seiner Arbeit beschriebene Algorithmus zur Artefakterkennung wird aufgegriffen und eingesetzt.

LUCIANA JATOBA hat sich in ihrer Dissertation primär mit der Bewegungsklassifizierung und Energieumsatzschätzung beschäftigt [Jat10]. In dieser Arbeit wird aus Effizienzgründen auf solch präzise Schätzungen verzichtet und statt dessen ein einfacherer Klassifikator vorgestellt, der dennoch alle notwendigen Informationen liefert, die für die erweiterte EKG-Analyse notwendig sind.

1.3 Gliederung dieser Arbeit

Diese Arbeit gliedert sich in zwei Teile: Der erste Teil mit den Kapiteln 1 bis 3 beinhaltet die Einleitung, beschreibt den Stand der Technik und die zum weiteren Verständnis notwendigen Grundlagen medizinischer, messtechnischer und mathematischer Art.

Der zweite Teil umfasst die eigenen Arbeiten und wird mit der Beschreibung des entwickelten Frameworks eingeleitet, welches die effektive Entwicklung von Algorithmen für Multisensorsignale erheblich vereinfacht (Kapitel 4). Kapitel 5 stellt die entwickelten Methoden zur Artefaktbehandlung vor. Hier werden die implementierten und getesteten Verfahren zur Artefakterkennung und Artefaktreduktion beschrieben und bewertet. Ein Schwerpunkt liegt stets auf der Verwendung von Kontextsignalen. Der Nutzen der kontextsensitiven EKG-Analyse ist in Kapitel 6 dargestellt. Grundlage bildet ein einfaches Aktivitätsmonitoring, um das aufgezeichnete EKG in den Bewegungskontext stellen zu können. Es wird beschrieben, wie die konventionelle EKG-Analyse sich auf die gemessenen Kontextsignale stützen kann, um verlässlichere Ergebnisse zu liefern. Ebenso wird die kontextsensitive Reportgenerierung vorgestellt.

Im Anschluss werden die erreichten Ziele noch einmal kapitelübergreifend kritisch bewertet (Kapitel 7). Die Arbeit schließt mit einer Zusammenfassung und einem Ausblick in Kapitel 8.

2 Medizinische und technische Grundlagen

In diesem Kapitel sollen die Grundlagen beschrieben werden, die zum Verständnis der Arbeit erforderlich sind. Der erste Teil beschreibt Anatomie und Physiologie des Herzens, der Haut und der Bewegung, im zweiten Teil werden technische Aspekte zur Messung von physiologischen Signalen behandelt, während sich der dritte Teil auf Berechnungs- und Filteralgorithmen in der Signalverarbeitung bezieht. Abschließend sollen Verfahren für die quantitative Beurteilung von Analysealgorithmen eingeführt werden.

2.1 Medizinische Grundlagen

Um die automatische Verarbeitung der biomedizinischen Signale besser verstehen zu können, soll kurz auf die anatomischen, physiologischen und pathophysiologischen Eigenschaften der Signalquellen eingegangen werden.

2.1.1 Anatomie und Physiologie des Herzens

Das menschliche Herz ist ein etwas über faustgroßes muskuläres Hohlorgan, dessen Aufgabe die Aufrechterhaltung der Blutzirkulation im Körper ist. Es liegt im Brustraum zwischen Brustbein und Wirbelsäule, die Herzspitze berührt die linke vordere Brustwand auf Höhe des 5. Zwischenrippenraums.

Im Gegensatz zu einem Skelettmuskel weist das Herz bezüglich der Erregungsleitung einige Besonderheiten auf: Die Weiterleitung der elektrischen Signale läuft nicht wie im Körper üblich über Nervenfasern, sondern über ein eigenes Erregungsleitungssystem (s. Abb. 2.1).

Angefangen beim Sinusknoten, der als Schrittmacher im rechten Atrium (Vorhof) selbständig depolarisiert und damit die elektrische Erregung des restlichen Myokards (Herzmuskel) auslöst, läuft das Signal über die Muskelzellen des Atriums weiter zum Atrioventrikularknoten (AV-Knoten), der Atrium und Ventrikel (Herzkammer) elektrisch verbindet. Über das His-Bündel und die Tawara-Schenkel wird das Signal in die Ventrikel geleitet, in denen ein verzweigtes Netz von Purkinje-Fasern eine rasche Signalausbreitung (bis zu 3,5 m/s) im Myokard garantiert. Die einzelnen Muskelzellen des Myokards sind untereinander mit sogenannten Gap Junctions verbunden, die eine elektrische Verbindung von Zelle zu Zelle ermöglichen.

Die Projektion der Erregungsleitung auf die Körperoberfläche lässt sich als Elektrokardiogramm (EKG) messen (s. Kap. 2.2.1). Abbildung 2.2 zeigt ein typisches EKG-Signal eines gesunden Menschen. Die einzelnen Wellen und Zacken des EKG werden mit Buchstaben gekennzeichnet: Die P-Welle entspricht dabei der elektrischen Erregung des Vorhofs, der QRS-Komplex (Q-Zacke, R-Zacke und S-Zacke) spiegelt die elektrische Erregung der Kammer wider. Auf Grund der Vielzahl der dort erregten Zellen ist die Amplitude deutlich größer als bei der Vorhoferregung. Die T-Welle kennzeichnet die Repolarisation des Kammermyokards. Die Repolarisation des Vorhofs (U-Welle) wird in den meisten Fällen von der T-Welle überlagert und ist nicht zu sehen.

Tieferegehende Beschreibungen zu Anatomie und Physiologie des Herzens finden sich in [Fal04] und [Sil03].

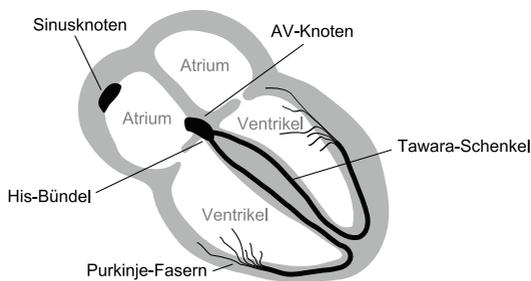


Abbildung 2.1: Erregungsleitungssystem des Herzens

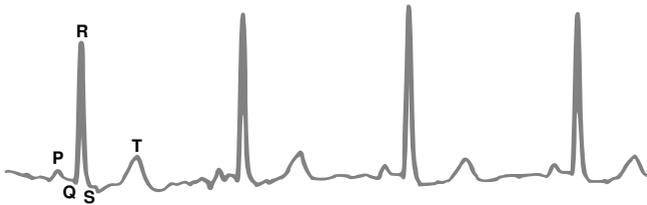


Abbildung 2.2: Bezeichnungen der Wellen und Zacken im EKG

2.1.2 Herzrhythmusstörungen

Das gesunde Herz scheint mit der Regelmäßigkeit eines Uhrwerks zu schlagen. Ist jedoch die Erregungsbildung oder -leitung des Herzens gestört, kommt es zu Herzrhythmusstörungen, die im EKG offensichtlich werden und die der Patient teilweise selbst spürt.

Grundsätzlich wird zwischen bradykarden und tachykarden Rhythmusstörungen unterschieden [DRK98]. Zu den *bradykarden Rhythmusstörungen* gehören alle Störungen, die zu einer Verringerung der Herzfrequenz führen. Die Ursache kann in einer Fehlfunktion des Sinusknotens oder einer verzögerten bzw. ganz blockierten Überleitung liegen. Für das EKG bedeutet dies, dass QRS-Komplexe verspätet auftreten oder „übersprungen“ werden (s. Abb. 2.3). Bei einer Herzfrequenz von unter 60 Schlägen pro Minute spricht man von einer Bradykardie.



Abbildung 2.3: Beispiele für bradykarde Herzrhythmusstörungen

Bei den *tachykarden Rhythmusstörungen* ist das Gegenteil der Fall: Einzelne verfrühte Schläge – sogenannte Extrasystolen – oder eine größere Anzahl von schnell aufeinander folgenden Kammeraktionen sorgen für eine plötzliche Erhöhung der Herzfrequenz. Ursache kann eine Fehlfunktion des Sinusknotens (Sick-Sinus-Syndrom) oder eines untergeordneten Erregungszentrums sein, genauso kann jedoch auch ein Kreisen der Erregung (Re-Entry) zu Grunde liegen. Die EKG-Morphologie der zusätzlichen Erregungen geben Hinweise auf ihren Entstehungsort. Ein Herzrhythmus mit über 100 Schlägen pro Minute wird

als Tachykardie bezeichnet. An dieser Stelle soll auf die weiterführende Literatur wie [Gon99, Sil03, Sch05] verwiesen werden. Einen Einblick in tachykarde Rhythmusstörungen im EKG bietet Abbildung 2.4.

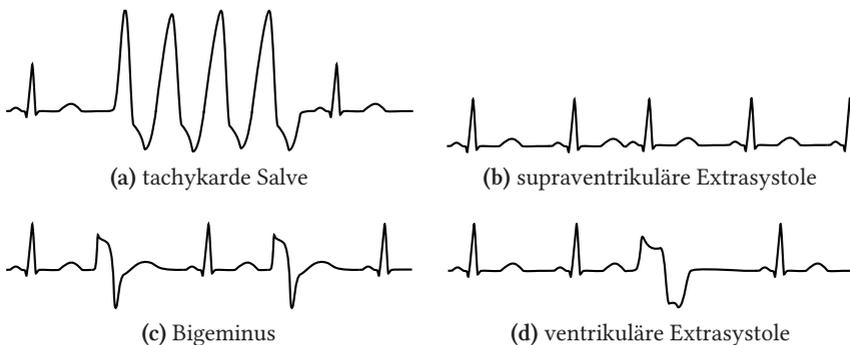


Abbildung 2.4: Beispiele für tachykarde Herzrhythmusstörungen

Wenn die tatsächliche Herzfrequenz den metabolisch-hämodynamischen Anforderungen einer Belastung nicht mehr folgen kann, spricht man von chronotroper Inkompetenz oder chronotroper Schwäche. Dies kann ein Hinweis auf eine gestörte autonome Funktion des Herzens sein, was insbesondere bei ansonsten symptomlosen Patienten ein schlechtes prognostisches Zeichen ist [Lö99].

2.1.3 Gangphysiologie

Man unterscheidet zwei Phasen des menschlichen Gangzyklus: die Standphase und die Schwungphase. Der Gangzyklus beginnt definitionsgemäß mit dem ersten Kontakt des Fußes (dies ist üblicherweise der Fersenaufprall) und damit der beginnenden Standphase. Es folgt die Gewichtsübernahme, bei der der Auftritt abgedämpft wird und das Gewicht des Körpers vom Referenzbein übernommen wird. Anschließend folgt der sogenannte Einbeinstand, der einen Großteil der Standphase ausmacht. Der Einbeinstand dauert vom Abheben des kontralateralen Beines bis zu dessen Aufsetzen an. Die anschließende Schwungphase wird durch den Vorschwung eingeleitet, während das Gewicht vom Referenzbein auf das kontralaterale Bein verlagert wird. Während der Schwungphase wird das Referenzbein vom Boden abgehoben, am kontralateralen Bein vorbeige-

führt, nach vorne gebracht und aufgesetzt. Die Schwungphase beendet mit dem Aufsetzen des Referenzbeins den Gangzyklus. [GN03]

Das zeitliche Verhältnis zwischen Stand- und Schwungphase beträgt im Durchschnitt 2:3. Wird der Gang beschleunigt, verkürzt sich die Standphase in Relation zur Schwungphase. Entfällt die doppelseitige Standphase mit der Gewichtsübernahme, spricht man von Laufen.

Bei älteren Menschen verändert sich der Bewegungsablauf beim Gehen leicht. Ab einem Alter von 60–70 Jahren verkürzen sich Schrittlänge und Gangzyklus und die Kadenz (Anzahl der Schritte pro Minute) nimmt ab. Gleichzeitig verbreitert sich die Spur, was wahrscheinlich einer erhöhten Gehsicherheit dient – ebenso wie die verlängerte doppelt unterstützte Standphase. Neben diesen Veränderungen können altersbedingte Erkrankungen wie z. B. Parkinson oder Arthritis hinzukommen, die ebenfalls den Bewegungsablauf verändern. Diese sind jedoch pathologisch, sodass nicht mehr vom normalen Gang gesprochen wird.

Der normale Gang kann durch Krankheiten, aber auch durch Emotionen beeinflusst werden. Ein depressiver Gang ist beispielsweise gedämpfter, weniger aufrecht und von geringerem Armschwung. Ebenso reduzieren sich die Kadenz und die Schrittlänge und damit die Gehgeschwindigkeit. Krankheiten können den Gang unspezifisch in vielfältiger Weise beeinflussen.

2.1.4 Eigenschaften der Haut

Die Haut bildet die äußere Grenzschicht des menschlichen Körpers und ist das Organ, an dem ein externes EKG abgeleitet wird. Im Inneren des Körpers liegt für die elektrischen Signale eine Ionenleitung in einem Elektrolyt vor, die äußeren Hautschichten sind für dieses jedoch (abgesehen von Schweißdrüsen) unpassierbar und müssen daher als elektrische Grenzschicht – gesondert vom Körper – betrachtet werden.

Der anatomische Aufbau der Haut gliedert sich nach [Fal04] in drei Schichten, die in Abbildung 2.5 veranschaulicht sind. Gegenübergestellt ist ihm ein mögliches elektrisches Ersatzschaltbild.¹ Im Folgenden wird auf Aufbau, Funktion und elektrische Eigenschaften der Haut eingegangen.

¹ In der Literatur findet man verschiedene elektrische Ersatzschaltbilder der Haut, die sich vor allem in ihrer Komplexität unterscheiden, siehe auch [Ham00b, Gri00, Bol02, MW85].

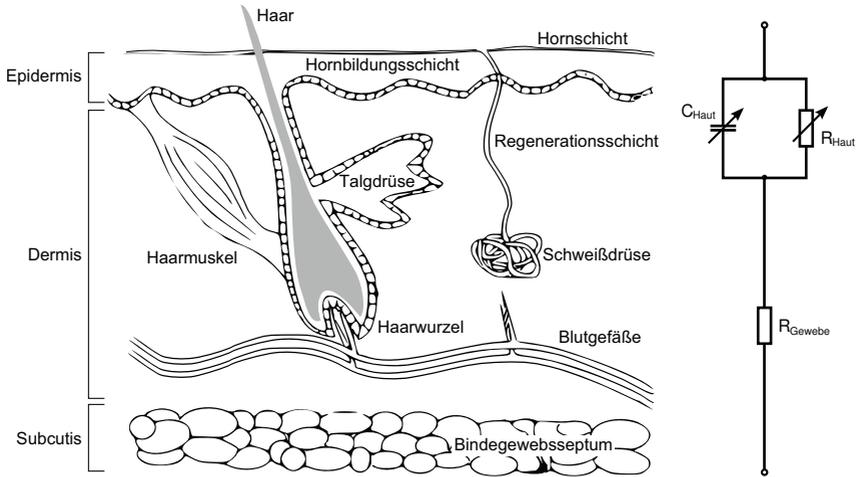


Abbildung 2.5: Aufbau der Haut und deren elektrisches Ersatzschaltbild

Epidermis Die äußerste Schicht ist die Oberhaut (Epidermis). Deren oberste Lage ist eine etwa 0,1 bis 1,5 mm dicke Schicht aus verhorntem Plattenepithel. Diese sogenannte Hornschicht (Stratum corneum) wird von der tiefer liegenden Regenerationsschicht gebildet. Deren Zellen teilen sich fortwährend, wandern nach außen und verhornen in der Hornbildungsschicht (Stratum granulosum), sodass die Hornschicht nach und nach ersetzt wird. Die Regenerationsschicht verhindert darüber hinaus das Eindringen von Wasser.

Da die Hornschicht keine Durchblutung aufweist, liegt hier auch kein Ladungstransport über Blutgefäße vor, was zu einem sehr hohen elektrischen Widerstand führt. Lediglich entlang von Haarwurzeln und Schweißdrüsen können Ladungen nach außen transportiert werden. Auf Grund des schichtartigen Aufbaus der Haut gibt es für den Ladungstransport relevante kapazitive Effekte. Diese Eigenschaften gehen als Parallelschaltung von Kondensator und Widerstand in das elektrische Ersatzschaltbild ein.

Dermis Die Lederhaut (Dermis oder auch Corium) bildet die mittlere Hautschicht. Sie enthält Blut- und Lymphgefäße, Bindegewebszellen, Nerven-

fasern und Abwehrzellen. Außerdem sitzen in ihr die Schweißdrüsen und Haarwurzeln, die die einzige Verbindung zum Stratum corneum darstellen. Ein dichtes Geflecht aus kollagenen und elastischen Fasern in der Dermis sorgt für die Dehnbarkeit und die Reißfestigkeit der Haut.

Im elektrischen Ersatzschaltbild ist der Widerstand der Dermis mit dem der Subcutis als R_{Gewebe} zusammengefasst.

Subcutis Die unterste Hautschicht ist die Unterhaut (Subcutis). Diese elastische, mit Blutgefäßen durchsetzte Schicht beinhaltet Fettreserven und ist für die Verschieblichkeit der Haut verantwortlich.

Auf Grund der guten Durchblutung der subkutanen Schichten liegt eine verhältnismäßig hohe elektrische Leitfähigkeit vor, sodass dieser Hautabschnitt im elektrischen Ersatzschaltbild nach [MW85] als Serienwiderstand dargestellt wird.

Die Hautimpedanz weist neben einer starken Frequenzabhängigkeit auch eine Kopplung mit der anliegenden Spannung auf. Bei einer anliegenden Spannung von unter 100 V kann die über herkömmliche Elektroden gemessene Hautimpedanz nach [Bol02] bis zu 100 k Ω betragen – bei einer Defibrillation mit einer auftretenden Spannung im Kilovolt-Bereich wird allerdings die Hornschicht der Haut durchschlagen, sodass nur noch der Widerstand der subkutanen Schichten mit etwa 25 bis 150 Ω messbar bleibt. Weitere Beeinflussungsmöglichkeiten der Hautimpedanz sind in Abbildung 2.6 gezeigt und sollen kurz erläutert werden:

- Eine gute Hautvorbereitung ist sehr wirkungsvoll, der Effekt jedoch nicht von allzulanger Dauer. Durch Abtragen der obersten Hautschicht (skin abrasion) kann der Hautwiderstand erheblich verringert werden [Tam77], gleichzeitig verringern sich die Potentialunterschiede bei Hautdeformationen [Mil83].
- Eine Änderung der Schweißsekretion kann verschiedene Effekte haben: Bei Trockenelektroden bildet der Schweiß das benötigte Elektrolyt und führt zu einer niedrigeren Impedanz. Ändert sich die Schweißsekretion während der Aufnahme, kommt es zu Impedanzänderungen von drei bis vier Größenordnungen, die die Signalamplitude des EKGs beeinflussen [Cam77]. Bei Klebelektroden kann sich durch den Schweiß der Klebstoff lösen und damit zum vollständigen Abfallen einer Elektrode führen.
- Eine erhöhte Durchblutung verbessert den Ionen-transport in der Haut. Damit wird die elektrische Leitfähigkeit erhöht und die Impedanz verringert.

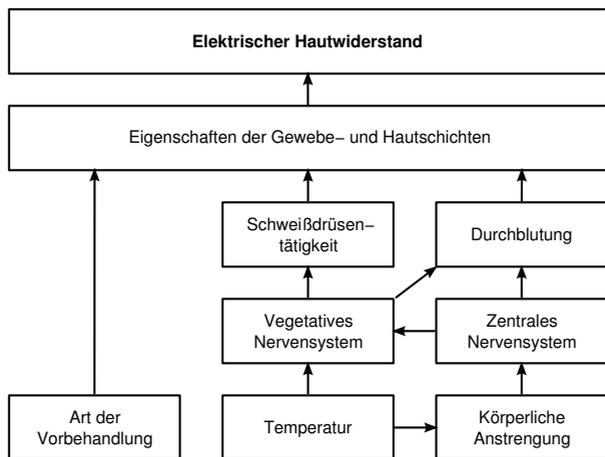


Abbildung 2.6: Möglichkeiten der Hautimpedanzbeeinflussung nach [MW85]

2.2 Messung physiologischer Signale

Um die vorangehend beschriebenen physiologischen Signale auf einem digitalen System verarbeiten zu können, müssen sie am Körper erfasst und digitalisiert werden. Je nach Fragestellung erfolgt die Messung über hochintegrierte Sensoren oder – wie bei der EKG-Ableitung – mittels einer empfindlichen Spannungsmessung über Elektroden am Körper.

2.2.1 EKG-Ableitungen

Bei der Depolarisation einer Herzmuskelzelle entsteht gegenüber repolarisierten Zellen eine Potentialdifferenz von etwa 120 mV. Das dadurch erzeugte elektrische Feld breitet sich durch den Körper aus und lässt sich auf der Körperoberfläche messen – zwischen linkem Fuß und linkem Arm ist so eine Potentialdifferenz von ca. 1 mV messbar, herznäher auf dem Thorax erhöht sich die Amplitude auf etwa 2 bis 3 mV. Das aufgezeichnete elektrische Signal der Herzaktivität wird EKG genannt.

In Abhängigkeit des Ableitungsortes weist das EKG unterschiedliche Morphologien und Amplituden vor. Um die EKGs verschiedener Menschen vergleichbar

zu machen, haben sich in der Praxis zwölf Standardableitungen mit festgelegten Ableitungsorten durchgesetzt (s. Abb. 2.7), die auch in der Norm EN 60601-2-51 definiert sind. Die Ableitungen nach Einthoven und Goldberger lassen sich über drei Elektroden an den Extremitäten (linker Arm, rechter Arm, linkes Bein) erfassen, die Brustwandableitungen nach Wilson werden mit sechs zusätzlichen Elektroden in unmittelbarer Herznähe am Thorax gemessen.

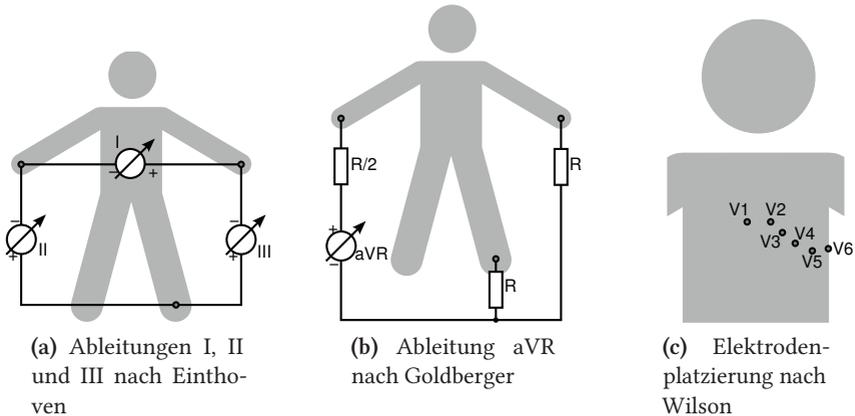


Abbildung 2.7: EKG-Standardableitungen

Bei den Ableitungen nach Einthoven handelt es sich um bipolare Ableitungen, da die Potentialdifferenz zwischen zwei definierten Punkten auf der Haut gemessen wird. Die drei Ableitungen werden mit den römischen Zahlen I, II und III bezeichnet. Werden die Spannungen U zweier Ableitungen gemessen, lässt sich die dritte nach dem Kirchhoffschen Gesetz berechnen [Mal95]:

$$U_{III} = U_{II} - U_I \quad (2.1)$$

Die unipolaren Goldberger-Ableitungen haben keinen eindeutigen Bezugspunkt. Wird über die erste Elektrode abgeleitet, wird der Bezugspunkt über den Zusammenschluss der beiden übrigen Elektroden gebildet. Die Ableitungen nach Goldberger werden aVR, aVL und aVF genannt. Das V kennzeichnet sie als unipolare Ableitung, das a steht für *augmented*. Sie lassen sich aus zwei

gemessenen Einthoven-Ableitungen berechnen:

$$U_{aVR} = -\frac{1}{2}(U_I + U_{II}) \quad (2.2)$$

$$U_{aVL} = \frac{1}{2}(U_I - U_{III}) \quad (2.3)$$

$$U_{aVF} = \frac{1}{2}(U_{II} + U_{III}) \quad (2.4)$$

Auch bei den sechs Brustwandableitungen nach Wilson handelt es sich um unipolare Ableitungen. Der Bezugspunkt wird hierbei über den Zusammenschluss der drei Extremitätenelektroden gewonnen. Die Wilson-Ableitungen werden mit V1 bis V6 bezeichnet.

In Abbildung 2.8 ist ein Zwölfkanal-EKG mit allen zuvor genannten Ableitungen gezeigt. Es ist deutlich zu erkennen, dass es je nach Ableitungsort zu Unterschieden in Amplitude und Morphologie kommt. Diese Form der EKG-Aufzeichnung ist üblicher Standard in der Kardiologie, da sie Projektionen des Herzvektors aus allen drei Raumrichtungen vereint.

Häufig wird zusätzlich eine weitere Elektrode zur negativen Einkopplung des am EKG-Verstärker anliegenden Gleichtaktsignals verwendet. Diese Bezugspotentialsteuerung wird Driven Right Leg genannt und erhöht die Gleichtaktunterdrückung, ohne dass Instabilitäten auftreten [Win83].

Zur Überwachung von Patienten (Monitoring) in der Klinik oder im präklinischen Bereich wird üblicherweise auf die Wilson-Ableitung verzichtet, stattdessen werden drei Elektroden – ähnlich der Einthoven- oder Goldberger-Ableitungen – auf dem Thorax bzw. in der Leistengegend platziert (Mason-Likar Modifizierung). Dies hat den Vorteil einer erhöhten Patientenmobilität (keine Einschränkung durch Kabel an den Extremitäten) sowie einer höheren Amplitude im abgeleiteten Signal. Damit wird das Signal-zu-Rausch-Verhältnis erhöht, sodass auch noch bei einem sich bewegenden Patienten ein auswertbares EKG abgeleitet werden kann.

Bei mobilen Langzeit-EKG-Rekordern werden oftmals zwei oder drei bipolare Ableitungen in unmittelbarer Herznähe geklebt. Dabei wird versucht, durch geschickte Elektrodenplatzierung verschiedene Raumachsen des Herzvektors aufzuzeichnen.

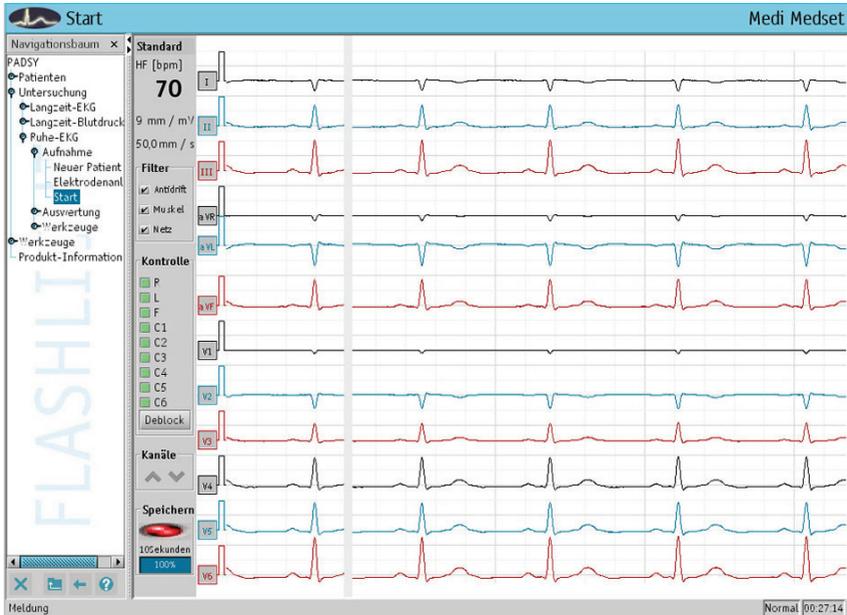


Abbildung 2.8: Klinisches EKG mit den zwölf Standardableitungen, aufgenommen mit dem PC-EKG-System FlashLight [Med06]

2.2.2 Elektroden für die EKG-Messung

Um die bioelektrischen Signale des Körpers erfassen zu können, bedarf es einer Ankopplung des Messsystems an den Körper. Dazu dienen Elektroden, die die im Körper vorherrschende Ionenleitung in die Elektronenleitung des Messsystems überführen. Es wird dabei zwischen intern (implantierten) und extern applizierten Elektroden unterschieden. Bei der nichtinvasiven EKG-Aufzeichnung sind nur die extern applizierten Elektroden relevant, welche sich wiederum in Gelelektroden, Trockenelektroden und isolierende (kapazitive) Elektroden einteilen lassen. Abbildung 2.9 zeigt Fotos bzw. Schemata dieser drei Elektrodentypen. In [Sea00] werden ihre Eigenschaften ausführlich verglichen, im weiteren Verlauf wird gezielt nur auf die für diese Arbeit relevanten Merkmale eingegangen.

Ein großer Vorteil der Gelelektroden ist ihre einfache Anwendbarkeit: Die

als günstige Einwegprodukte hergestellten selbstklebenden Elektroden werden einfach entsprechend der gewünschten Ableitung auf den Körper aufgeklebt. Die Elektrode besteht aus einem kleinen Kissen, das mit Elektrodengel getränkt ist. Durch dieses Kissen werden zum einen Bewegungsartefakte gedämpft, zum anderen bietet das Elektrodengel einen guten elektrischen Übergang zwischen Haut und der eigentlichen Silber/Silberchlorid-Elektrode (Ag/AgCl-Elektrode). In der Langzeitüberwachung führen diese vermeintlichen Vorteile jedoch zu Problemen: Das Elektrodengel trocknet innerhalb weniger Tage aus, wodurch sich der Kontaktwiderstand vergrößert. Außerdem kann sowohl das Elektrodengel als auch der verwendete Elektrodenklebstoff zu Hautirritationen führen. Aus diesen Gründen werden selbstklebende Gelelektroden nur für EKG-Aufnahmen bis zu 48 Stunden verwendet. Soll die Aufnahme länger andauern, muss die Position der EKG-Elektroden regelmäßig gewechselt werden.

Kapazitive Elektroden befinden sich zur Zeit noch in einem Entwicklungsstadium und werden in der Praxis noch nicht eingesetzt. Der Vorteil dieser Elektroden ist das Ableiten des EKG ohne direkten Hautkontakt – jegliche Hautreizungen können damit vermieden werden. Nachteil ist die sehr hohe Anfälligkeit für Artefakte. [Har02] und [Har04] gehen näher auf die Anwendungsmöglichkeiten kapazitiver Elektroden ein.

Für eine langfristig andauernde EKG-Überwachung bieten sich Trockenelektroden an. Dies sind Elektroden aus Metall (meist Edelstahl oder Silber) oder leitfähigen Kunststoffen bzw. Textilien, die ohne ein Elektrodengel verwendet werden. Die Fixierung am Körper erfolgt beispielsweise durch einen Brustgurt, der einen möglichst gleichmäßigen Anpressdruck gewährleisten soll. Das fehlende Elektrodengel wird durch den elektrolythaltigen körpereigenen

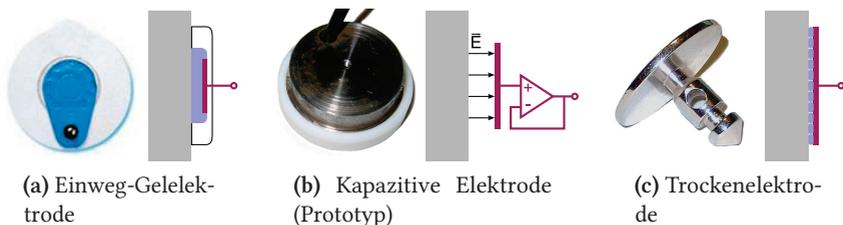


Abbildung 2.9: Verschiedene Elektrodentypen zur EKG-Ableitung

Schweiß ersetzt, dennoch ist nach [Sea00] der Übergangswiderstand gegenüber Gelelektroden erhöht. Allerdings verbessern sich die Eigenschaften von Trockenelektroden im Laufe der Messung, sodass bei einer Überwachung über einen längeren Zeitraum insgesamt bessere Ergebnisse zu erwarten sind als bei Gelelektroden.

Zur Veranschaulichung des elektrischen Überganges Haut–Elektrode existieren verschiedene Ersatzschaltbilder. Abbildung 2.10 zeigt das Ersatzschaltbild aus [Bol02], das neben der Kapazität der Helmholtz-Doppelschicht C_H und dem Faraday-Widerstand R_F auch noch eine Spannungsquelle U_E beinhaltet, welche die Elektrodengleichgewichtspotentiale modelliert, die an der Phasengrenze Elektrode–Haut entstehen. C_H und R_F sind spannungsabhängig, der Zuleitungswiderstand R_Z ist konstant. Durch eine Änderung einer Einzelkomponente – beispielsweise durch einen unvollständigen Kontakt zwischen Haut und Elektrode – ändern sich die elektrischen Eigenschaften der Elektrode und es kommt zu Störungen im Signal. Eine genauere Beschreibung der elektrochemischen Prozesse an der Elektrode finden sich in [Bol02] und [MW85].

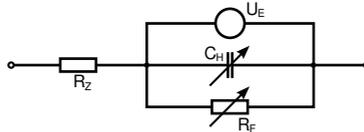


Abbildung 2.10: Ersatzschaltbild einer Elektrode

2.2.3 Artefakte im EKG

Das gemessene menschliche EKG enthält neben dem gewollten elektrischen Signal des Herzens noch eine Anzahl von Störsignalen, die im Allgemeinen als Artefakte bezeichnet werden. [Weh03] unterteilt Artefakte nach ihrem Ursprung in drei Gruppen: instrumentelle, extern beeinflusste und physiologische Artefakte. Abbildung 2.11 gibt einen Überblick über mögliche Störquellen, Abbildung 2.12 zeigt die Folgen im EKG.

Instrumentelle Artefakte

Als instrumentelle Artefakte bezeichnet man alle Störsignale, die mit dem Messsystem in Zusammenhang stehen. Mit einer sorgfältigen Überprüfung des

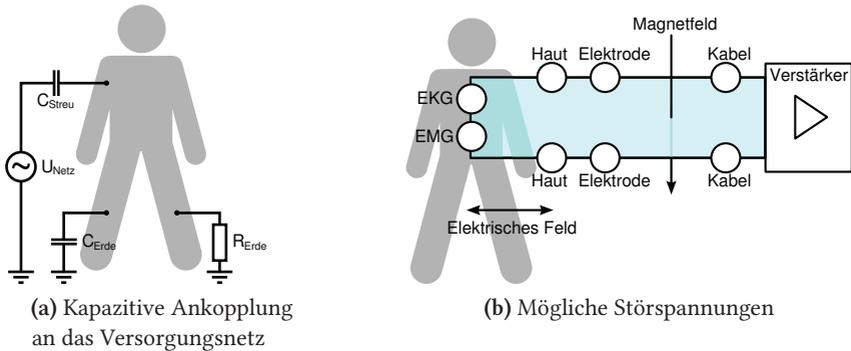


Abbildung 2.11: Übersicht möglicher Störquellen bei der EKG-Ableitung nach [Web84]

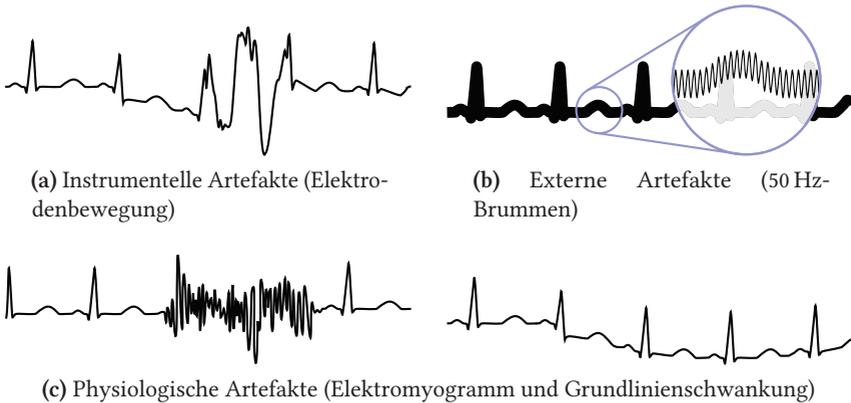


Abbildung 2.12: Beispiele für verschiedene Artefakte im EKG

Messgerätes, einer EKG-Messung in Ruhe (Ruhe-EKG) und einer gewissenhaften Hautvorbereitung lassen sich die meisten instrumentellen Fehler vermeiden. Zu den möglichen Artefaktquellen zählen:

- falsch eingestellte Parameter am Messgerät
- Änderungen der Eigenschaften von Bauelementen (z. B. Temperaturdrift)
- Kontaktfehler bis hin zum Abfallen einer Elektrode oder Kabelbruch
- Oberflächenkurzschlussstrom zwischen zwei Elektroden auf der Haut durch eine Elektrolytbrücke (Shunt-Effekt)
- Bewegung des Elektrodenkabels
- Bewegung der Elektrode relativ zur Haut

Bei der mobilen Langzeitüberwachung sind insbesondere die durch Bewegung entstehenden Artefakte nicht vermeidbar. Durch eine Bewegung des Elektrodenkabels ändert sich die Position des Leiters zur Isolierung, dadurch kommt es zu einer Änderung der Streukapazität und zu großamplitudigen Schwankungen im Signal. Des Weiteren kann es durch die Reibung des Kabels an seiner Isolierung zu triboelektrischen Effekten kommen. Die Verwendung von speziellen Kabeln (Low-Noise-Kabel) kann diese Art der Artefakte jedoch minimieren.

Wird eine Ableitungselektrode relativ zur Haut bewegt, kommt es zu einer Änderung des Kontaktwiderstandes, zu einer Störung der Helmholtz-Doppelschicht und zu teilweise erheblichen Potentialveränderungen in der Haut. Die Impedanzveränderung kann durch einen entsprechend dimensioniertes Analogteil des EKG-Verstärkers minimiert werden, die Störung der Helmholtz-Doppelschicht und die Hautpotentiale können durch die Art der verwendeten Elektroden beeinflusst werden [Sea00]. Gelelektroden können diese Bewegungen besser kompensieren als Trockenelektroden, sind aber – wie bereits in Kapitel 2.2.2 erwähnt – für eine 24/7-Überwachung nicht geeignet.

Die Frequenz der bewegungsinduzierten Störungen ist abhängig von der Bewegungsgeschwindigkeit. Die Atmungsbewegung eines am Thorax abgeleiteten EKGs zeichnet sich so als niederfrequente Grundlinienschwungung (0,27 Hz bei 16 Atemzügen pro Minute [Sil03]) aus. Bewegungen wie Gehen, Treppensteigen oder Hüpfen verursachen deutlich größere Beschleunigungen und damit auch steilere Artefakte mit höheren Frequenzanteilen (1 bis 10 Hz laut [Ham97]).

Externe Artefakte

Störsignale, die von außen auf das Messsystem einwirken, werden als externe Artefakte bezeichnet. Dies ist insbesondere ein 50 Hz-Brummen, das durch die Netzfrequenz umliegender Versorgungsleitungen verursacht wird.¹

Sowohl der menschliche Körper als auch die Elektrodenkabel sind kapazitiv mit dem Versorgungsnetz gekoppelt. Abbildung 2.11a auf Seite 20 zeigt ein entsprechendes Ersatzschaltbild. Die so eingestreute Störspannung liegt in der Größenordnung von 10 V und damit um ein Vielfaches höher als das gewünschte Messsignal. Davor kann man sich nur durch eine Faraday-Abschirmung wirkungsvoll schützen, was in der mobilen Langzeitüberwachung aber nicht realisierbar ist. Die Folgen lassen sich durch EKG-Verstärker mit einer hohen Gleichtaktunterdrückung und notfalls auch mit einem Notchfilter bei der Netzfrequenz soweit minimieren, dass sie nur in seltenen Fällen ein Problem darstellen.

Eine Abschirmung vor elektromagnetischen Feldern, wie sie von Motoren (z. B. Fahrstühle, Ventilatoren), Drosselspulen (z. B. Leuchtstoffröhren) oder Monitoren verursacht werden, ist nur mit sehr großem Aufwand möglich [Weh03] und in der mobilen EKG-Überwachung ebenfalls nicht durchführbar. Die Minimierung der vom Magnetfeld durchsetzten Fläche mittels dicht aneinander geführter bzw. ineinander verdrehter (twisted pair) Elektrodenkabel vermag jedoch dem Entstehen einer durch Magnetfelder induzierten Spannung entgegenwirken [MW85].

Physiologische Artefakte

Zur Gruppe der physiologischen Artefakte gehören alle mitaufgezeichneten Biosignale des Messobjektes, die für die Fragestellung nicht relevant sind. Dies sind im Falle eines EKGs vor allem Muskelpotentiale (Elektromyogramm, EMG) und Schweißsekretion. Letztere verändert die Eigenschaften der Ableitelektroden und führt somit zu einer Grundlinienschwankung von 0,2 bis 1 Hz mit großer Amplitude [Weh03]. Bei einer ungeschickten Platzierung der Elektroden kann sich außerdem die Pulsation von Arterien als Störsignal im EKG niederschlagen.

Laut [Web84] ist eine Muskelbewegung meist mit einer Dehnung der Haut verbunden. Dadurch sinkt die Potentialdifferenz des Stratum granulosum in der

1 In Ländern mit einer Netzfrequenz von 60 Hz gilt Entsprechendes.

Epidermis von normalerweise 30 mV auf etwa 25 mV. Durch eine sorgfältige Hautvorbereitung, wie das vorsichtige Abtragen der obersten Hautzellen, kann dieser Effekt minimiert werden.

Muskelpotentiale und deren nervale Erregung können durch schlechte Elektrodenpositionierung Störsignale von bis zu 10 mV verursachen [Bro00]. Durch den verhältnismäßig hohen Frequenzanteil lassen sie sich jedoch weitgehend herausfiltern. Tabelle 2.1 zeigt eine Übersicht der Biosignale, die für die EKG-Messung relevante Störungen verursachen können.

Tabelle 2.1: Frequenz- und Dynamikumfang von Biosignalen [Bro00]

Quelle	Frequenzbereich	Amplitude	Kommentar
Nerven	100 Hz – 1 kHz	5 μ V – 10 mV	Potential eines Nervenbündels
Muskeln	0.01 – 1 Hz	50 μ V – 5 mV	Potential der glatten Muskulatur
	2 – 500 Hz	50 μ V – 5 mV	Potential der Skelettmuskulatur
Herz	0,05 – 100 Hz	1 – 10 mV	EKG-Signal

2.2.4 Anwendungsszenarien

In der Praxis haben sich verschiedene Arten der EKG-Aufzeichnung durchgesetzt, die in [Gon99] ausführlich beschrieben sind. Sie unterscheiden sich in der Länge der Aufnahme, der Anzahl der abgeleiteten Kanäle und vor allem in ihrem Nutzen bezüglich einer bestimmten medizinischen Fragestellung. Im Folgenden werden die am häufigsten verwendeten Verfahren erklärt und ihre Unterschiede aufgezeigt.

Sowohl in der Klinik und der kardiologischen Praxis als auch vermehrt im Rettungsdienst werden zwölfkanalige *Ruhe-EKGs* geschrieben, um bestimmte Pathologien zu bestimmen. Insbesondere zur sicheren Befundung von Myokardinfarkten, Schenkelblöcken oder Durchblutungsstörungen im Koronarsystem ist eine zwölfkanalige Ableitung notwendig. Da sich der Patient entspannt und in Ruhe befindet und die EKG-Aufzeichnung üblicherweise nicht unter Zeitdruck gemacht werden muss, erhält man ein qualitativ sehr hochwertiges

EKG, sodass automatische Analysealgorithmen das EKG weitgehend vermessen und interpretieren können.

Bei einem *Belastungs-EKG* (Ergometrie) wird der Patient mit intervallartig ansteigender Leistung auf einem Laufband oder Fahrradergometer belastet, zeitgleich wird ein Zwölfkanal-EKG abgeleitet. Durch Erschütterungen und Bewegungen des Körpers wird dabei das EKG sehr leicht durch Artefakte gestört. Eine gründliche Hautvorbereitung und ein sorgfältiges Verlegen und Fixieren der Elektrodenkabel und Elektroden ist deshalb unabdingbar, um solche Fehler zu minimieren. Zur Diagnostik einer koronaren Herzkrankheit ist das Belastungs-EKG die wichtigste Untersuchungsmethode. So können belastungsinduzierte Durchblutungsstörungen aufgedeckt werden, die bei einem Ruhe-EKG maskiert sind.

Eine andere Art der Überwachung stellt das *Langzeit-EKG* (auch Holter-EKG genannt) dar. Die International Electrical Commission (IEC) empfiehlt für die Aufnahmegeräte eine Registrierdauer von mindestens 24 Stunden mit mindestens zwei Kanälen. Die tragbaren Geräte zeichnen das EKG des Patienten im Alltag auf, während dieser ein Protokoll über seine Tätigkeiten und eventuell auftretende Beschwerden führt. Der Kardiologe kann nun retrospektiv das EKG klassifizieren und befunden. Computerprogramme mit ihren Analysealgorithmen unterstützen den Arzt dabei mit einer automatischen Schlagdetektion und -klassifikation. Langzeitaufnahmen sind dann sinnvoll, wenn der Patient unter selten auftretenden Rhythmusstörungen leidet, deren Auftretenswahrscheinlichkeit bei einer kurzen ambulanten Aufnahme zu gering ist. Neben der Diagnose von Rhythmusstörungen wird das Langzeit-EKG auch zur Therapiekontrolle eingesetzt, für ein Ischämies-Screening bei asymptomatischen Patienten ist es aber ungeeignet [Mai04]. Eine Analyse von ST-Veränderungen ist nur möglich, wenn exakt definierte Elektrodenpositionen verwendet werden.

Ein großes Problem dieser Aufzeichnungsart ist, dass immer wieder weite Signalabschnitte durch Bewegungsartefakte gestört werden. Auch während der Messung auftretende Fehler wie lockere oder ganz abgefallene Elektroden werden häufig nicht bemerkt. Unterbleibt die fachmännische Fehlerbehebung, kann dies eine ganze Aufnahme unbrauchbar machen.

In Kapitel 3.5 werden die Gerätetypen, die für die Langzeitaufnahme von EKG-Signalen eingesetzt werden, genauer vorgestellt. Da solche Aufnahmen unüberwacht und während des Alltags des Patienten erstellt werden, kann ein ungestörtes EKG nicht garantiert werden. Auf Grund der langen Aufzeichnungs-dauer ist eine zuverlässige automatische Analyse unabdingbar.

2.2.5 Bewegungserfassung

Zur Erfassung von Bewegungen sind mikro-elektromechanische (MEMS) Beschleunigungssensoren sehr verbreitet. Das Kernstück eines solchen integrierten Sensors ist ein Feder-Masse-System, das bei Beschleunigungen in Richtung der sensitiven Achse ausgelenkt wird. Mit Hilfe des Newtonschen Gesetzes

$$F = m \cdot a \quad (2.5)$$

und des Hookschen Gesetzes

$$F = -D \cdot x \quad (2.6)$$

lässt sich mit bekannter Masse m und Federkonstante D über eine Messung der Auslenkung x auf die Beschleunigung a schließen. Die Auslenkung wird bei den meisten kommerziellen Beschleunigungssensoren über eine Kapazitätsänderung bestimmt. Die Genauigkeit gängiger Sensoren liegt bei 15 mg ($1 \text{ g} \hat{=} 9,81 \text{ m/s}^2$), der Aufnahmebereich geht von $\pm 2 \text{ g}$ bis $\pm 10 \text{ g}$. Für eine Aktivitätserkennung sollte die Abtastrate bei etwa 40 Hz oder mehr liegen, einige Sensoren können auch im unteren kHz-Bereich abtasten.

Bei der Beschleunigungsmessung wird zwischen statischer und dynamischer Beschleunigung unterschieden. Die Erdbeschleunigung ist eine statische Beschleunigung, über die sich die Lage des Sensors bestimmen lässt. Über die dynamische Beschleunigung lässt sich auf die Bewegung schließen.

Die Stromaufnahme eines dreiachsigen MEMS-Beschleunigungssensors liegt in der Größenordnung von wenigen hundert μA . Verwendet man MEMS-Sensoren mit digitalem Ausgang, können diese einfach über einen SPI- (Serial Peripheral Interface) oder I²C-Bus (Inter-Integrated Circuit) mit dem verwendeten Mikrocontroller verbunden werden, ohne eine aufwändige Analogschaltung für die A/D-Wandlung implementieren zu müssen.

Man findet diese Bauelemente z. B. in Kraftfahrzeugen, Mobiltelefonen und Kameras. Der Preis eines solchen Bausteins liegt bei wenigen Euro.

2.2.6 Impedanzmessung

Zur Impedanzmessung muss ein konstanter Strom i in das Messobjekt – bei der Bioimpedanzmessung ist das der menschliche Körper – eingepreßt werden,

gleichzeitig wird die abfallende Spannung u gemessen und daraus die Impedanz Z berechnet:

$$Z = \frac{u}{i} \quad (2.7)$$

Zum Einprägen des Stroms und zur Spannungsmessung können wahlweise dieselben oder verschiedene Elektroden verwendet werden, man unterscheidet so zwischen Zwei- und Vierelektrodenmessung. Die Frequenz des eingepprägten Stroms ist stark anwendungsabhängig und kann von einer Gleichstrommessung bis zum Wechselstrom im kHz-Bereich variieren, in einigen Anwendungen ist auch ein Frequenzsweep sinnvoll. Die maximale Stromstärke für diesen sogenannten Patientenhilfsstrom ist bei Medizinprodukten nach DIN EN 60601-1 auf maximal $100 \mu\text{A}$ für Wechselstrom begrenzt.

Für die Messung der Elektrode-Haut-Impedanz sollte eine Zweielektrodenmessung gewählt werden (s. Abb. 2.13). Der Impedanz Einfluss des menschlichen Gewebes ist in diesem Fall um Größenordnungen geringer als das gewünschte Messsignal, der Übergangsimpedanz zwischen Elektrode und Haut, und kann deshalb vernachlässigt werden.

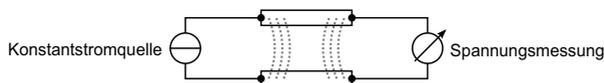


Abbildung 2.13: Impedanzmessung über zwei Elektroden nach [Web10]

Das wohl verbreitetste Gerät zur Bioimpedanzmessung ist die Körperfettwaage, weitere Anwendungsfelder sind die Impedanzpletismographie, die Messung der transthorakalen Impedanz bei automatischen Defibrillatoren oder die Messung der elektrodermalen Aktivität. In den meisten Anwendungsfällen steht aber die Impedanz des Körpergewebes und nicht die des Elektrode-Haut-Übergangs im Vordergrund.

2.3 Mathematische Grundlagen

Mit Hilfe verschiedener Formen der digitalen Signalverarbeitung können die aufgezeichneten Biosignale gefiltert werden, um Störanteile zu unterdrücken. Zur Bewertung von implementierten Analysealgorithmen werden standardisierte Bewertungskriterien herangezogen.

2.3.1 Adaptive Filter

Ein adaptives Filter ist ein digitales Filter mit veränderbaren Filterkoeffizienten. Auf diese Weise kann die Übertragungsfunktion des Filters permanent einem variierenden Eingangssignal angepasst werden und damit die Filterleistung optimieren. Abbildung 2.14 zeigt den prinzipiellen Aufbau eines adaptiven Filters. Dabei wird ein Eingangssignal x_k entsprechend der Filtergewichte gefiltert. Das Ausgangssignal y_k wird mit einem Wunschsinal d_k (desired) verglichen – die Differenz aus beiden Signalen bildet das Fehlersignal e_k . Der Optimierungsalgorithmus versucht nun, durch Veränderung der Filtergewichte das Fehlersignal e_k zu minimieren. Ist $e_k = 0$, entspricht das Ausgangssignal y_k dem gewünschten Wert, das Filter ist dann optimal eingestellt. Die folgenden Ausführungen bedienen sich [Mos00] und [Wid75], welche Grundlagen und Anwendungen adaptiver Filter ausführlich beschreiben.

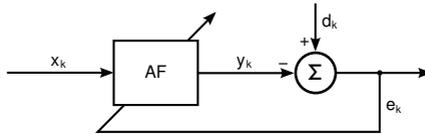


Abbildung 2.14: Aufbau eines adaptiven Filters

Als digitales Filter wird üblicherweise ein Filter mit endlicher Impulsantwort (FIR-Filter, finite impulse response filter) verwendet, da diese – auch bei fehlerhaft gewählten Filterkoeffizienten – stets stabil bleiben. Zusätzlich wird ein Einstellnetzwerk benötigt, das anhand eines Fehlersignals die Filtergewichte so bestimmt, dass das Fehlersignal minimiert wird. Für diese Minimierung des Fehlersignals gibt es zahlreiche Algorithmen. Bewährt haben sich der sehr gute, aber leider auch sehr rechenintensive RLS-Algorithmus (recursive least squares algorithm), sowie der deutlich weiter verbreitete LMS-Algorithmus (least mean squares algorithm). Letzterer ist im Vergleich zum RLS-Algorithmus auf Grund der fehlenden Rekursionen deutlich schneller in der Rechenzeit und verhältnismäßig einfach zu implementieren, sodass er in den meisten Anwendungen bevorzugt wird.

Die Einsatzgebiete adaptiver Filter sind weit gestreut: Sie werden zur Kanalverzerrung in der digitalen Funkübertragung, zur Minimierung von Störungen, zur Echokompensation oder zur Systemidentifikation genutzt.

Wird ein adaptives Filter zur Unterdrückung von Störungen eingesetzt, so

wird das gestörte Signal auf den Eingang d_k gelegt, während x_k ein Signal ist, das mit den Störungen möglichst gut korreliert (Abbildung 2.15). Das gestörte Signal kann als Summe aus einem Störsignal n_k (noise) und einem Nutzsignal s_k (signal) betrachtet werden:

$$d_k = n_k + s_k \quad (2.8)$$

Das adaptive Filter muss nun versuchen, den Störanteil in d_k zu schätzen, sodass er entfernt werden kann. Dazu wird ein Referenzsignal x_k benötigt, das mit n_k gut und mit s_k möglichst gar nicht korreliert:

$$x_k = \tilde{n}_k \quad (2.9)$$

Mit Hilfe dieses Referenzsignals bildet das Filter den Störanteil aus d_k nach. Am Ausgang des Filters liegt demnach $y_k = \hat{n}_k$ an. Entsprechend gilt für den Schätzfehler e_k

$$e_k = d_k - y_k \quad (2.10)$$

$$= s_k + n_k - \hat{n}_k \quad (2.11)$$

Als Algorithmus zur Filtereinstellung dient oft ein LMS-Algorithmus, der den Erwartungswert des Fehlerquadrates minimiert. Der Erwartungswert des quadrierten Fehlers aus (2.11) ist

$$E\{e_k^2\} = E\{s_k^2\} + 2E\{s_k(n_k - \hat{n}_k)\} + E\{(n_k - \hat{n}_k)^2\} \quad (2.12)$$

Wenn nun sowohl Nutz- und Störsignal, als auch Nutz- und Referenzsignal unkorreliert zueinander sind, entfällt der mittlere Term in (2.12):

$$E\{e_k^2\} = E\{s_k^2\} + E\{(n_k - \hat{n}_k)^2\} \quad (2.13)$$

$E\{e_k^2\}$ wird also dann minimal, wenn $n_k = \hat{n}_k$ ist. Damit entspricht der Fehler e_k dem Nutzsignal s_k .

Der LMS-Algorithmus nutzt neben der Filterlänge N (Anzahl der Gewichte w) einen zweiten Parameter, die Schrittweite μ . Damit berechnen sich die neuen Filtergewichte w_{k+1} folgendermaßen:

$$w_{k+1} = w_k + \mu \cdot e_k \cdot x_k \quad (2.14)$$

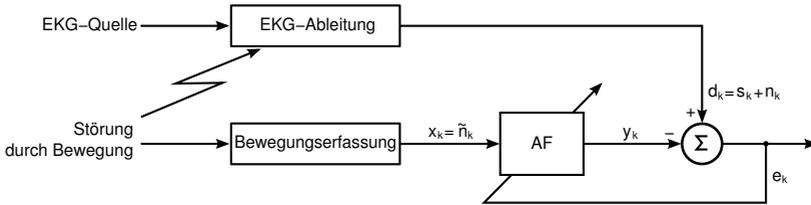


Abbildung 2.15: Einsatz eines adaptiven Filters zur Störunterdrückung

Die Auswahl von μ beeinflusst den Adaptionsalgorithmus wie folgt: Eine große Schrittweite lässt das Filter schneller konvergieren, das Ergebnis ist allerdings nicht so genau. Eine kleine Schrittweite führt zu einem langsamen Konvergieren, dafür ist das Resultat des eingeschwungenen Filters genauer. Hier gilt es jetzt einen geeigneten Wert zu finden, für den gilt:

$$0 < \mu < \frac{2}{N \cdot \text{mittlere Eingangsleistung}} \quad (2.15)$$

Der Vergessensfaktor ρ beschreibt das Gedächtnis eines adaptiven Filters und kann die Werte $0 < \rho \leq 1$ annehmen. Dieser Faktor beschreibt die Gewichtung der alten und neuen Daten. Setzt man $\rho = 1$, ist das Gedächtnis unendlich.

Die Schwierigkeit bei der Anwendung adaptiver Filter zur Störsignalunterdrückung besteht darin, ein geeignetes Referenzsignal zu finden. Sobald das Referenzsignal mit dem Nutzsignal korreliert ist, kann das Filter keine erfolgreiche Fehlerminimierung durchführen. Das gleiche gilt für ein Referenzsignal, das unkorreliert zum Störsignal ist.

Gute adaptive Filter (bzw. deren Fehlerminimierungsalgorithmen) zeichnen sich durch eine hohe Konvergenzgeschwindigkeit mit einem geringen Restfehler und guten Tracking-Eigenschaften – also der Fähigkeit, einem veränderlichen Signal zu folgen – aus. Zusätzliche Randbedingung sind der Realisierungsaufwand, die Robustheit des Filters sowie die Rechengeschwindigkeit.

2.3.2 Bewertung von Analysealgorithmen

Zur Bewertung von Klassifikatoren wird deren Sensitivität (Se), Spezifität (Sp) bzw. positive Prädiktivität (pP) angegeben. Diese Metriken lassen sich aus

einer Wahrheitsmatrix berechnen, in der alle erkannten und nicht erkannten Ereignisse eingetragen werden (s. Tab. 2.2).

Tabelle 2.2: Wahrheitsmatrix für Klassifikatoren

	Ereignis eingetroffen	Ereignis nicht eingetroffen
Ereignis erkannt	richtig positiv (TP)	falsch positiv (FP)
Ereignis nicht erkannt	falsch negativ (FN)	richtig negativ (TN)

Bezogen auf die automatische QRS-Erkennung ist die Sensitivität die Güte, mit der ein QRS-Komplex als solcher erkannt wird (Empfindlichkeit), während die positive Prädiktivität angibt, wie viele der vermeintlich erkannten QRS-Komplexe auch tatsächlich QRS-Komplexe sind (Relevanz). Zur Bestimmung von Se und pP generiert der Analysealgorithmus eine Liste mit allen von ihm gefundenen QRS-Komplexen, die sogenannte Triggerliste. Diese Liste wird mit einer zweiten Triggerliste verglichen, die eine manuelle Referenz der QRS-Positionen enthält (Referenz-Triggerliste). Alle Übereinstimmungen und Abweichungen werden dabei entsprechend der Wahrheitsmatrix gezählt und folgendermaßen berechnet:

$$Se = \frac{TP}{TP + FN} \quad (2.16)$$

$$pP = \frac{TP}{TP + FP} \quad (2.17)$$

Dabei bezeichnet TP (true positive) die Anzahl aller QRS-Komplexe, die richtigerweise als QRS-Komplex erkannt wurden. FN (false negative) ist die Anzahl aller QRS-Komplexe, die nicht als QRS-Komplex erkannt wurden und FP (false positive) ist die Anzahl der Schläge, die fälschlicherweise als QRS-Komplex erkannt wurden, aber keine sind. Findet sich innerhalb eines festgelegten Zeitfensters (± 75 ms laut DIN EN 60601-2-47) um einen Referenz-Trigger kein QRS-Komplex in der zu testenden Triggerliste, handelt es sich um einen FN-Trigger. Gibt es einen Trigger in der Test-Triggerliste, der innerhalb des Zeitfensters kein Pendant in der Referenz-Triggerliste hat, ist dies ein FP-Trigger.

Eine Bestimmung der richtig negativen QRS-Komplexe ist in diesem Fall

nicht sinnvoll, da es sich bei der QRS-Erkennung um die Detektion diskreter Ereignisse handelt. Für die Bewertung von Klassifikatoren, die ganze Bereiche einordnen – wie es beispielsweise bei der Erkennung von Artefaktbereichen der Fall ist – benötigt man zur Bewertung neben der Sensitivität die Spezifität:

$$Sp = \frac{TN}{TN + FP} \quad (2.18)$$

TN (true negative) steht dabei für den Zeitraum, der korrekterweise als Nicht-Artefaktbereich erkannt wurde. Ein Artefakterkennung mit hoher Spezifität erkennt nur wenige Nicht-Artefaktbereiche fälschlicherweise als Artefakt.

3 Telemedizin und EKG-Monitoring

Der Begriff Langzeit-EKG wird üblicherweise synonym zum 24-Stunden-Holter-EKG genutzt – auch wenn es inzwischen viele Anwendungen gibt, in denen ein EKG deutlich länger mobil aufgezeichnet wird. Das Langzeit-EKG von heute kann mitunter tagelang getragen werden, analysiert womöglich schon auf dem Gerät das EKG-Signal und meldet sich bei Bedarf selbständig beim Arzt, wenn es Auffälligkeiten entdeckt.

In diesem Kapitel soll der aktuelle Entwicklungsstand im Bereich Holter-EKG, Langzeit-EKG-Monitoring und EKG-Telemetrie vorgestellt werden. Dabei soll kurz auf das Stichwort *Telemedizin* und die aktuelle EKG-Hardware eingegangen werden. Den Schwerpunkt bildet aber der Stand der Technik in EKG-Signalverarbeitung, Artefaktbehandlung und Bewegungsanalyse.

3.1 Telemedizin

Unter Telemedizin versteht man den Einsatz von Kommunikationstechnologien zum elektronischen Austausch von medizinischen Daten, um eine diagnostische oder therapeutische Interaktion zu ermöglichen – die Distanz zwischen Patient und Arzt wird überwunden [Sch08].

3.1.1 Definition und Begriffe

Telemedizin wird bereits in vielen Bereichen der klinischen Medizin erfolgreich eingesetzt, sie ist dabei jedoch immer als Ergänzung zur konventionellen ärztlichen Behandlung anzusehen. Laut dem Telemedizinführer Deutschland ist der Begriff *Telemedizin* als

Medizinische Anwendungen oder Anwendungsfälle, die Telekommunikation und Informatik (Telematik) verwenden

definiert [Jäc08]. Ihre wichtigste Indikation ist die Diagnostik von nicht lebensbedrohlichen Herzrhythmusstörungen und die Abklärung von Symptomen [Mül09a].

Obwohl Einthoven schon im Jahr 1906 das erste EKG über eine Telefonleitung übertragen hatte, konnte sich die Telemedizin im Bereich der Kardiologie erst rund 90 Jahre später durchsetzen – geschuldet den schnellen Entwicklungen in der Informations- und Kommunikationstechnik. Heutzutage werden in der Kardiologie telemedizinische Dienste insbesondere für die Diagnostik und Überwachung von Herzrhythmusstörungen und zum Monitoring von Patienten mit chronischer Herzinsuffizienz oder mit Implantaten (Herzschrittmacher oder ICD) eingesetzt. Bei diesen Anwendungsfällen spricht man im Allgemeinen von *Telekardiologie*.

Der Begriff *kardiologisches Telemonitoring* schränkt die Telekardiologie weiter ein: Hierunter versteht man die kardiologische Fernüberwachung von Patienten mit Hilfe telemedizinischer Geräte. In heutigen Szenarien ist das häufig ein EKG-Event-Rekorder, um entweder ein tägliches Kontroll-EKG oder bei Palpitationen das EKG-Event aufzuzeichnen, ein Blutdruckmessgerät zur täglichen Blutdruckkontrolle und eine Körperwaage, um täglich das Gewicht zu kontrollieren. Eine plötzliche Gewichtszunahme kann durch Wasseransammlungen im Gewebe bzw. in der Lunge bedingt sein, die wiederum ihre Ursache in einer Linksherzinsuffizienz mit drohender Dekompensation finden. Das Ziel des kardiologischen Telemonitorings ist die bessere Einstellung mit Medikamenten oder eine Überwachung nach therapeutischen Eingriffen [Sch08].

Im Gegensatz dazu dient die *Telediagnostik* der Erkennung von eher selten auftretenden Rhythmusstörungen, die mit einem konventionellen 24 h-EKG nicht erfasst werden konnten. Die Telediagnostik endet mit der Diagnosestellung.

3.1.2 Telemedizin in Deutschland

Mit der Langzeitstudie *Partnership for the Heart*, bei der ein Telemonitoring von 710 Herzinsuffizienzpatienten durchgeführt wurde, konnten auch in Deutschland erste Erfahrungen im Bereich der Telekardiologie gesammelt werden. Zwar konnte die Gesamtmortalität aller Patienten innerhalb der Studie nicht gesenkt werden, allerdings wurde ermittelt, welche Patientengruppen von einer telemedizinischen Versorgung besonders profitieren. Bei einem gezielten Einsatz von Telemonitoring bei Herzinsuffizienzpatienten mit einer linksventrikulären

Auswurfraction von 25–35 % kann die kardiovaskuläre Mortalität drastisch gesenkt werden [KB10].

Zur Erkennung selten auftretender symptomatischer Rhythmusstörungen bietet sich die Telediagnostik an. In Abbildung 3.1 ist das ideale Verfahren zur Diagnostik von Rhythmusstörungen gezeigt: Kann trotz Basisdiagnostik und 24 h-EKG keine Diagnose gefällt werden, kommen – je nach Symptomatik – Loop- oder Post-Event-Rekorder zum Einsatz. Da ein Einsatz dieser Ereignis-getriggerten Geräte in der Regel nicht von den Krankenkassen übernommen wird, gehören sie noch nicht zur Routine in der Kardiologie.

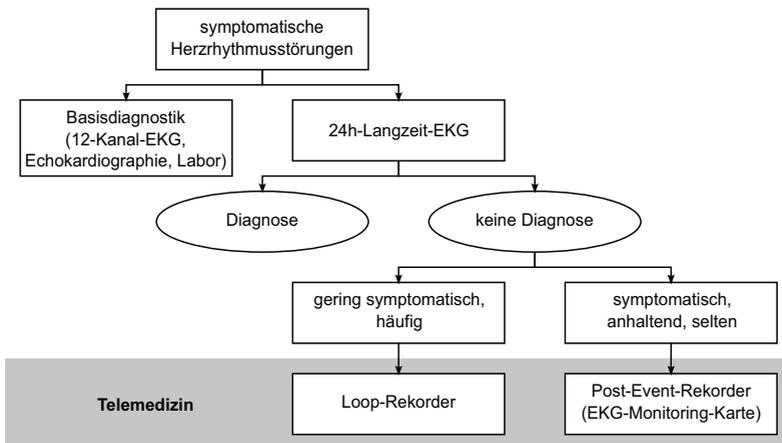


Abbildung 3.1: Einsatz von Telemedizin zur Diagnostik symptomatischer Herzrhythmusstörungen [Sch08]

3.1.3 Grenzen der Telemedizin

Obwohl die ersten großen Telemedizin-Studien in Deutschland abgeschlossen sind, gibt es hier immer noch Akzeptanzprobleme. Auf Seiten der Patienten ist dafür unter anderem die Angst vor etwas Neuem bzw. der ungewohnte Umgang mit neuen technischen Geräten und die Anonymisierung des Arzt-Patienten-Verhältnisses verantwortlich [Lee09]. Aber auch auf Seiten der Mediziner ist die Akzeptanz verhalten: Zum einen fehlen noch immer umfassende Abrechnungsmöglichkeiten, zum anderen sind die eingesetzten Geräte noch unausgereift.

Gerade beim EKG-Telemonitoring können unausgereifte Gerätekonzepte einen enormen Mehraufwand für den behandelnden Arzt bedeuten. Wenn in einem sicherheitskritischen Szenario wie bei der LifeVest [ZOLa] zu viele falsch-positive Alarme an den Mediziner gesendet werden, hat dieser kaum die Möglichkeit, alle betreffenden EKG-Sequenzen zu beurteilen. An dieser Stelle ist eine Relevanzbewertung des Telemonitoringsystems unabdingbar.

3.2 EKG-Analyse

Mit dem Einsatz der Telemedizin in der EKG-Überwachung steigen die Anforderungen an die EKG-Analyse. Aufgrund der großen anfallenden Datenmenge ist eine zuverlässige, automatische EKG-Analyse unumgänglich. Da die Rhythmus- und Schlagklassifikationen zu weiten Teilen auf eine zuverlässige Erkennung der QRS-Komplexe aufbauen, ist diese der zentrale Teil der automatischen EKG-Analyse.

3.2.1 QRS-Erkennung

Mit dem Thema QRS-Erkennung bzw. der Verbesserung der automatischen QRS-Erkennung beschäftigen sich viele Forschungsgruppen. Einen guten Überblick über die verschiedenen Verfahren liefert [Koh02].

Ein weit verbreiteter und schneller Algorithmus ist der Open Source ECG Analysis Algorithm (OSEA) von [Ham02]. Dieser Algorithmus ist eine Weiterentwicklung des Pan-Tomkins-Algorithmus [Pan85]; er arbeitet im Zeitbereich, die Erkennung des QRS-Komplexes erfolgt auf dem mehrfach gefilterten EKG-Signal. Der OSEA ist als freie Software unter der General Public License (GPL) verfügbar und lässt sich somit leicht einsetzen. Mit geringen Einbußen in der Detektionsgüte kann er sogar auf leistungsschwachen Mobilprozessoren eingesetzt werden. Die meisten Verfahren zur QRS-Detektion im Zeitbereich sind ähnlich aufgebaut [Pah84]. Verschiedene Implementierungen dieser Art werden in [Fri90] verglichen, ein Schwerpunkt ist dabei die Performanz im gestörten EKG.

Mit zunehmender verfügbarer Rechenleistung lassen sich auch komplexere Algorithmen auf mobilen Prozessoren umsetzen. Gute Ergebnisse haben in diesem Zusammenhang Verfahren gezeigt, die die Wavelet-Transformation einsetzen. Ein Maßstab für solche Algorithmen ist die Implementierung von [Li95].

Durch Hinzunahme eines Neuro-Fuzzy-Entscheidungers konnten die Analyseergebnisse weiter verbessert werden [vW05, vW06]. Diese Algorithmen benötigen zwar alle deutlich mehr Rechenleistung als ein einfaches Verfahren wie der OSEA, sie lassen sich aber dennoch auf einem Mobilsystem umsetzen [Zau08].

Die Sensitivität und positive Prädiktivität dieser QRS-Detektoren liegt bei ungestörtem EKG bei über 99 % (s. Tab. 3.1). Ist das EKG jedoch durch Bewegungsartefakte gestört, sinkt die Erkennungsgüte sehr schnell ab. Interessant ist deshalb der Ansatz, solche Zustände zu erkennen und als weitere Parameter in die QRS-Erkennung einfließen zu lassen. Die Arbeit von [Li07] stellt eine solche Möglichkeit vor: Mit Hilfe eines Beschleunigungssensors werden Bewegungen erkannt, je nach Intensität der Bewegung wird zwischen zwei verschiedenen QRS-Detektoren hin und her geschaltet. Dafür wurde ein QRS-Detektor implementiert, der im gestörten EKG akzeptable Ergebnisse erzielt, gefolgt von einem weiteren QRS-Detektor, dessen Stärke das ungestörte EKG ist.

Tabelle 3.1: Erkennungsgüte verschiedener QRS-Detektoren auf der MIT/BIH-Datenbank

Algorithmus	Se [%]	pP [%]
von Wagner [vW06]	99,86	99,36
OSEA [Ham02]	99,74	99,81
Afonso [Afo99]	99,59	99,56
Li [Li95]	99,90	99,94

3.2.2 Kanalentscheidung

Die QRS-Detektion kann auf einem oder auf mehreren EKG-Kanälen durchgeführt werden. Steht mehr als ein EKG-Kanal zur Verfügung, kann im Vorfeld durch eine automatische Kanalentscheidung der am wenigsten gestörte EKG-Kanal für die Analyse gewählt werden. [Chi07] beschreibt einen solchen QRS-Detektor, der automatisch den besten Kanal auswählt. Er berechnet dafür einen Rausch-Index, der der Quotient aus der durchschnittlichen geschätzten Energie von jedem T-P-Intervall geteilt durch die durchschnittliche geschätzte Energie von jedem detektierten QRS-Komplex ist. Je nach Höhe des Rausch-Indexes wird der Kanal zur weiteren Analyse herangezogen oder nicht. Auch [Moo82] versucht verrauschte EKG-Sequenzen in einem Zweikanal-EKG zu erkennen.

Das Ziel seiner Methode ist es, die Erkennung von ventrikulären Extrasystolen zu verbessern. [Chr04] stellt einen flexiblen Algorithmus zur Mehrkanal-EKG-Analyse vor, der das EKG mit einem aus mehreren Parametern berechneten adaptiven Schwellwert vergleicht.

3.2.3 Schlagklassifikation

Ist ein QRS-Komplex gefunden, ist es für die weitere Analyse wichtig, ob sich dieser in der Morphologie von den nicht-pathologischen QRS-Komplexen unterscheidet. Auf diese Weise lässt sich herausfinden, ob der Schlag ventrikulären oder supraventrikulären Ursprungs ist bzw. ob ein Schenkelblock vorliegt. Ist das EKG artefaktbehaftet, lassen sich ventrikuläre Ereignisse nur schwer von Störungen unterscheiden – dies gilt sowohl für den menschlichen Betrachter als auch für automatische Algorithmen [Chi90].

Der OSEA nutzt zur Schlagklassifikation den RR-Abstand und die Morphologie. Typische Morphologie-Parameter sind Breite, Höhe und Flankensteilheit des Schlags. Wird der RR-Abstand miteinbezogen, fällt die Erkennung von Schenkelblöcken oder deformierten, aber rhythmischen ventrikulären Schlägen schwerer.

In der Arbeit von [Jek08] werden verschiedene Klassifikationsverfahren (k^{th} Nearest Neighbor (kNN), Fuzzy Logic, Linear discriminant analysis, Neuronale Netze) verglichen. Es zeigt sich, dass die Ergebnisse der Klassifikatoren sehr dicht bei einander liegen. Viel entscheidender ist die Auswahl geeigneter Trainingsdaten – idealerweise wird ein solcher Algorithmus auf Daten desselben Patienten trainiert, bei dem er auch zum Einsatz kommt.

Nutzt man mehrere EKG-Kanäle zur Unterscheidung zwischen ventrikulären und supraventrikulären Schlägen, lässt sich diese noch verbessern. [Bar98] nutzt in seiner Arbeit ein adaptives neuronales Netz, das diese Entscheidung im Mehrkanal-EKG trifft. Auch der Algorithmus von [vW05] arbeitet mit einem Neuro-Fuzzy-System, das Parameter aus mehreren EKG-Kanälen berücksichtigt.

3.2.4 Rhythmusanalyse

Sind die Position und die Morphologie (deformiert oder normal) eines QRS-Komplexes bekannt, kann eine Rhythmusanalyse vorgenommen werden. Bei

Normal-Schlägen lassen sich über den RR-Abstand supraventrikuläre Extrasystolen, Bradykardien, Tachykardien und Pausen erkennen. Kommen deformierte Schläge hinzu, können ventrikuläre Extrasystolen (auch als Bigemini, Couplets und ähnliches) und ventrikuläre Tachykardien (VT) erkannt werden. Bei schnellen VTs kann aber oft eine Unterscheidung der einzelnen QRS-Komplexe nicht mehr durchgeführt werden, da die Herzfrequenz so hoch ist, dass ein Herzschlag in die vom Algorithmus angenommene Refraktärphase des vorangegangenen Herzschlags fällt.

Um solche schnellen, meist pulslosen ventrikulären Tachykardien und ebenso Kammerflimmern oder Kammerflattern (ventrikuläres Flattern, VF) erkennen zu können, werden weitere Analysealgorithmen benötigt. Diese arbeiten nicht mehr auf dem Prinzip der Schlägerkennung, sondern analysieren die Morphologie des gesamten Signals über einen längeren Zeitraum, meist in der Größenordnung von 5–10 s. Dabei handelt es sich um einen Kompromiss zwischen dem möglichst schnellen Erkennen einer Therapiekonsequenz (z. B. Defibrillation) und einem – bei längerer Analyse – besseren Detektionsergebnis.

Einen Überblick über verschiedene Methoden zur Erkennung von VT/VF geben [Cla93] und [Jek00]. Der von [Jek04] vorgestellte Algorithmus analysiert das EKG über 10 s im Zeitbereich. Der nichtlineare Algorithmus von [Zha99, Zha00] nutzt die sogenannte Complexity Measure zur Erkennung von VT/VF-Sequenzen. Ab einer Fensterlänge von 7 s konnte eine sehr hohe Sensitivität und Spezifität erreicht werden.

Neben der VT/VF-Erkennung wird auch für die Detektion von Vorhofflimmern (Atrial Fibrillation, AF) ein eigener Algorithmus benötigt. Im Gegensatz zu VT/VF ist ein Vorhofflimmern nicht akut lebensbedrohlich, kann aber langfristig das Schlaganfall-Risiko stark erhöhen [Wol91]. Die Therapie kann medikamentös oder über eine Kardioversion erfolgen [Hoh05].

Die Detektion von Vorhofflimmern kann direkt auf dem EKG-Signal ausgeführt werden, indem das eigentliche Vorhofflimmern, also Grundlinienschwankungen zwischen zwei QRS-Komplexen, untersucht wird. Aufgrund des schlechten Signal-zu-Rausch-Verhältnis ist dieses Verfahren im gestörten Langzeit-EKG nicht praktikabel. Da Vorhofflimmern zu einem sehr unregelmäßigen Herzrhythmus führt, ist es für die automatische Analyse möglich, dieses zu erkennen. Viele Detektionsalgorithmen, die mit extern abgeleiteten EKG-Signalen arbeiten, nutzen deshalb nur die RR-Intervalle als Eingangsparameter. In der Arbeit von [Log05] werden erst alle RR-Intervalle normiert, anschließend wird die Varianz

in 10 s-Abschnitten berechnet. Übersteigt die Varianz ein gewisses Maß, liegt ein Vorhofflimmern vor.

Die in [Tat00] vorgestellte Methode betrachtet die Häufigkeitsverteilung der Länge von RR-Intervallen in einem Abschnitt von 101 Herzschlägen (das entspricht ca. 80 s). Anhand eines Ähnlichkeitstests wird entschieden, ob ein Vorhofflimmern vorliegt oder nicht.

[Art91] ordnet jedes RR-Intervall als kurz, lang oder normal ein. Diese nicht-lineare Transformation ist die Basis für ein Neuronales Netz, welches für jeden Herzschlag – verglichen mit den letzten 30 Herzschlägen – eine eigene Entscheidung trifft.

3.2.5 Zusammenfassung

Die automatische EKG-Analyse ist ein technisch und wissenschaftlich weit bearbeitetes Feld. Neue Methoden und Algorithmen werden nur noch selten präsentiert, da die Erkennungsgüte – insbesondere bei der QRS-Detektion – bereits nahe am möglichen Maximum liegt.

Der in dieser Arbeit eingesetzte Open Source ECG Analysis Algorithm vereint gute Erkennungsleistungen mit minimalem Ressourcenanspruch und eignet sich daher auch für mobile Anwendungen. Der online verfügbare Quelltext der unter der GPL stehenden Software macht den Einsatz besonders attraktiv. Die integrierte Schlagklassifikation reicht aus, um darauf eine weiterführende Rhythmusanalyse aufzubauen.

Da der OSEA nur für einen EKG-Kanal ausgelegt ist, muss eine externe Kanalentscheidung integriert werden. Da viele der vorhandenen Testdaten aufgrund der verwendeten Hardware nur eine EKG-Ableitung besitzen, fällt dieser Nachteil weniger ins Gewicht.

3.3 Artefaktbehandlung

Bei der Langzeit-EKG-Überwachung soll der Patient möglichst wenig in seiner Lebensweise eingeschränkt werden. Dies bedeutet auch, dass der Patient wie gewohnt körperliche Aktivitäten ausübt. Dadurch entstehen vermehrt Bewegungsartefakte, die das EKG-Signal über lange Zeiträume unbrauchbar machen können. Durch die höhere Artefaktanfälligkeit von Trockenelektroden wird

dieser Effekt noch verstärkt, sobald langzeitverträgliche, textilintegrierte EKG-Systeme im Einsatz sind.

3.3.1 Artefakterkennung

Mit Hilfe von Verfahren zur automatischen Artefakterkennung wird versucht, die bei der unüberwachten EKG-Aufzeichnung auftretenden Störungen zu kennzeichnen. Um die während der Messung auftretenden Bewegungsartefakte zu erkennen, gibt es verschiedene Ansätze, die sich teilweise neben dem EKG noch auf weitere Signale stützen.

Artefakterkennung ohne Kontextsignale

Die Arbeiten von [Red08, Lov10] beschäftigen sich mit der Artefakterkennung in unüberwachten EKG-Aufnahmen mit einem stationären Tele-EKG. Der Patient nimmt in diesem Fall täglich eine kurze EKG-Sequenz auf, die anschließend übermittelt wird. Um dem Anwender ein direktes Feedback über die EKG-Qualität geben zu können, ist ein entsprechender Algorithmus implementiert. Vier verschiedene Analysen kommen zur Artefakterkennung zum Einsatz:

- Mit einem 1 Hz-Tiefpass werden starke Grundlinienschwankungen im EKG detektiert, um Bewegungsartefakte zu ausschließen.
- Wenn das EKG in ein 5 %-Fenster um die Versorgungsspannung gerät, wird dieser Bereich großzügig als Artefakt markiert.
- Hochfrequentes Rauschen größer als 40 Hz wird als EMG-Störung markiert.
- Wenn das Signal zu lange unter einer Schwelle von 0,02 mV bleibt, wird es als zu niederamplitudig markiert.

Auf diese Weise kann schon während der EKG-Aufzeichnung überprüft werden, ob das Signal einen verwertbaren 10 s-Abschnitt enthält, der für eine weitere Analyse verwendet werden kann. Für ein Langzeit-Monitoring lässt sich dieses Verfahren allerdings nur übernehmen, wenn man auf die Erkennung der niederamplitudigen Signale verzichtet, da es ansonsten Probleme bei der Erkennung von Pausen geben könnte, da diese fälschlicherweise als Artefakt markiert werden könnten.

Mit der Artefakterkennung in einem textilintegrierten mobilen Monitoringssystem beschäftigt sich [Müh04]. In einem Brustgurt mit integrierten EKG-Trockenelektroden ist ein zweiachsiger Beschleunigungssensor untergebracht.

Versuche, die auftretenden Artefakte mit Hilfe des Beschleunigungssignals herauszufiltern, schlugen fehl. Eine Artefakterkennung erfolgt jedoch nur über das Ergebnis der automatischen QRS-Erkennung: Ist die Herzrate außerhalb eines physiologischen Bereichs oder ändert sie sich zu stark, gilt die entsprechende Sequenz als artefaktbehaftet. Die Bewegungsdaten werden lediglich für eine Ruhe-Erkennung genutzt. Die gesamte Analyse wird offline mit Matlab vorgenommen.

In [Rap04] wird ein Algorithmus vorgestellt, mit dem EMG-Störungen im EKG gefunden werden können. Das Augenmerk liegt hierbei auf einem schnellen Algorithmus, der auch für große Datenmengen geeignet ist. Dazu wird ein morphologisches Filter sowie eine automatische QRS-Detektion verwendet, um das EMG aus dem aufgezeichneten EKG zu isolieren. Anhand der Varianz dieses Signals wird entschieden, ob ein Artefakt vorliegt oder nicht.

[Bro06] nutzt die Wavelet-Transformation, um die hochfrequente Störung der Elektrokoagulation während einer Operation zu detektieren. Diese hochfrequente Störung lässt sich in bestimmten Skalen der Wavelet-Transformierten präzise erkennen, sodass anschließende Algorithmen zur Herzfrequenzberechnung diese Information nutzen können.

Artefakterkennung mit Kontextsignalen

[Kis07] nutzt in seiner Arbeit einen dreiachsigen Beschleunigungssensor, um Bewegungsartefakte im EKG bei Schlafenden zu erkennen. Die eigentliche Artefakterkennung wird in dieser Arbeit jedoch von einer kommerziellen EKG-Analysesoftware vorgenommen. Das Bewegungssignal wird lediglich dazu genutzt, um zwischen Bewegungsartefakten und sonstigen Artefakten zu unterscheiden. Basis dafür ist eine Lageänderung, die über einen Wechsel der 1 g-Komponente der Gravitation in den Achsen des Beschleunigungssignals detektiert werden kann. Validiert wird gegen eine manuell erstellte Referenz.

Die Arbeit von [Ott10] stellt ein Gesamtsystem zur Artefakterkennung vor. Das dafür entworfene Aufnahmesystem misst neben dem einkanaligen EKG für jede Elektrode die Impedanz des Elektrode-Haut-Systems und die Beschleunigung der EKG-Elektrode. Auf Basis der so gewonnenen Daten wird mit Hilfe der aufgezeichneten Kontextinformationen und einem adaptiven Filter der Artefaktanteil im EKG geschätzt.

3.3.2 Artefaktunterdrückung

Besser als eine reine Erkennung von Artefakten im EKG, ist eine aktive Artefaktunterdrückung. Leider lassen sich insbesondere Bewegungsartefakte nicht durch ein einfaches FIR-Filter reduzieren, da das Frequenzband der Bewegungsartefakte das der QRS-Komplexe überschneidet. Deshalb wird von vielen Arbeitsgruppen eine Artefaktreduktion mit Hilfe weiterer artefaktkorrelierter Sensorsignale angestrebt – oft in Verbindung mit adaptiven Filtern. Die Schwierigkeit besteht darin, ein geeignetes Fehlersignal zu erhalten, mit dem der adaptive Algorithmus gespeist wird. In der Literatur finden sich verschiedene Ansätze, dieses mit dem Fehler korrelierende Signal zu erhalten.

Dehnungssensor

[Ham97, Ham00b] versucht das Fehlersignal mit Hilfe eines Dehnungssensors auf einer EKG-Elektrode zu konstruieren. Dabei wird auf einer Klebeelektrode ein Dehnungsmessstreifen angebracht, sodass sich die Dehnung der Elektrode – und damit indirekt auch die Dehnung der Haut – erfassen lässt. Bei einer Dehnung der Haut ändern sich die elektrischen Eigenschaften der oberen Hautschichten, was sowohl zu einer Impedanz- als auch zu einer Potentialänderung führt und damit das EKG stark beeinflusst.

Im getesteten Verfahren ließen sich großamplitudige Störungen weitgehend herausfiltern, allerdings entspricht die Artefaktquelle – nämlich das Klopfen auf eine EKG-Elektrode – nicht den realen Bedingungen eines mobilen Langzeitmonitorings. Bei der Verwendung von starren Trockenelektroden ist die Hautdehnung über die Elektrode nicht messbar.

Auch in [Liu06] wird die Hautdehnung als Referenzsignal für ein adaptives LMS-Filter genutzt. Der verwendete optische Dehnungssensor ist in den Schaumstoff der Ag/AgCl-Elektrode integriert. Eine Reduktion langsamer, großamplitudiger Dehnungsartefakte ist möglich. Ob ein Einsatz unter Monitoring-Bedingungen eine Verbesserung der QRS-Erkennung bringt, bleibt unklar.

Dehnungssensor und Impedanzmessung

In [Ham00a] wird neben dem erprobten Dehnungssensor noch eine Impedanzmessung zwischen zwei Elektroden durchgeführt. Da die Impedanzmessung

mit einem Messsignal durchgeführt wird, dessen Frequenz um Größenordnungen höher ist als das Frequenzspektrum des EKGs, können die dadurch entstandenen Störungen aus dem EKG entfernt werden. Nachteilig ist jedoch die bezogen auf die Frequenz nichtlineare Impedanz der Haut (vgl. Kapitel 2.1.4), die insbesondere bei hohen Frequenzen zu niedrig gemessen wird. Der Zusammenhang zwischen einer gemessenen Impedanzänderung und der tatsächlichen Potentialänderung im EKG kann demnach durchaus nichtlinear sein.

Impedanzmessung

[Dev84] versucht in seiner Arbeit, Bewegungsartefakte im EKG mit Hilfe eines aufgezeichneten Elektrodenimpedanzsignals zu reduzieren. Als Datenbasis stehen ihm ca. zehn Stunden über Gel-Elektroden abgeleitetes EKG mit einer Samplingrate von 250 Hz zur Verfügung. Zur Isolierung der Artefakte nutzt er ein adaptives Filter mit $N = 4$ Filtergewichten, erreicht damit aber – auch nach eigener Aussage – nur leichte Verbesserungen. Als Ursache dafür wird auch in diesem Fall der nichtlineare Zusammenhang zwischen Elektrodenimpedanz und Artefakt genannt.

Desweiteren beschäftigt sich die Arbeit mit der Erkennung von artefakt-behafteten EKG-Sequenzen. Dort ist die angewendete Methode erfolgreicher: Die EKG-Aufnahmen liegen in kurzen Sequenzen vor, die einzeln untersucht werden. Dabei wird jeweils das Signal-zu-Rausch-Verhältnis (Signal-to-noise ratio, SNR) einer Sequenz geschätzt und untersucht.

Beschleunigungssensor

[Ray02] verwendet zur Generierung des Fehlersignals einen bzw. zwei einachsige Beschleunigungssensoren, die auf dem Rücken des Probanden auf Höhe der Lendenwirbel angebracht sind. Die Bewegungsartefakte der Aufnahme entstehen durch Fahren auf einem Fahrradergometer. Als Filteralgorithmen werden RLS und LMS verglichen, wobei das Ergebnis mit einem einachsigen Accelerometer und dem LMS-Algorithmus am besten war. Auch hier gilt, dass die Aufnahmebedingungen nicht denen des mobilen Langzeitmonitorings entsprechen, da hier bei weitem störanfälligere Bewegungen wie Laufen, Treppensteigen oder auch Zähneputzen durchgeführt werden. Die Ausrichtung der verwendeten Sensoren wird nicht genannt.

Ein dreiachsiger Beschleunigungssensor am Rumpf dient in [Liu11] als Referenzeingang für ein adaptives LMS-Filter. Den Beispielen kann man entnehmen, dass niedrigamplitudige Bewegungsartefakte deutlich reduziert werden, aber auch die Amplitude des QRS-Komplexes stark verkleinert wird und sich dessen Morphologie ändert. Eine Verbesserung der QRS-Detektion wird nicht gemessen.

Die Firma Zoll setzt in ihren Defibrillatoren mit der See-Thru CPR ein System ein, das die bei der Herzdruckmassage auftretenden Artefakte herausrechnet [Pal09, ZOLb]. Ein Beschleunigungssensor nahe der Defibrillationselektrode auf dem Sternum liefert das notwendige Referenzsignal. Das gefilterte EKG wird aber lediglich für die Anzeige genutzt und fließt nicht in die EKG-Analyse mit ein.

Beschleunigungssensor und Magnetfeldsensor

Neben einem Beschleunigungssensor (dreiaxsig) nutzt [Ton02] auch einen 2-achsigen Magnetfeldsensor (AMR-Sensor) und vergleicht die Ergebnisse miteinander. Die Sensoren sitzen unmittelbar auf den Ableitelektroden und messen somit die tatsächliche Elektrodenbewegung – im Fall des 2-achsigen AMR-Sensors nur die Bewegung parallel zum Körper. Als Adaptionalgorithmus wird ein LMS-Schätzer benutzt. Die Artefakte während der Aufzeichnung werden durch Drücken auf die Elektrode, Drücken auf die Haut neben der Elektrode und durch Ziehen am Elektrodenkabel provoziert. Die so entstandenen Artefakte konnten weitgehend unterdrückt werden, dabei waren die Ergebnisse mit dem Beschleunigungssensor besser als die mit dem AMR-Sensor.

Störpotential

[Luo95] versucht, das Störsignal direkt aufzuzeichnen, indem er zwei EKG-Elektroden in einem Abstand von 5 mm auf dem Oberarm platziert. Eine davon wird für die Ableitung II genutzt, die zweite zur Aufzeichnung eines Referenzsignals, welches dann als Second Channel für die Artefaktunterdrückung dient. Mit einem adaptiven RLS-Filter wird ein System erreicht, was Artefakte (Anhand der Bilder scheint es sich hier primär um EMG-Artefakte zu handeln) aus einem gestörten EKG herausrechnen kann. Ist das EKG allerdings ungestört und liegt kein Rauschen am Referenzeingang an, wird das Signal deutlich verschlechtert.

Weitere Methoden ohne Kontextsignale

In [Chu89] wird beschrieben, wie man morphologische Filter zur Reduktion der Grundlinienschwankungen und zur Rauschunterdrückung einsetzen kann. Die Filterung mit morphologischen Filtern ist sehr effektiv und benötigt keine weiteren Signale, kann aber nur einen Teil der Bewegungsartefakte eliminieren.

[Jan92] stellt eine Methode vor, Grundlinienschwankungen mit Hilfe von adaptiven Filtern zu entfernen, jedoch ohne auf ein zusätzlich gemessenes Referenzstörsignal angewiesen zu sein. Dafür wird ein *adaptive impulse correlated filter* (AICF) eingesetzt, dessen Referenzsignal die zuvor erkannten QRS-Komplexe bilden. Die Ergebnisse des Algorithmus sind gut, jedoch muss die Position der QRS-Komplexe im Vorfeld bekannt sein. Aus diesem Grund lässt sich die von [Jan92] beschriebene Methode nicht für die Verbesserung der QRS-Detektion einsetzen.

Auch [Tha91] beschreibt eine effektive Methode, ein EKG mittels adaptiver Filter von Störungen zu befreien – allerdings muss auch hier bereits eine erfolgreiche QRS-Triggerung erfolgt sein. Das Verfahren ähnelt dem von [Jan92].

[Ira02] stellt eine Filtermethode vor, die periodische bioelektrische Signale – unter anderem auch EKG-Signale – von niedrigamplitudigem Rauschen befreit, ohne dabei jedoch das Signal zu deformieren. Für die Entfernung von Bewegungsartefakten scheint diese Methode jedoch nicht geeignet. Auch die Arbeit von [Kim06] konzentriert sich auf die Entfernung von hochfrequenten Störungen und niedrigfrequenten Grundlinienschwankungen. In einem ersten Schritt wird die Art und Schwere der Störung geschätzt, diese Ergebnisse bilden dann einen zusätzlichen Eingang für das verwendete Filter, welches auf neuronalen Netzwerken und generischen Algorithmen aufbaut.

Die Arbeiten von [Yoo07a, Yoo07b] konzentrieren sich auf das Entfernen von Bewegungsartefakten bei textilintegrierten EKG-Systemen – als Referenz für das adaptive Filter wird jedoch ein Differenzsignal genommen, das aus dem textilintegrierten EKG-System und einem EKG-System mit normalen Ag/AgCl-Elektroden abgeleitet wurde. Will man auf diese Klebeelektroden verzichten, kann dieser Ansatz nicht weiter verfolgt werden.

[Ben95] entfernt mit einem mehrdimensionalen adaptiven Filter EMG-Störungen aus dem EKG. Als Signaleingang dient hier ein dreikanaliges EKG, bei dem ein Kanal als primärer Eingang und die beiden weiteren als Referenz-Eingang genutzt werden. Auf diese Weise können die hochfrequenten Störungen

zuverlässig entfernt werden, ohne das EKG-Signal stark zu verformen. Die Arbeit von [DV84] präsentiert eine einfache Hardware-Lösung zur R-Zacken-Erkennung in EMG-gestörtem EKG.

[Mil06] vergleicht in seiner Arbeit zwei verschiedene Möglichkeiten der Artefaktreduktion: Zum einen wird neben einem 1-Kanal-EKG das Signal eines Beschleunigungssensors genutzt, um mit Hilfe eines adaptiven LMS- oder RLS-Filters die Störungen zu entfernen; zum anderen wird die Independent Component Analysis (ICA) genutzt, um beide Kanäle eines 2-Kanal-EKGs von den Artefakten zu separieren. Die Ergebnisse der zweiten Methode werden dabei als überlegen bewertet. In [Mil08] werden die Ergebnisse aufgegriffen und die ICA für die Artefaktreduktion weiter untersucht. Eine direkte Auswirkung auf die QRS-Erkennung wird nicht getestet, die Ergebnisse sehen aber sehr vielversprechend aus. Voraussetzung für das beschriebene Verfahren ist allerdings eine ungestörte Referenzelektrode, sodass die Anwendung in einem mobilen System ausgeschlossen werden kann.

Die Arbeiten von [Dju05] und [Big04] beschäftigen sich ebenfalls mit der ICA im Zusammenhang mit Biosignalanalyse und Artefaktreduktion. Besonders in der Arbeit von [Dju05] kommt zum Ausdruck, dass die ICA zur Artefaktreduktion kaum geeignet ist. Grund hierfür ist, dass die Voraussetzungen für eine ICA nur unzureichend erfüllt sind. So sind die aufgenommenen Biosignale nicht immer statistisch unabhängig. Weiterhin bleibt die Bedingung, dass die Signale nicht Gauß-verteilt sind, üblicherweise unerfüllt. Ein weiterer gegen die Verwendung der ICA sprechende Punkt ist, dass mit diesem Verfahren nur Linearkombinationen der verschiedenen Quellen getrennt werden können. Die vorliegenden Signale korrelieren zwar miteinander, eine Linearkombination liegt aber keinesfalls vor.

3.3.3 Zusammenfassung

Die hier beschriebenen Verfahren zeigen, dass einfache Grundlinienschwankungen oder hochfrequente EMG-Störungen gut aus dem EKG-Signal entfernt werden können. Betrachtet man aber den breiten Querschnitt der durch Bewegungen des täglichen Lebens verursachten Störungen, ist die Artefaktreduzierung eine große Herausforderung.

Für keines der Verfahren gibt es eine belastbare Aussage über die tatsächliche Verbesserung der automatischen EKG-Analyse. Zum Teil wird das gefilterte

EKG rein qualitativ bewertet, andere wiederum versuchen, die Verbesserung mit Hilfe eines Fehlersignals zu quantifizieren. Eine Aussage über die verbesserte QRS-Detektion lässt sich hieraus leider nicht ableiten.

Eine Übersicht der Second-Channel-Methoden gibt Tabelle 3.2. Vergleicht man bei diesen Methoden das Referenzsignal mit dem gestörten EKG, erkennt man oft deutlich eine Übereinstimmung zwischen Artefakten im EKG und Schwankungen im Referenzsignal (vgl. [Ham00b, Abb. 5]). Für solche speziellen Störfälle korrelieren Störreferenz und die Störung im EKG viel mehr, als es bei unbekanntem Störquellen der Fall ist. Damit ist auch der Adaptionsalgorithmus wirkungsvoller. Die verschiedenen Ansätze zeigen, dass mit Hilfe adaptiver Filter nur dann eine deutliche Signalverbesserung zu erreichen ist, wenn das Referenzsignal mit den Störungen im EKG sehr gut korreliert.

Bei einer Reduzierung der Artefakte trotz weniger guter Korrelation (vgl.

Tabelle 3.2: Übersicht über die in der Literatur beschriebenen Verfahren zur Artefaktreduktion mit Hilfe eines Second Channel

Autor	Quelle	Second Channel
Devlin et. al.	[Dev84]	Impedanz
DeVel et. al.	[DV84]	Hardware-Lösung
Thakor et. al.	[Tha91]	QRS-Erkennung, adapt. Filter
Jane et. al.	[Jan92]	QRS-Erkennung
Bensadoun et. al.	[Ben95]	3-Kanal EKG
Luo et. al.	[Luo95]	Störpotential
Hamilton et. al.	[Ham97]	Hautdehnung, adapt. Filter
Hamilton et. al.	[Ham00b]	Hautdehnung, adapt. Filter
Hamilton et. al.	[Ham00a]	Impedanz, Hautdehnung, adapt. Filter
Raya et. al.	[Ray02]	Beschleunigung
Tong et. al.	[Ton02]	AMR, Beschleunigung, adapt. Filter
Milanesi et. al.	[Mil06]	3-Achs-Beschleunigung, ICA vs. adapt. Filter
Liu et. al.	[Liu06]	Hautdehnung, adapt. Filter
Chen et. al.	[Che07]	Beschleunigung
Milanesi et. al.	[Mil08]	Referenz-EKG
Liu	[Liu11]	3-Achs-Beschleunigung, adapt. Filter

[Liu11, Abb. 5]) ist hingegen fraglich, inwiefern die Störreferenz überhaupt Einfluss auf die Artefaktreduktion hatte.

Für die Verbesserung der automatischen EKG-Analyse sind Algorithmen ungeeignet, die eine a-priori-Information wie die QRS-Detektion voraussetzen. Da durch die Signalfilterung eine anschließende QRS-Detektion verbessert werden soll, liegen im Vorfeld keine Informationen über die korrekte Position der QRS-Komplexe im Datensatz vor.

3.4 Bewegungserkennung

Um die Bewegungs- und Aktivitätsinformationen in die EKG-Analyse integrieren zu können, müssen entsprechende Daten aufgezeichnet werden. In den meisten Fällen bildet das Signal von Beschleunigungssensoren die Grundlage für die weitere Analyse.

3.4.1 Aktivitätserkennung

In [iC05] wird ein einfaches Verfahren zur Unterscheidung von verschiedenen Bewegungsarten mit einem Beschleunigungssensor beschrieben. Über einen Entscheidungsbaum werden anhand von wenigen Parametern die Aktivitäten Liegen, Stehen / Sitzen, Gehen, Laufen, Treppensteigen und sonstige unterschieden. Die Genauigkeit des Klassifikators liegt bei 80 %. Als Sensor wurde ein vertikal ausgerichteter einachsiger Beschleunigungssensor auf der Brust verwendet. Abgesehen von der schlechten Erkennung von körperlicher Ruhe eignet sich dieser Ansatz gut für eine einfache Aktivitätserkennung.

Die Arbeiten von [Paw07c, Paw07b, Paw07a] beschäftigen sich ebenfalls mit der Erkennung von Aktivitäten – Ziel ist jedoch bei ihnen, auf Bewegungssensoren zu verzichten. Stattdessen soll die Art der Bewegung allein aus den Artefakten im EKG bestimmt werden.

In den Arbeiten von [Jat07a, Jat10] wird ein neuronales Netz eingesetzt, um verschiedene Aktivitäten zu klassifizieren. Das selbstlernende System nutzt die Daten eines dreiachsigen Beschleunigungsmessers, der in einem Brustgurt getragen wird. Die Fehlerrate der Aktivitätserkennung liegt bei etwa 5 %.

3.4.2 Energieumsatzschätzung

Darauf aufbauend wird in [Jat10] eine Möglichkeit beschrieben, den Energieumsatz eines Menschen anhand der aufgezeichneten Bewegung zu schätzen. Die Basis für die Energieumsatzschätzung ist der *EEAC*-Wert, der aus den Beschleunigungsdaten a_x , a_y und a_z berechnet werden kann:

$$EEAC = \frac{1}{n} \cdot \sum_{i=1}^n \sqrt{a_{xi}^2 + a_{yi}^2 + a_{zi}^2} \quad (3.1)$$

Um von diesem Wert auf den Energieumsatz *EE* zu kommen, wird ein Modell benötigt, das neben Größe, Alter und Gewicht des Probanden auch aktivitätsspezifische Koeffizienten b enthält:

$$EE = b_0 + b_1 \cdot EEAC + b_2 \cdot \text{Größe} + b_3 \cdot \text{Gewicht} + b_4 \cdot \text{Alter} \quad (3.2)$$

Da sich der Zusammenhang zwischen *EE* und *EEAC* je nach Aktivität ändert, muss für jede erkannte Aktivität ein eigenes Koeffizientenset b_i erstellt werden. Auf diese Weise lässt sich der Energieumsatz mit einer Genauigkeit von bis zu 90–95 % bestimmen.

3.4.3 Sturzerkennung

Neben dem Erkennen von Aktivitäten wird der Sturzerkennung besonders viel Aufmerksamkeit verliehen. Die Sturzerkennung ist eine interessante Ergänzung bestehender Hausnotrufsysteme und verspricht in diesem Zusammenhang ein großes Marktpotential. Die Detektion wird üblicherweise auf Basis von Beschleunigungssensoren vorgenommen, die gegebenenfalls durch Gyroskope unterstützt werden. Die Arbeiten [Nou07, Yu08] geben einen guten Überblick über verschiedene Methoden zur Sturzerkennung.

Bei dem Ansatz von [Ber09] werden die aufgezeichneten Beschleunigungsdaten über die Mahalanobis-Distanz mit der Referenzsignatur eines Sturzes verglichen. Auf der eigenen, nichtveröffentlichten Testdatenbank konnte eine Sensitivität von 90 % bei einer Spezifität von 97 % erreicht werden.

3.4.4 EKG im Aktivitätskontext

Das in [Fis10] vorgestellte System zeichnet das EKG und Beschleunigungsdaten auf, um zwischen verschiedenen Aktivitäten wie z. B. Laufen, Liegen und Treppensteigen unterscheiden zu können. Der Energieumsatz des Patienten wird qualitativ (gering, mittel, hoch) abgeschätzt. Eine direkte Verknüpfung von Aktivitäts- und EKG-Daten liegt nicht vor.

[Che07] beschreibt ein EKG mit Beschleunigungssensoren, das ein Mobiltelefon als Datenverarbeitungseinheit nutzt. Über das Mobilfunknetz kann ein abnormes EKG zusammen mit den Bewegungsinformationen verschickt werden. Aber auch hier findet keine Verknüpfung zwischen EKG- und Bewegungsdaten statt.

In der Arbeit von [Hea05] werden EKG und Bewegungsdaten online auf einem PDA ausgewertet. Die EKG-Erkennung wird im Kontext von Tachykardien während körperlicher Belastung angesprochen. Ebenso wird vorgeschlagen, die Aktivität als direktes Maß für den Gesundheitszustand zu sehen, da beispielsweise bei herzkranken Patienten der Bewegungsumfang abnimmt. Ob diese Ansätze bereits implementiert sind, bleibt unklar.

In [Jat10, Jat07b] wird eine Möglichkeit präsentiert, wie man die Tachykardieschwelle in Abhängigkeit von der körperlichen Aktivität verschieben kann. Dabei wurden auch die Übergangsbereiche zwischen Aktivitäten berücksichtigt, wie z. B. die Erholungsphase nach einer körperlichen Anstrengung.

Das System von [Yaz08] zeichnet ein 1-Kanal-EKG, Körpertemperatur und dreiachsige Beschleunigungsdaten auf. Über einen PC als Gateway ist das Gerät in der Lage, per E-Mail Benachrichtigungen zu verschicken. Die Datenanalyse läuft auf dem Gateway, sodass sich das System nur für das Home-Monitoring nutzen lässt. Die Auswertung beschränkt sich auf einen unteren Schwellwert für die Herzrate und eine Sturzerkennung über die Amplitude der Beschleunigungssignale.

3.4.5 Zusammenfassung

In den letzten zehn Jahren haben sich viele Arbeitsgruppen mit dem Thema Bewegungsanalyse und Aktivitätserkennung beschäftigt – nicht zuletzt, weil die benötigte Sensorik immer erschwinglicher wird. Man findet in der Literatur viele gute Ansätze zur Erkennung von Aktivitäten oder zur Abschätzung des

Energieumsatzes. Allerdings stehen diese Erkenntnisse in den allermeisten Fällen isoliert von einer EKG-Analyse. Wird eine Verknüpfung vorgenommen, beschränkt sich diese auf die Verschiebung von Tachykardieschwellen während körperlicher Aktivität.

3.5 Geräte und deren Anwendungsszenarien

Auf dem internationalen Markt ist eine Vielzahl an Geräten zur mobilen EKG-Aufzeichnung erhältlich. Die Geräte unterscheiden sich sowohl in ihren funktionalen Eigenschaften als auch in ihrem bestimmungsgemäßen Gebrauch.

3.5.1 Medizinprodukte

Die als Medizinprodukt zugelassenen Geräte dürfen zur medizinischen Diagnostik und zum Monitoring von Patienten eingesetzt werden. Die Entwicklung solcher Produkte entspricht der Norm DIN EN ISO 13485 (Medizinprodukte – Qualitätsmanagementsysteme – Anforderungen für regulatorische Zwecke), der gesamte Produktlebenszyklus unterliegt in Deutschland dem Medizinproduktegesetz (MPG).

In Tabelle 3.3 ist eine Übersicht der verschiedenen Gerätetypen für die unüberwachte EKG-Aufzeichnung gegeben. Für alle Geräte hat ein artefaktfreies EKG-Signal einen hohen Stellenwert. Die automatische Erfassung des Aufnahmekontext wie der körperlichen Aktivität wird jedoch sekundär, wenn der Patient die Aufnahme selber auslösen muss. Durch die Interaktion ist dem Patienten die Aufnahmesituation bewusster und kann in der Anamnese abgefragt werden.

Holter-EKG-Geräte

Damit der Arzt das Patienten-EKG einer Langzeitaufnahme oder die EKG-Sequenz eines Event-Rekorders retrospektiv richtig bewerten kann, ist die Kenntnis eines Zusammenhangs mit der Patientenaktivität oder einer Medikamenteneinnahme wichtig. Beim Holter-EKG muss dafür der Patient ein Protokoll – eine Art Tagebuch – führen und dort alle relevanten Informationen eintragen. Dazu gehören z. B. sportliche Aktivitäten, die Einnahme von

Tabelle 3.3: Typische Applikationsdauer und notwendige Patienteninteraktion für verschiedene Gerätekonzepte

Typ	Applikationsdauer	Interaktion
Holter-EKG	1-2 Tage	möglich (Marker-Taste)
externe Loop-Rekorder	ca. 1 Woche	teilweise notwendig
Post-Event-Rekorder	beliebig	notwendig
kontinuierliches Tele-EKG	> 1 Woche	möglich (Marker-Taste)
implantierbare Loop-Rekorder	max. 14 Monate	möglich (nur mit Aktivierungsgerät)

Medikamenten oder auch der Beginn der Nachtruhe bzw. der Zeitpunkt des morgendlichen Erwachens und Aufstehens. Moderne Langzeitrekorder vereinfachen die Protokollierung mit einer Event-Taste, mit der z. B. zusätzlich eine Sprachaufnahme gestartet wird. Die Aufzeichnung wird zusammen mit einem Zeitstempel im Aufnahmegerät gespeichert und dem Arzt bei der Befundung angezeigt.

In den Holter-EKG-Geräten der neusten Generation ist bereits ein Beschleunigungssensor integriert, der die Patientenbewegung aufzeichnet. Auf dem deutschen Markt befinden sich derzeit die beiden in Abbildung 3.2 gezeigten Geräte mit dieser Eigenschaft: Der Schiller Medilog AR12 plus (seit 2010) und der Getemed CardioMem 4000 (seit 2011) [Sch09, Get]. Beiden fehlt jedoch noch die notwendige Software zur Bewegungsanalyse – die Messdaten werden dem Mediziner lediglich angezeigt, aber nicht weiter interpretiert.

Post-Event-Rekorder

Ein Post-Event-Rekorder – oft auch als EKG-Monitoring-Karte bezeichnet – kommt nur durch den aktiven Einsatz des Patienten zur Anwendung. Die Geräte sind üblicherweise sehr klein gehalten und besitzen integrierte Trockenelektroden. Bei auftretender Symptomatik nimmt der Patient das Gerät und drückt es sich auf die Brust.

Der Vorteil dieser Geräteklasse ist die einfache Handhabung, die im Alltag nicht stört. Verträglichkeitsprobleme mit Elektroden können wegen der kurzen



(a) CardioMem 4000 der Firma Getemed [Get]

(b) Medilog AR12 plus der Firma Schiller [Sch09]

Abbildung 3.2: Holter-EKG-Geräte mit integriertem Beschleunigungssensor

Anwendungszeit nicht auftreten. Ein Nachteil ist aber die hohe Latenzzeit zwischen dem Auftreten der Symptome und der EKG-Registrierung. [Mül09a]

Ein Post-Event-Rekorder wird zur Diagnostik eingesetzt, wenn Symptome vorliegen und diese anhaltend sind (s. Abb. 3.1 auf Seite 35). Außerdem muss der Patient in der Lage sein, das Gerät bedienen zu können. Da hier die Aufnahme manuell ausgelöst wird, geschieht die Analyse des EKGs retrospektiv. Eine telemetrische Datenübertragung erfolgt mittels Bluetooth oder akustisch per Telefon.

Loop-Rekorder

Ein externer Loop-Rekorder leitet üblicherweise ein 1- bis 3-Kanal-EKG am Rumpf ab. Je nach Gerätetyp, analysiert der Rekorder ständig das EKG, speichert es aber nur, wenn bestimmte Events auftreten. Andere Typen speichern das Signal nur, nachdem manuell eine Event-Taste gedrückt wurde. Im Gegensatz zu einem Post-Event-Rekorder speichern Loop-Rekorder eine EKG-Sequenz, die schon einige Sekunden vor dem auslösenden Event beginnt [Mül09a].

Loop-Rekorder können entweder über eine telemetrische Schnittstelle (z. B. akustisch über die Telefonleitung) oder direkt beim Arzt ausgelesen werden. Wie man Abbildung 3.1 entnehmen kann, werden sie für die Diagnostik von asymptomatischen Rhythmusstörungen und Synkopen eingesetzt.

Die beiden auf dem Markt befindlichen implantierbaren Loop-Rekorder (ILR) eignen sich sehr gut zur Synkopendiagnostik und scheinen den externen Loop-Rekordern überlegen zu sein [Pez04]. Der Einsatz ist jedoch immer mit einem invasiven Eingriff verbunden. Das Gerät verfügt vermutlich aufgrund seiner Baugröße nur über einen kleinen internen Speicher und keine zusätzliche Sensorik. Mit Ende der Batterielebensdauer (nach ca. 14 Monaten) oder nach erfolgter Diagnostik wird das Gerät wieder explantiert.

Tele-EKG-Geräte

Tele-EKG-Geräte für die kontinuierliche Aufzeichnung und Analyse des EKGs sind aufgrund der unklaren Kostenübernahme noch nicht etabliert. Ihr Anwendungsfeld ist weniger die Diagnostik, sondern primär das Monitoring von Patienten nach einem Klinikaufenthalt, zur Therapieverlaufskontrolle oder zur besseren medikamentösen Einstellung.

Ein in Deutschland zugelassenes und zum Teil eingesetztes Gerät ist die Life-Vest der Firma Zoll [ZOLa]. Dieses Gerät kombiniert das permanente automatische EKG-Monitoring mit einem integrierten Defibrillator. Die EKG-Reports werden täglich an den behandelnden Arzt versendet.

3.5.2 Studiengeräte

Im Gegensatz zu den Medizinprodukten handelt es sich bei den hier vorgestellten Geräten um EKG-Rekorder, die nicht für medizinische Zwecke eingesetzt werden dürfen. Diese Geräte sind oft auf einen speziellen Einsatzzweck abgestimmt, benutzen häufig unkonventionelle EKG-Ableitungen (da für Studien meist nur die Herzfrequenz relevant ist) und besitzen zum Teil zusätzliche Sensoren wie z. B. einen Beschleunigungssensor oder einen barometrischen Höhenmesser. Die aufgezeichneten Daten können üblicherweise als Rohdaten ausgelesen werden, um sie für wissenschaftliche Zwecke nutzen zu können.

In Abbildung 3.3 sind exemplarisch drei verschiedene Gerätetypen gezeigt. Der ekgMove der Firma movisis GmbH zeichnet ein einkanaliges EKG über in einem Brustgurt integrierte Trockenelektroden auf und überträgt wahlweise die Daten live per Bluetooth. Zusätzlich werden Bewegungsinformationen über einen dreiachsigen Beschleunigungssensor und einen temperaturkompensierten barometrischen Höhenmesser aufgezeichnet. Mit Hilfe dieser Daten können die körperliche Aktivität und der Energieumsatz relativ genau geschätzt werden.



Abbildung 3.3: Nicht-zugelassene EKG-Geräte unterscheiden sich oftmals in Form und Funktion von konventionellen EKG-Rekordern [mov, Zep10, cam]

Der Zephyr BioHarness BT überwacht Herzfrequenz, Atmung, Hauttemperatur und Aktivität. Über eine Bluetooth-Anbindung können die Daten an die proprietäre Software gesendet werden. Dieses Gerät kann laut [Zep10] auf Anfrage auch als Medizinprodukt mit FDA-Zulassung (U.S. Food and Drug Administration) geliefert werden.

Der ActiWave Cardio der Firma CamNtech ist ein hoch miniaturisierter, wasserdichter 1-Kanal-EKG-Rekorder, der direkt mit Hilfe der zwei Klebeelektroden auf der Brust befestigt wird. Er kann EKG- und Beschleunigungsdaten für einen Tag aufzeichnen.

4 Framework zur Entwicklung von Analysealgorithmen

Mit Hilfe eines effizienten Frameworks wird die Entwicklung von Analysealgorithmen – insbesondere für Mobilsysteme – erheblich erleichtert. In diesem Kapitel werden neben dem eigenen Systemkonzept zur Signalanalyse auch die für diesen Anwendungsbereich entwickelten Werkzeuge, Datenformate und Datenbanken vorgestellt.

4.1 Systemkonzept

Diese Arbeit gibt einen Überblick über verschiedene Verfahren, wie man mit Hilfe von parallel aufgezeichneten Kontextsignalen die automatische EKG-Analyse verbessern kann. Abbildung 4.1 zeigt das verwendete Systemkonzept: Neben dem EKG werden die Elektrode-Haut-Impedanz der Trockenelektroden und Bewegungsdaten erfasst. Alle Daten fließen in die EKG-Analyse mit ein. Eine erweiterte Interpretation stellt den Zusammenhang zwischen Kontextinforma-

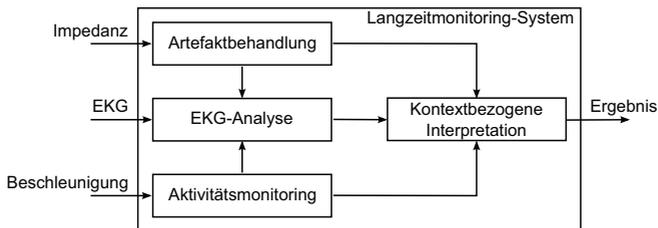


Abbildung 4.1: Systemkonzept: Neben dem EKG werden weitere Signale aufgezeichnet und ausgewertet

tionen und EKG-Analyse her und kann die Ergebnisse in einem täglichen Report zusammenfassen oder Warnungen bzw. Alarme ausgeben.

4.1.1 Problemstellung und Ansatz

Bei der Langzeit-EKG-Überwachung soll der Patient möglichst wenig in seiner Lebensweise eingeschränkt werden. Dies bedeutet, dass das Monitoringsystem selbst möglichst unauffällig und angenehm zu tragen ist. Um diesen Ansprüchen gerecht zu werden, bieten sich textilintegrierte Monitoringsysteme mit Trockenelektroden an. Der große Nachteil solcher Systeme ist jedoch, dass sie anfälliger für Störungen – sogenannte Artefakte – sind.

Dennoch ist die Verwendung von Trockenelektroden im Langzeitmonitoring sinnvoll. Die Vorteile der Langzeitstabilität [Sea00] und Minimierung von Hautirritationen durch das Fehlen von Elektrodengel und Klebstoff überwiegen. Durch die Integration der Elektroden in ein Kleidungsstück bzw. einen Brustgurt kann außerdem immer eine definierte Ableitungsposition sichergestellt werden, auch wenn das Monitoringsystem ohne die Hilfe geschulten Personals angelegt wird.

Um die während der Messung auftretenden Bewegungsartefakte zu erkennen und gegebenenfalls zu unterdrücken, wird ein Artefaktbehandlungsmodul benötigt. Eine vielversprechende Methode zur Artefaktunterdrückung ist die Auswertung von artefaktkorrelierenden Kontextsignalen als sogenannter Second Channel. Einfacher als die Artefaktreduktion lässt sich eine Artefakterkennung realisieren: EKG-Sequenzen, die so stark gestört sind, dass eine fehlerfreie Rhythmusanalyse nicht mehr möglich ist, werden automatisch als artefaktbehaftet markiert und von der Analyse ausgeschlossen.

Wichtig für die Beurteilung von Artefakterkennung oder -reduktion ist die Möglichkeit, die Güte der entwickelten Algorithmen quantifizieren zu können. Hierfür bietet sich die QRS-Detektion als Referenz an: Steigt die Güte der QRS-Erkennung nach der Artefaktreduktion, sind die eingesetzten Algorithmen wirkungsvoll. Des weiteren erhält man aus der automatischen QRS-Erkennung eine Definition für Artefaktbereiche: Als Artefakt wird die EKG-Sequenz bezeichnet, bei der der verwendete QRS-Erkennungsalgorithmus Fehler macht. Nach dieser Betrachtungsweise wird schnell klar, wie eng Artefaktbehandlung und QRS-Erkennung miteinander verknüpft sind.

Das Hinzufügen von Aktivitätsinformationen zum Ergebnis der EKG-Analyse ist für den behandelnden Arzt von zusätzlichem Nutzen [Fot00]. Die EKG-Interpretation verbessert sich, da eine Änderungen der Herzfrequenz als angemessen oder unangemessen beurteilt werden kann. Ebenso können auftretende Arrhythmien als belastungsinduziert markiert werden, gegebenenfalls lassen sich sogar Hinweise auf die kardiale Belastbarkeit des Patienten ableiten.

Die notwendigen Aktivitätsinformationen lassen sich mit Hilfe eines dreiaxigen Beschleunigungssensors ermitteln. Mit den aufgezeichneten Daten lassen sich Aktivitätsklassen, Aktivitätslevel oder der Energieumsatz des Patienten relativ genau bestimmen [Jat07a]. Neben dem Aktivitätsmonitoring können die Beschleunigungsdaten auch zur Sturzdetektion genutzt werden [Nou07, Yu08].

Für EKG-Telemonitoring-Anwendungen ist eine zuverlässige Schlägerkennung (QRS-Detektion) und Schlagklassifikation (Unterscheidung von ventrikulären und supraventrikulären Schlägen) eine wichtige Basis. Um die QRS-Detektion robuster gegen Störungen zu machen, kann man die Informationen aus der Artefakterkennung nutzen und den QRS-Detektor anhalten, sobald ein Artefakt erkannt wird. So kann zum einen verhindert werden, dass Störsignale als falsch-positive QRS-Komplexe erkannt werden, zum anderen werden die internen Schwellwerte des QRS-Detektors nicht verändert, sodass die QRS-Erkennung unmittelbar nach der Störung wieder mit unverminderter Qualität fortgesetzt werden kann. Die Bereiche, in denen die QRS-Detektion aussetzt, müssen gekennzeichnet und von einer Rhythmusanalyse ausgeschlossen werden. Liegen mehrere Kanäle vor, kann in diesem Fall auf einen weniger stark gestörten EKG-Kanal gewechselt werden.

Abhängig von der Aktivität des Patienten kann die Grenze für Tachykardiewarnungen verschoben werden, um falsch-positive Alarme bei körperlicher Belastung zu vermeiden. Werden Arrhythmien erkannt, kann das System mit Hilfe der Bewegungsdaten diese als belastungsinduziert oder nicht belastungsinduziert einstufen. Verfügt das System über eine Energieumsatzschätzung, lässt sich die Belastbarkeit des Patienten ableiten sowie die Reaktion des Herzens auf auftretende körperliche Belastung untersuchen.

Ein mehrkanaliges EKG-Monitoringsystem mit textilintegrierten Trockenelektroden hat unter Umständen Ableitungen, die in bestimmten Körperlagen viele Störungen aufweisen. Besonders häufig ist dies beim Liegen zu beobachten. Durch die veränderte Belastung des Tragesystems können sich Elektroden von der Haut ablösen oder es kommt durch den hohen Druck auf die Elektroden zu

Änderungen der Hautpotentiale. Mit Hilfe der Beschleunigungssensoren kann eine Lageerkennung durchgeführt werden, die in Abhängigkeit der Körperposition unterschiedliche Ableitungen für die EKG-Analyse bevorzugt.

Die Detektion von schnellen ventrikulären Tachykardien und Kammerflimmern muss über eigene Erkennungsalgorithmen erfolgen, da ein herkömmlicher QRS-Detektor hier die einzelnen Herzschläge nicht mehr differenzieren kann. Durch die Verknüpfung der Ergebnisse eines solchen VT/VF-Detektors mit den Resultaten des Aktivitätsmonitorings, lassen sich falsch-positive Alarime minimieren. Dies spielt vor allem dann eine wichtige Rolle, wenn das Monitoringsystem über einen integrierten Defibrillator verfügt oder in der Lage ist, einen Notruf abzusetzen.

4.1.2 Auswahl der Kontextsignale

Beim Langzeit-EKG-Monitoring gibt es viele Faktoren, die das EKG und damit auch die automatische Analyse beeinflussen können (s. Abb. 1.2 auf Seite 3). Bei hoher Sensitivität der EKG-Analyse können hierdurch falsch-positive Alarime ausgelöst werden; ist die Sensitivität zu niedrig, besteht die Gefahr, dass tatsächlich relevante Ereignisse übersehen werden. Eine verlässliche EKG-Analyse trotz der Störfaktoren zu gewährleisten fällt schwer.

Durch die Aufzeichnung der Kontextsignale *Körperbewegung* (Beschleunigung) und die *Elektrode-Haut-Impedanz*, kann man die größten Störfaktoren im EKG automatisch erkennen oder minimieren. Eine veränderte Elektrode-Haut-Impedanz lässt auf Elektrodenbewegung oder Hautdehnung – und damit auf vermehrte Artefakte – schließen, mit Hilfe eines Beschleunigungssensors lässt sich die körperliche Aktivität und die Körperlage bestimmen. Externe Störquellen können weitgehend durch einen konventionellen Bandpass entfernt werden. Die Auswahl der verwendeten Kontextsignale soll im Folgenden weiter motiviert werden.

Elektroden- oder Körperbewegung

Das Kapitel 5 dieser Arbeit beschäftigt sich mit der Artefakterkennung bzw. dem Umgang mit artefaktbehafteten EKG-Sequenzen. Deshalb werden Kontextsignale verwendet, die möglichst gut mit den Störungen im EKG korrelieren. Ein naheliegender Indikator für Bewegungsartefakte ist die Bewegung selbst.

Mit einem Beschleunigungsmesser lässt sich diese sehr einfach und präzise messen. Die meisten der verwendeten Datensätze enthalten deshalb das Signal von einem oder mehreren dreiachsigen mikro-elektromechanischen Beschleunigungssensoren, die an verschiedenen Stellen positioniert sein können.

Der Zusammenhang zwischen fehlerhaften QRS-Detektionen und der Bewegung wird in Abbildung 4.2 deutlich. Während der körperlich aktiven Phasen nimmt die Häufigkeit der Falscherkennungen stark zu, in den Phasen körperliche Ruhe gehen die Fehldetektionen zurück.

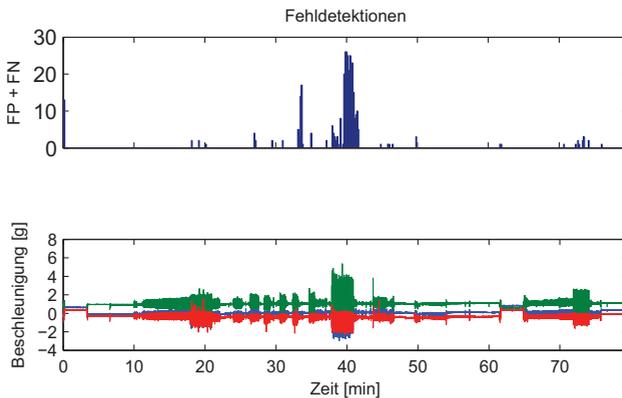


Abbildung 4.2: Zusammenhang zwischen fehlerhaften QRS-Detektionen (OSEA) und körperlicher Bewegung

Betrachtet man aber viele Datensätze, fällt auf, dass oben genannter Zusammenhang nicht immer zutrifft. Vielmehr lassen sich die Datensätze in drei Gruppen mit folgenden Eigenschaften aufteilen:

- Die körperliche Aktivität stimmt mit den Fehldetektionen überein.
- Die Fehldetektionen sind scheinbar unabhängig von der körperlichen Bewegung gleichmäßig über den Datensatz verteilt.
- Es liegen unabhängig der körperlichen Bewegung fast keine Fehldetektionen vor.

Somit wird klar, dass die Körperbewegung zwar als zusätzlicher Indikator für Bewegungsartefakte genutzt werden kann, aber in diesem Zusammenhang nicht isoliert betrachtet werden darf.

Neben der Nutzung als Second Channel für die Artefakterkennung lässt sich

das Bewegungssignal auch dazu verwenden, die körperliche Aktivität, die Körperlage oder Ereignisse wie Stürze oder schnelles Aufstehen zu bestimmen. Will man das Beschleunigungssignal als Second Channel für die Artefaktreduktion nutzen, müssen Sensorposition und verwendete Achsen berücksichtigt werden: Ist der Sensor in Herznähe angebracht (z. B. auf den Elektroden), kann das Seismokardiogramm (SKG) im Beschleunigungssignal beobachtet werden. Als SKG bezeichnet man die nicht-invasive Messung der mechanischen Herztätigkeit – und diese korreliert im physiologischen Fall sehr gut mit der elektrischen Herzaktivität. In Abbildung 4.3 sind verschiedene Sensorpositionen dargestellt, deren Kreuzkorrelationsfunktionen zwischen Beschleunigungssignal und ungestörtem EKG in Abbildung 4.4 zu sehen sind. Alle Sensoren waren mit breiten, elastischen Gurten am Probanden befestigt. Die berechneten Werte schwanken bei diesen Beispielen bei einem Probanden betragsmäßig zwischen 0,05 (Hüfte, z-Achse) und 0,45 (Brust, z-Achse). Insbesondere bei schlanken Personen und einer guten mechanischen Kopplung zwischen Sensor und Brust wurden in Herznähe sogar Korrelationskoeffizienten von 0,8 gemessen.

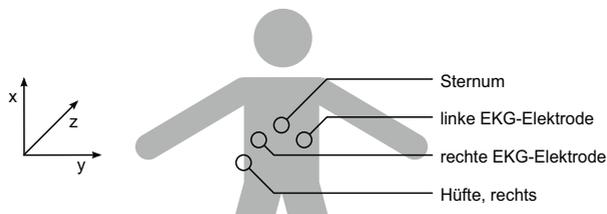
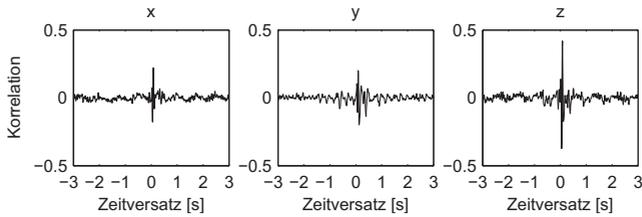


Abbildung 4.3: Unterschiedliche Sensorpositionen führen zu verschieden starker Korrelation zwischen EKG und Beschleunigungssignal

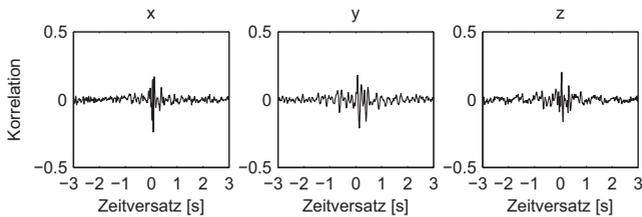
Ein geeigneter Second Channel für die Artefaktreduktion hat eine hohe Korrelation mit dem Störsignal, aber idealerweise gar keine Korrelation mit dem Nutzsignal. Aus diesem Grund ist das Bewegungssignal kein geeignetes Kontextsignal für die Artefaktreduktion.

Elektrode-Haut-Impedanz

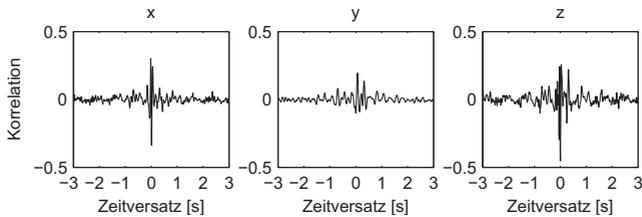
Besser als die Elektrodenbewegung ist die Elektrode-Haut-Impedanz geeignet, um Bewegungsartefakte zu erkennen oder gar zu reduzieren. Das Ersatzschaltbild in Abbildung 4.5 zeigt den Zusammenhang: Das EKG U_{EKG} wird durch das Elektrode-Haut-System überlagert. Z_{EH} ist die Elektrode-Haut-Impedanz, U_H



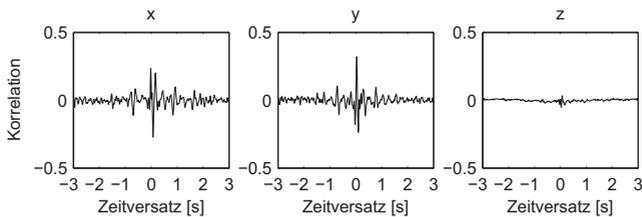
(a) Beschleunigungssensor in der linken EKG-Elektrode



(b) Beschleunigungssensor in der rechten EKG-Elektrode



(c) Beschleunigungssensor auf dem Sternum



(d) Beschleunigungssensor an der rechten Hüfte

Abbildung 4.4: Kreuzkorrelationsfunktion zwischen EKG und dreiaxsigem Beschleunigungssensor bei verschiedenen Sensorpositionen während des Liegens

ist die Summe der Hautpotentiale an einer Elektrode und U_E ist das Elektrode-Elektrolyt-Gleichgewichtspotential, das an der Grenzschicht zwischen Elektrode und Haut entsteht. Übt man nun Druck auf die Elektrode aus, verändert sich die Summe aus U_E und U_H ins Positive und die Impedanz Z_{EH} ins Negative [Zip79].

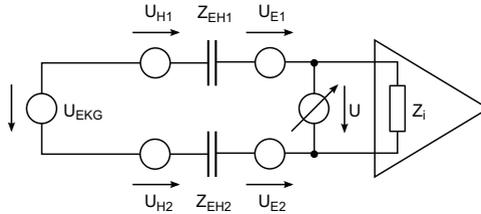


Abbildung 4.5: Zusammenhang zwischen Elektrode-Haut-Impedanz und Artefakten (Ersatzschaltbild nach [Zip79])

Der Druck auf die Elektrode oder die Bewegung an ihr führt zu mechanischen Veränderungen an der unter der Elektrode liegenden Haut. Sowohl Hautdehnung als auch Druck auf die Haut führen zu Veränderungen des Hautpotentials in der Größenordnung von einigen Millivolt [dT96]. Gleichzeitig ändert sich das Elektrodenpotential, da die Grenzschicht Haut/Elektrolyt bzw. Elektrolyt/Elektrode gestört wird. Die hier auftretenden Potentialveränderungen liegen betragsmäßig unter denen des Hautpotentials [Ott10].

Die Bewegung der Elektrode führt gleichzeitig zu Veränderungen in der Elektrode-Haut-Impedanz, da sich die effektive Fläche des Übergangs verändert. Durch die mechanische Kopplung zwischen Elektrode und Haut kommt es zu einer Ähnlichkeit zwischen Elektrode-Haut-Impedanz und den verursachten Störpotentialen. Berechnet man die Kreuzkorrelation zwischen dem Impedanzsignal und dem EKG, erhält man für artefaktbehaftete Sequenzen verhältnismäßig hohe Werte. In Abbildung 4.6 sind die Kreuzkorrelationsfunktionen einer artefaktbehafteten und einer ungestörten EKG-Sequenz gegenübergestellt.

Ein Nachteil dieses Kontextsignals ist allerdings die aufwändige Messung. In Abbildung 4.7 ist ein Blockschaltbild zur Messung der Elektrode-Haut-Impedanz dargestellt, intensiv wird das Thema in [Ott10] behandelt. Die Stromquelle wird üblicherweise sinusförmig angeregt, die Frequenz sollte so weit von der Nutzfrequenz des EKG-Signals entfernt liegen, dass sich beide Signale gut trennen lassen, aber so ähnlich sein, dass sich die Impedanzeigenschaften nicht

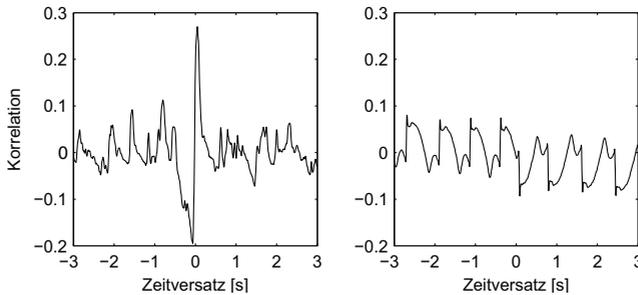


Abbildung 4.6: Korrelation zwischen dem EKG und der Elektrode-Haut-Impedanz bei einem 50-sekündigen artefaktbehafteten Segment (links) und einer artefaktfreien Sequenz (rechts)

zu stark unterscheiden. Über geteilte EKG-Elektroden wird dieses Signal in das Gewebe eingebracht. Als Demodulator auf der Verstärkerseite eignet sich ein Lock-In-Verstärker, der analog oder digital implementiert werden kann [Gri00].

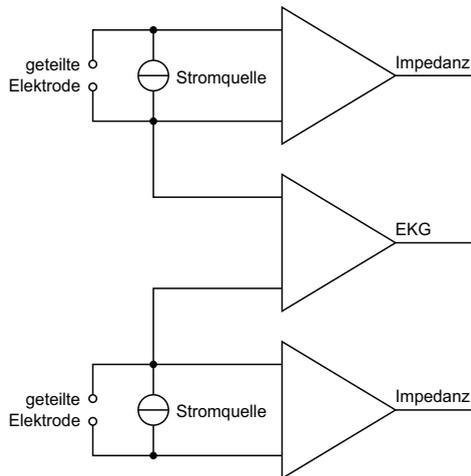


Abbildung 4.7: Blockschaltbild zur Messung der Elektrode-Haut-Impedanz [Ott06]

4.1.3 Entwicklungswerkzeuge und Werkzeugketten

Zur Entwicklung und Validierung der notwendigen Algorithmen wurde ein umfangreiches Framework erstellt. Dazu gehören neben dem eigens spezifizierten Datenformat Unisens auch die dazugehörigen, auf die speziellen Anforderungen zugeschnittenen Werkzeuge (s. Kap. 4.2). Zusätzlich wurden kommerzielle Entwicklungsumgebungen und -werkzeuge genutzt.

Ein wichtiges Softwarepaket für die schnelle Entwicklung von Signalverarbeitungsalgorithmen und die einfache Visualisierung von Ergebnissen ist die Software Matlab der Firma Mathworks. Mit der integrierten Skriptsprache lassen sich dank des sehr großen Pools an Funktionen auch komplexe und umfangreiche Aufgabenstellungen lösen. Die Arbeit mit großen Datenmengen kann mitunter problematisch sein. Da Matlab auf die Verarbeitung von Matrizen und Vektoren ausgelegt ist, treten Performance-Probleme auf, sobald die zu verarbeitenden Daten nicht mehr vollständig in den Speicher geladen werden können. Bei der Verwendung von Schleifen mit vielen Durchläufen sinkt die Performance von Matlab rapide.

Ersetzt man solche Elemente durch C/C++-Code, kann man die Geschwindigkeitsvorteile von C/C++ mit der einfachen Visualisierung von Matlab kombinieren. Man verliert unter Umständen aber den großen Pool von fertigen Matlab-Funktionen zu verschiedensten Fragestellungen und muss diese entsprechend selbst in C/C++ implementieren. Dennoch ist Matlab ein gut geeignetes Werkzeug, um selbst entwickelte Algorithmen mit vorhandenen Daten zu testen.

Über ein eigenes Interface und spezielle Compiler-Einstellungen lassen sich mit C/C++ Bibliotheken (DLL, Dynamic Link Library) erstellen, die direkt von Matlab genutzt werden können. Der Aufruf dieser sogenannten MEX-Dateien erfolgt von Matlab so wie der von Matlab-nativen Funktionen. Als Compiler kann der in Matlab integrierte Compiler oder ein spezielles Software Development Kit (SDK) für C/C++ genutzt werden. In dieser Arbeit wurden dafür verschiedene Versionen des Microsoft Visual Studio genutzt. Die benötigten MEX-Header-Dateien und Bibliotheken werden mit Matlab ausgeliefert.

Wird der gesamte Algorithmus in C/C++-Code ausgelagert, kann man diesen für verschiedene Targets (und ggf. mit verschiedenen Entwicklungsumgebungen) kompilieren. Abbildung 4.8 zeigt eine solche Werkzeugkette, die erstmalig in [Kir09] veröffentlicht wurden: Es gibt nur eine Codebasis in C oder C++.

Dieser Code wird über einen Target-spezifischen Wrapper in der selben Programmiersprache eingebunden und für das entsprechende Target kompiliert. Da für alle Targets die gleiche Codebasis verwendet wird, verbessert sich die Wartbarkeit der Software. Es muss lediglich darauf geachtet werden, dass es zu keinen Konflikten bei plattform- oder anwendungsspezifischen Details wie zum Beispiel der Wortlänge kommt.

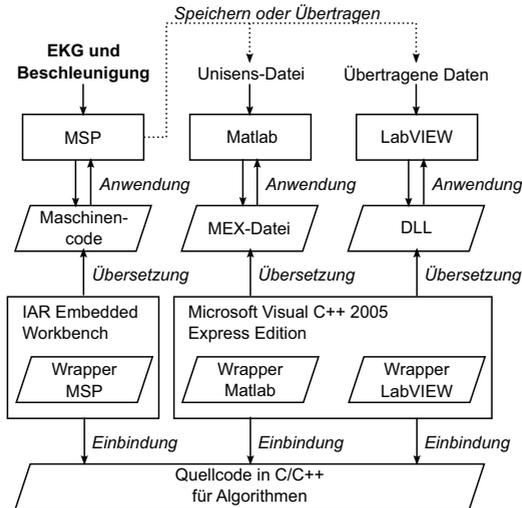


Abbildung 4.8: Werkzeugkette zum Entwickeln, Testen und Evaluieren der Artefaktbehandlungsalgorithmen

Jedes Target bzw. jede Applikation, die den kompilierten Code einbindet, hat seine Daseinsberechtigung. Erstellt man Maschinencode, beispielsweise für den MSP, einem Mixed Signal Processor von Texas Instruments, kann man den Algorithmus direkt auf einer entsprechenden Zielplattform ausführen und validieren. Das Debuggen ist hier aber mitunter umständlich, da sich Ergebnisse nur schwer visualisieren lassen. Verfügt der MSP aber über eine Online-Datenübertragung, kann man die aufgezeichneten Daten direkt an einen PC übertragen.

Für den PC eignet sich LabVIEW (National Instruments) als Softwarepaket zur Anzeige von gestreamten Daten. Kompiliert man den Algorithmus als DLL für LabVIEW, kann die Analyse direkt ausgeführt und Ergebnisse angezeigt werden. Eine LabVIEW-DLL lässt sich beispielsweise mit dem Microsoft Visual Studio

erstellen, sofern alle benötigten Header-Dateien und Compiler-Einstellungen vorhanden sind.

Um bereits aufgezeichnete Daten zu verarbeiten, kann Matlab genutzt werden. Aufgrund der hohen Geschwindigkeit von Matlab in Verbindung mit MEX-Files eignet sich dieses Konstrukt besonders für die Validierung und Verifikation von neuen Algorithmen.

4.1.4 Spezifikation eines universellen Datenformats

Für die Durchführung dieser Arbeit war der schnelle und unkomplizierte Zugriff auf Messdaten von großer Bedeutung. Allerdings sollen – im Gegensatz zu vielen herkömmlichen Analysesystemen – hier nicht nur das Signal eines Sensors untersucht werden, sondern die Informationen mehrerer Sensoren genutzt werden. Das bedeutet, dass diese Daten in einem Datenformat gespeichert werden, in dem die Informationen zu den einzelnen Sensoren wie auch die Informationen zum semantischen Zusammenhang zwischen den Sensoren erhalten bleiben.

Die im Bereich der EKG-Signalverarbeitung oftmals eingesetzten Datenformate WFDB [Moo08] und das mächtigere EDF [Kem92] haben sich für diese Anforderungen als unzureichend erwiesen. Mit seiner Weiterentwicklung zu EDF+ [Kem03] konnten zwar viele Schwachstellen des EDF-Formats verbessert werden, die Spezifikation konnte dennoch nicht überzeugen. Probleme bereitet das Speichern von Annotationen und einzelnen, nicht äquidistant abgetasteten Messwerten sowie die Handhabung von mehrkanaligen Sensoren. Ein Datenzugriff ohne entsprechende Bibliotheken ist nicht vorgesehen. Darüber hinaus bietet EDF nicht die Möglichkeit, verschiedene Signale zu gruppieren und zu kommentieren, um auf diese Art den semantischen Zusammenhang zu erhalten.

Aus diesen Gründen wurde mit Unisens ein eigenes, frei verfügbares Datenformat spezifiziert, dessen Fokus auf dem Umgang mit Multisensordaten liegt [Kir08a, Kir08b]. Durch die Trennung von Daten und Kontextinformationen bleibt das Format für den Menschen lesbar, was die Erstellung von Datensätzen sehr vereinfacht. Verschiedene Datentypen und vielfältige Annotationsmöglichkeiten machen das Datenformat universell einsetzbar.

4.2 Unisens-Datenformat

Das Datenformat Unisens 2.0 baut auf den Anforderungen des von der Firma Medset Medizintechnik GmbH spezifizierten Unisens 1.7 auf, das als Container alle enthaltenen Dateneinträge in einer Binärdatei zusammenfasst. Der Zugriff auf die Dateneinträge eines Datensatzes ist damit nur über eine entsprechende Funktionsbibliothek möglich. Dieser entscheidende Nachteil sollte im Nachfolgeformat Unisens 2.0 behoben werden.

4.2.1 Datenformatspezifikation

Die Spezifikation des neuen Datenformats erfolgte nach einer umfangreichen Sammlung von Anforderungen innerhalb der Arbeitsgruppe und externer Projektpartner und wurde in [Kir08b] erstmalig veröffentlicht. Gefordert wurde ein flexibles Datenformat, das sowohl maschinen- als auch menschenlesbar ist. Dabei muss das Format sowohl äquidistant und nicht äquidistant abgetastete Messdaten mit unterschiedlichen Abtastraten als auch beliebige Annotationen handhaben können, dabei aber stets einen Sample-genauen Datenzugriff erlauben. Weitere Anforderungen waren die Unterstützung verschiedener Datentypen, die Möglichkeit zur Gruppierung innerhalb eines Datensatzes und umfangreiche Kommentarfunktionen. Die vollständige Liste aller Anforderungen sowie Begriffsdefinitionen befindet sich im Anhang A.

Methode

Ein Unisens-Datensatz lässt sich als Container auffassen, der verschiedene Dateneinträge und einen Abschnitt mit Kontextinformationen enthalten kann. Dieser Aufbau wird in Abbildung 4.9 verdeutlicht.

Ein Dateneintrag enthält die Messdaten eines Sensors, eine Liste von Annotationen oder anwendungsspezifische Fremddaten. Jeder Dateneintrag hat eine eigene Zeitbasis (Abtastrate) und bekommt für seinen Inhalt eine Klasse (ContentClass) zugewiesen (z. B. EKG, Pleth, Blutdruck etc.). Mit Hilfe der ContentClass können Anwendungen die Daten automatisch richtig interpretieren. Ein Visualisierungsprogramm für EKG-Daten kann beispielsweise so implementiert werden, dass es nur Signale der ContentClass *ECG* anzeigt.

Sensormessdaten können als quasikontinuierliches Signal mit fester Abtastrate (SignalEntry) aufgezeichnet werden, so wie es bei einem EKG der Fall wäre.

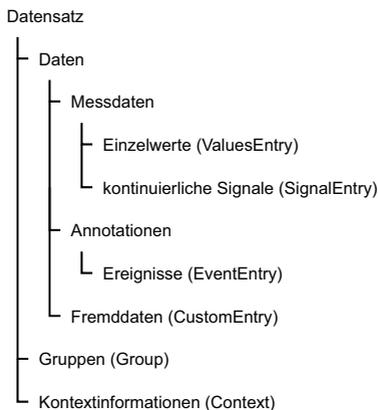


Abbildung 4.9: Aufbau eines Unisens-Datensatzes

Genauso können aber auch zeitdiskrete, nicht äquidistant abgetastete Werte (ValuesEntry) erfasst werden, wie z. B. bei einer oszillometrischen Langzeit-Blutdrucküberwachung. Sensordaten werden mit allen wichtigen Parametern des Sensors gespeichert (Informationen über A/D-Wandler, Abtastrate, Quantisierung etc.) und können mehrere Kanäle enthalten.

Ein Dateneintrag mit Annotationen speichert eine Liste von Ereignissen (EventEntry), die aber auch die Start- und Endmarkierung von Zeitbereichen sein können. Annotationen bestehen aus einem Zeitstempel, der Annotation selbst und einem optionalen Kommentar.

Das Datenformat sieht vor, anwendungsspezifische Fremddaten zu integrieren. Ein Fremddatensatz steht in direkter Beziehung zum gesamten Unisens-Datensatz, lässt sich aber nicht als Daten-Entry speichern. Ein Beispiel hierfür wäre eine Videoaufzeichnung einer durchgeführten Aktivitätsmessung. Eine spezielle Anwendung könnte nun das Vorhandensein einer Videoaufnahme überprüfen und zusammen mit den Sensordaten der Aktivitätsmessung darstellen.

Alle Dateneinträge können beliebig zu Gruppen zusammengefasst werden. Auf diese Art kann z. B. einem EKG eine zugehörige QRS-Triggerliste zugeordnet werden, genauso können Rohdaten von bereits verarbeiteten Daten getrennt werden.

Um Kontextinformationen zur Messung oder zum Messobjekt zu speichern, können weitere Informationen in textueller Form dem Datensatz hinzugefügt werden. Auf diese Art ist es möglich, z. B. Patientendaten oder generelle Informationen zur Aufnahmesituation festzuhalten.

Umsetzung

Bei der Umsetzung wurde auf eine klare und einfache Struktur sowie auf eine strikte Trennung zwischen Metainformation und Sensordaten geachtet, ohne dabei die Flexibilität einzuschränken.

Ein Unisens-Datensatz besteht aus einem Ordner im Dateisystem, in dem alle zugehörigen Dateien abgelegt sind. Der Ordnername bestimmt den Namen des Datensatzes. Alle Metainformationen zum gesamten Datensatz bzw. zu jedem darin enthaltenen Entry stehen in einer Header-Datei. Für diese Header-Datei wurde das XML-Format gewählt, die Struktur ist in einem XML-Schema vorgegeben. Der Name der Header-Datei ist immer *unisens.xml*.

Die Header-Datei verweist auf alle zugehörigen Entries, die in eigenen Dateien abgelegt sind und die Daten (s. Abb. 4.9) enthalten. Ein Entry wird dabei über seine ID als Primärschlüssel identifiziert, der auch dem Dateinamen des Entries entspricht. In Abbildung 4.10 ist die Dateistruktur eines Beispieldatensatzes dargestellt.

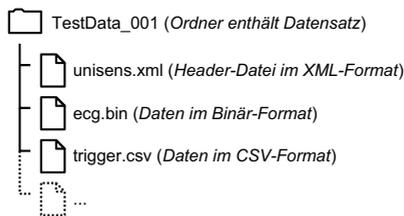


Abbildung 4.10: Repräsentation eines Unisens-Datensatzes im Dateisystem

Für jedes Daten-Entry existiert eine eigene Datei, welche in verschiedenen Formaten vorliegen kann. Spezifiziert sind die Formate XML, CSV sowie Binärdateien. Der Anwender kann sich beim Speichern der Daten für ein Dateiformat entscheiden. Für Signale bietet sich das Binärformat an, da so gespeicherte Datensätze eine akzeptable Dateigröße behalten und einen wahlfreien Zugriff erlauben. Für das Abspeichern von Annotationen und Einzelwerten ist das CSV-

Format empfehlenswert, da sich diese Dateien auch ohne die Unisens-Bibliothek komfortabel lesen und bearbeiten lassen.

Für alle Dateiformate werden unterschiedliche Datentypen unterstützt, unter anderem 32-Bit Integer-Werte (Int32) und Fließkommazahlen (Double). Alle unterstützten Datentypen sind in Tabelle 4.1 aufgelistet.

Tabelle 4.1: Alle von Unisens unterstützten Datentypen

Datentyp	Größe (Byte)	Wertebereich
DOUBLE	8	$4.9 \cdot 10^{-324} \dots 1.7976931348623157 \cdot 10^{308}$
FLOAT	4	$1.4 \cdot 10^{-45} \dots 3.4028235 \cdot 10^{38}$
INT32	4	-2147483648 ... 2147483647
INT16	2	-32768 ... 32767
INT8	1	-128 ... 127
UINT32	4	0 ... 4294967295
UINT16	2	0 ... 65535
UINT8	1	0 ... 255

Gruppen werden innerhalb der Header-Datei festgelegt. Die Gruppierung erfolgt über eine Liste der IDs der zu gruppierenden Einträge. In einem Kommentarfeld kann die Gruppe textuell umschrieben werden. Auf diese Weise lassen sich z. B. jeweils Sensorrohdaten und verarbeitete Daten gruppieren und so voneinander trennen.

Das Speichern von Kontextinformationen kann auf verschiedene Arten erfolgen: entweder als einfache Key-Value-Paare innerhalb der Header-Datei oder in einer separaten XML-Datei mit selbst vorgegebener Struktur. Innerhalb der Header-Datei können Key-Value-Paare global für den gesamten Datensatz oder spezifisch für einzelne Dateneinträge angelegt werden. Die Schlüssel der Key-Value-Paare können frei definiert werden.

Sollen Kontextinformationen in einer separaten XML-Datei gespeichert werden, muss ein entsprechendes XML-Schema mitgeliefert werden, welches die Datenstruktur beschreibt. Diese Methode eignet sich besonders für die Archivierung von Probandeninformationen bei großen Studien. Die erstellte XML-Datei wird mit dem Namen *context.xml* dem Datensatz hinzugefügt.

Die modulare Organisation der Daten-Entries in einzelnen Dateien ermöglicht es, einen Datensatz jederzeit schnell und einfach durch neue Entries zu erweitern oder bestehende Entries zu entfernen. Damit können zusätzliche

Signale gespeichert werden, die durch die Bearbeitung der Sensorrohdaten entstehen. Der semantische Zusammenhang kann durch eine Gruppe, entsprechende Hinweise im Kommentarfeld bzw. in der Quelle oder durch eigene Key-Value-Paare angegeben werden.

Mit der Spezifikation des Datenformates wurde eine Java-Bibliothek bereitgestellt, die das Lesen und Schreiben von Unisens-Daten ermöglicht [Kir08a]. Für die Nutzung in Matlab kann diese Java-Bibliothek direkt genutzt werden. Viele Funktionen wurden aber zusätzlich nativ in Matlab implementiert, um einen Performanzgewinn zu erzielen. Für Implementierungen in .NET wurde die Unisens-Bibliothek in C# konvertiert. Von National Instruments wurde ein Unisens-DataPlugin für LabVIEW entwickelt.

Listing 4.1 zeigt in einem Minimalbeispiel, wie ein Datensatz mit Hilfe der Unisens-Bibliothek geöffnet und gelesen werden kann. Aufgrund der klaren und Menschen-lesbaren Struktur ist es aber darüber hinaus möglich, Unisens ohne Benutzung der Bibliothek zu verwenden.

Listing 4.1: Lesen eines Unisens-Datensatzes mit Hilfe der Java-Bibliothek

```
// Datensatz und Entry öffnen
UnisensFactory uf = UnisensFactoryBuilder.createFactory();
Unisens u = uf.createUnisens("C:\\\\TestData_001");
SignalEntry se = (SignalEntry) u.getEntry("ecg.bin");

// Daten lesen (1000 Samples)
int [][] data = (int [][]) se.read(1000);

// Unisens-Dateien schließen
u.closeAll();
```

Im Laufe dieser Arbeit wurden verschiedene Anwendungen entwickelt, die das Betrachten, Erstellen und Bearbeiten von Unisens-Datensätzen vereinfachen. Die wichtigsten Programme sind der EKG-Editor und der UnisensViewer.

4.2.2 EKG-Editor

Der EKG-Editor ist ein Anzeige- und Bearbeitungswerkzeug für EKG-Daten im Unisens-Format. Er wurde entwickelt, um EKG-Datensätze anzuzeigen, zu annotieren und relevante Bereiche auszuschneiden und als Testdatensätze definierter Länge in einer Testdatenbank zu speichern. Nach und nach wurde die Software zu einem funktionsreichen Editor für EKG-Daten weiterentwickelt.

Die Anzeige des EKG-Editors teilt sich in zwei Bereiche: Oben befindet sich die EKG-Anzeige, in der alle EKG-Kanäle übereinander dargestellt werden. Im unteren Bereich der Anzeige befinden sich mehrere Registerkarten, die mit unterschiedlichen Funktionen oder Sichten auf das Signal belegt sind. Desweiteren gibt es eine Menü- und eine Funktionsleiste, über die auf die integrierten Funktionen zugegriffen werden kann. Abbildung 4.11 zeigt einen Screenshot des EKG-Editors.

Für die EKG-Anzeige lassen sich Amplitude und Vorschub getrennt einstellen; eine 1 mV-Eichzacke, ein integrierter EKG-Zirkel und das Millimeterpapier im Hintergrund erleichtern Medizinern die Interpretation des Signals. Über das Signal können zwei QRS-Triggerlisten und eine Liste mit Zeitbereichs-Annotationen für Artefakte eingeblendet werden.

Die *EKG-Übersicht* im unteren Teil zeigt fünf Minuten des EKG-Signals an, die *Signalinformation* zeigen alle Informationen aus der Header-Datei des Datensatzes, die Registerkarte *Testdatensätze* bietet eine Oberfläche, um aus dem EKG-Signal Testdatensätze auszuschneiden und als neuen Datensatz abzuspeichern. Die Karte *Artefakte* enthält eine Übersicht über alle markierten Artefaktbereiche und in der *Tachogramm*-Ansicht werden – sofern eine QRS-Annotation vorhanden ist – die Länge der RR-Intervalle über der Zeit angezeigt. Um direkt zu annotierten Ereignissen springen zu können, wurde die Registerkarte *Ereignisse* implementiert.

Datensätze annotieren

Eine wichtige Funktion des EKG-Editors ist das Annotieren von Datensätzen. Um entwickelte EKG-Analysealgorithmen validieren zu können, wird häufig eine Referenzannotation der QRS-Komplexe benötigt. Mit dem EKG-Editor kann man diese einfach erstellen. Verschiedene integrierte QRS-Erkennungsalgorithmen können das EKG analysieren und zeigen die erstellte Triggerliste an. Anschließend kann diese per Hand gesichtet und ggf. korrigiert werden. Mit Hilfe der Tachogrammübersicht lassen sich schnell Unregelmäßigkeiten in der QRS-Detektion erkennen und prüfen, ob diese aufgrund von Herzrhythmusstörungen oder Fehldetektionen entstanden sind. Ein spezieller Trigger-Editier-Modus und die hinterlegte Liste mit den *WFDB Annotation Codes* (s. Tab. 4.2 und 4.3) beschleunigen das Korrigieren der Triggerliste. Die fertige Triggerliste kann dem Datensatz als EventEntry im CSV-Format hinzugefügt werden.



Abbildung 4.11: EKG-Editor mit 5 min EKG in der Übersicht

Sucht man auffällige Herzrhythmusstörungen oder artefaktbehaftete EKG-Sequenzen, kann man hierfür die EKG-Übersicht nutzen. Der aktuell in der EKG-Anzeige dargestellte Ausschnitt wird farblich hervorgehoben. Die fünfzeilige Anzeige mit insgesamt 5 min EKG kann automatisch mit einer einstellbaren Geschwindigkeit durch den Datensatz blättern. So kann man schnell und mühelos auch große Datensätze sichten.

Neben der Schlagklassifikation ist es auch möglich, artefaktbehaftete EKG-Sequenzen als Artefakte zu markieren. Dazu markiert man den entsprechenden Bereich mit der Maus und fügt über das Kontextmenü die Artefaktnotation hinzu. Artefakte können auch einzelnen Kanälen zugeordnet werden. Die Liste in der Registerkarte *Artefakte* zeigt stets alle eingetragenen Bereiche, die sich hierüber auch editieren lassen. Gespeichert wird die Artefaktliste als EventEntry innerhalb des Unisens-Datensatzes.

Tabelle 4.2: EKG-Annotationen für QRS-Komplexe [Moo08]

Code	Abkürzung	Beschreibung
NORMAL	N	Normal beat
LBBB	L	Left bundle branch block beat
RBBB	R	Right bundle branch block beat
BBB	B	Bundle branch block beat (unspecified)
APC	A	Atrial premature beat
ABERR	a	Aberrated atrial premature beat
NPC	J	Nodal (junctional) premature beat
SVPB	S	Supraventricular premature or ectopic beat (atrial or nodal)
PVC	V	Premature ventricular contraction
RONT	r	R-on-T premature ventricular contraction
FUSION	F	Fusion of ventricular and normal beat
AESC	e	Atrial escape beat
NESC	j	Nodal (junctional) escape beat
SVESC	n	Supraventricular escape beat (atrial or nodal)
VESC	E	Ventricular escape beat
PACE	/	Paced beat
PFUS	f	Fusion of paced and normal beat
UNKNOWN	Q	Unclassifiable beat
LEARN	?	Beat not classified during learning

Testdatensätze erstellen

Der EKG-Editor ist das ideale Werkzeug, um aus vorhandenen Langzeitaufnahmen Signale definierter Länge und mit definierten Rhythmusstörungen für eine Testdatenbank zu extrahieren. Über eine Konfigurationsdatei im XML-Format können bestimmte Klassen definiert und ihnen eine Länge (in Millisekunden) zugeordnet werden (siehe Listing 4.2). Über die Registerkarte *Testdatensätze* kann auf diese Klassendefinitionen zugegriffen werden: Man setzt mit der Maus den Startpunkt des gewünschten Abschnitts, wählt die entsprechende Klasse aus und speichert diese. Die Software kopiert automatisch den entsprechenden Zeitbereich des EKG-Signals und alle weiteren im Datensatz enthaltenen Einträge und speichert diese als neuen Datensatz. Der Dateiname kann dabei

Tabelle 4.3: Weitere EKG-Annotationen [Moo08]

Code	Abkürzung	Beschreibung
VFON	[Start of ventricular flutter/fibrillation
FLWAV	!	Ventricular flutter wave
VFOFF]	End of ventricular flutter/fibrillation
NAPC	x	Non-conducted P-wave (blocked APC)
WFON	(Waveform onset
WFOFF)	Waveform end
PWAVE	p	Peak of P-wave
TWAVE	t	Peak of T-wave
UWAVE	u	Peak of U-wave
PQ	‘	PQ junction
JPT	’	J-point
PACESP	~	(Non-captured) pacemaker artifact
ARFCT		Isolated QRS-like artifact
NOISE	~	Change in signal quality
RHYTHM	+	Rhythm change
STCH	s	ST segment change
TCH	T	T-wave change
SYSTOLE	*	Systole
DIASTOLE	D	Diastole
MEASURE	=	Measurement annotation
NOTE	"	Comment annotation
LINK	@	Link to external data

automatisch anhand eines festgelegten Namensschemas generiert werden. Auf diese Weise wird das Erstellen von großen Testdatenbanken nach einem zuvor festgelegten Schema erheblich vereinfacht. Zudem wird eine Verknüpfung zwischen dem Originaldatensatz und dem kopierten Ausschnitt des Testdatensatzes gespeichert.

Sollen einzelne Störungen aus dem EKG entfernt werden, können diese Bereiche aus dem Signal gelöscht werden. Hierzu wird der entsprechende Bereich mit der Maus markiert und über das Kontextmenü gelöscht. Ein integrierter Algorithmus verschiebt die Schnittstellen auf beiden Seiten so, dass Signalsprünge

vermieden werden. Der so bearbeitete Datensatz kann dann unter einem neuen Namen gespeichert werden.

Auf diese Art lassen sich auch für Test- und Demonstrationszwecke künstliche Rhythmusstörungen erzeugen, ohne auf das schlechte Signal eines Signalgenerators zurückgreifen zu müssen. Dabei sollte aber stets beachtet werden, dass sich zwar durch Entfernen von Signalteilen ein offensichtlich bradykarder oder tachykarder Rhythmus erstellen lässt, bei einer realen Rhythmusstörung spielen aber parallel noch weitere Parameter, wie z. B. die ST-Streckenmorphologie.

Listing 4.2: "Konfigurationsdatei MedicalClasses.xml"

```
<?xml version="1.0" encoding="ISO-8859-1" standalone="yes"?>
<MedicalClasses>
  <entry>
    <title>grobe VF</title>
    <minimalLength>15000</minimalLength>
    <abbreviation>VF</abbreviation>
  </entry>
  <entry>
    <title>schnelle VT</title>
    <minimalLength>15000</minimalLength>
    <abbreviation>FVT</abbreviation>
  </entry>
</MedicalClasses>
```

Interface für Analysealgorithmen

Der EKG-Editor kann durch ein definiertes Interface um weitere Analysealgorithmen ergänzt werden. So lassen sich z. B Algorithmen zur QRS-Erkennung bei verschiedenen Abtastraten, Artefakterkennungsalgorithmen oder Schlag-Klassifikatoren sinnvoll integrieren.

Die Analysealgorithmen liegen als in C kompilierte DLL vor und werden über das Java Native Interface (JNI) eingebunden. Über eine Konfigurationsdatei im XML-Format können die Ein- und Ausgänge der Algorithmen definiert werden. Neben dem EKG kann an dieser Stelle auf weitere Dateneinträge des geöffneten Datensatzes zurückgegriffen werden, auch wenn der EKG-Editor diese nicht anzeigt.

Zur Analyse werden die Daten dem Algorithmus als Stream übergeben, der Algorithmus ist selbst für das Puffern der Daten verantwortlich. Aus diesem

Grund können die selben Algorithmen verwendet werden, die auch für eine Online-Analyse zum Einsatz kommen, es muss dafür lediglich das Interface angepasst werden.

4.2.3 UnisensViewer

Der EKG-Editor hat sich als sehr hilfreiches Werkzeug herausgestellt, allerdings gibt es zwei gravierende Nachteile:

- Aufgrund der gewählten Technologie (Java) ist die Software nicht besonders performant.
- Es können nur EKG-Daten und zugehörige Annotationen betrachtet und bearbeitet werden.

Aus diesem Grund wurde ein weiteres Werkzeug spezifiziert, ein universeller und performanter Viewer für Unisens-Daten. Die neue Software sollte alle Arten von Messdaten und Annotationen anzeigen können. Der Schwerpunkt sollte dabei auf die performante Darstellung über einer gemeinsamen Zeitachse gelegt werden. Die auf einem Bildschirm zur Verfügung stehende Fläche sollte für die Signalanzeige ideal ausgenutzt werden können. Dennoch sollte ein Anzeigen und Editieren der Metainformationen möglich sein.

Gemäß dieser Spezifikation wurde der UnisensViewer erstellt (s. Abb. 4.12). Die Software wurde in C# mit dem .NET Framework 4.0 programmiert. Das minimierbare Ribbon-Menü und die variable Seitenleiste lassen viel Platz für die Anzeige der Daten, die alle über einer gemeinsamen Zeitachse ausgerichtet sind und gegebenenfalls interpoliert werden. Die Implementierung in C# bietet gegenüber Java erhebliche Performancevorteile.

Performance-Aspekte

Zur schnellen Darstellung vieler Messdaten tragen Memory Mapped Files und intelligentes Rendering bei. Bei einem Memory Mapped File wird der Dateiinhalt in den virtuellen Adressraum der Anwendung abgebildet. Die Daten werden dabei nur nach Bedarf oder gemäß einer Betriebssystem-eigenen Strategie aus der Datei geladen oder zurückgeschrieben. Abbildung 4.13 zeigt diesen Mechanismus: Die Messdatendatei wird in einzelne Page Frames zerlegt, die im virtuellen Adressraum einer Anwendung als Pages linear adressierbar sind. Durch diese Technik wird das Einlesen und Schreiben von Dateien beschleunigt.



Abbildung 4.12: UnisensViewer mit verschiedenen Messdaten und Annotationen

Neben dem Einlesen der Daten ist auch das Anzeigen (Rendern) sehr zeitintensiv. Eine Rastergrafik ist Zeile für Zeile sequentiell im Speicher abgelegt, das Einlesen von Messdaten für die Anzeige erfolgt aber spaltenweise. Durch zeilenweises Rendern des um 90° gedrehten Bitmaps und einer anschließenden Transformation werden ein sequenzieller Speicherzugriff und eine bessere Cache-Nutzung erreicht, sodass auch hier ein erheblicher Performance-Gewinn erzielt werden konnte.

Bedienkonzept

Die Anzeige des UnisensViewers unterteilt sich in drei Bereiche: Oben ist das Ribbon-Menü angeordnet, links ist die Seitenleiste mit allen Metainformationen des Datensatzes, rechts liegt der Anzeigebereich, in dem Messdaten und Annotationen angezeigt werden (s. Abb. 4.12). Der UnisensViewer ist auf eine Bedienung mit der Maus ausgelegt. Zur Anzeige, zum Sortieren und zum Zoomen innerhalb angezeigter Daten werden Mausgesten und Drag and Drop genutzt. Viele Funktionen sind sowohl über das Ribbon-Menü als auch über ein

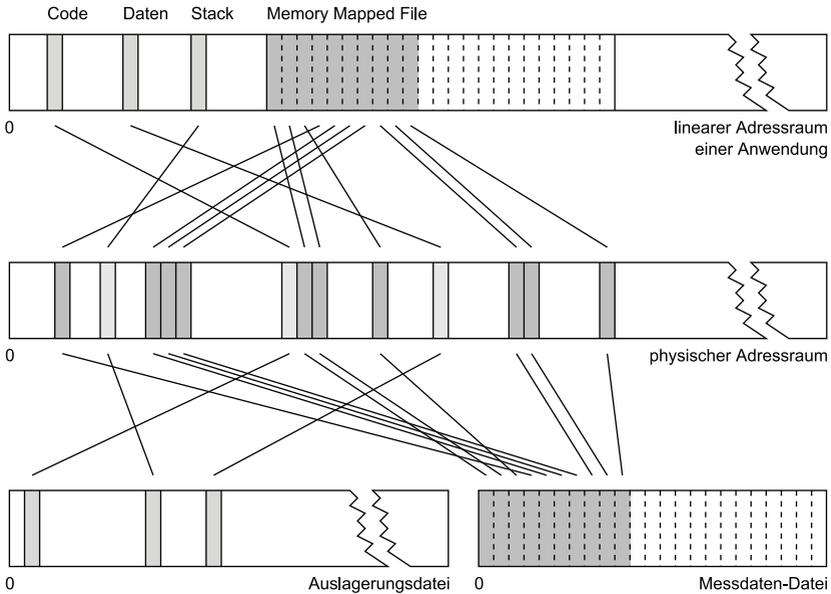


Abbildung 4.13: Virtuelle Speicherverwaltung durch Paging und Memory Mapped Files

Kontextmenü erreichbar.

Schnittstelle für Plug-ins

Um den UnisensViewer langfristig nutzen und einfach erweitern zu können, wurde eine Plug-in-Schnittstelle implementiert. Plug-ins sind spezielle Bibliotheken in einem Plug-in-Ordner, die vom UnisensViewer aus ohne Installation erkannt und ausgeführt werden können. Plug-ins haben die Möglichkeiten, vorhandene Daten zu lesen, zu manipulieren oder zu speichern, ebenso können sie neue Daten schreiben, eigene GUI-Elemente öffnen oder gezielt Daten im UnisensViewer anzeigen. Plug-ins können über das Ribbon-Menü, das Kontextmenü oder über frei konfigurierbare Hotkeys aufgerufen werden.

In Abbildung 4.14 ist die Kommunikation zwischen dem UnisensViewer und einem Plug-in gezeigt: Der UnisensViewer übergibt mit dem Aufruf eines

Plug-ins die Header-Informationen des Datensatzes sowie eine Liste der ausgewählten Entrys und gegebenenfalls noch Zeitpunkte einer Markierung oder der aktuellen Mausposition oder spezielle Hotkey-Parameter. Das Plug-in selbst kann nun lesend und schreibend auf alle Daten zugreifen sowie nach Bedarf noch eigene GUI-Komponenten, wie zum Beispiel einen Fortschrittsbalken oder einen Dialog, öffnen. Mit Beendigung des Plug-ins kann eine Liste mit anzuzeigenden Entrys zurückgegeben werden. Auf diese Art können Ergebnisse direkt im Viewer angezeigt werden.

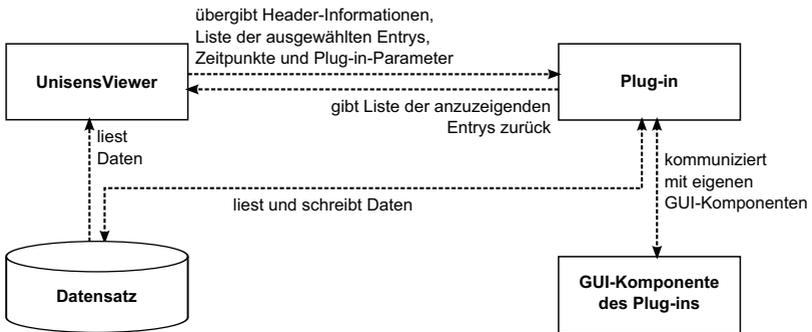


Abbildung 4.14: Kommunikation zwischen UnisensViewer und Plug-ins

Anbindung an Matlab

Um die schnelle und komfortable Anzeige von großen Datensätzen des UnisensViewers mit der einfachen Implementierung von Algorithmen unter Matlab zu verbinden, muss eine Verbindung zwischen dem UnisensViewer und Matlab entwickelt werden. Dafür bieten sich verschiedene Möglichkeiten: Eigene Matlab-Funktionen können aus Matlab heraus mit dem Deploy-Tool als C#-Library (.NET-Assembly) exportiert werden und anschließend direkt in einem UnisensViewer-Plug-in benutzt werden. Eine Matlab-Installation ist hierfür nicht erforderlich, es wird lediglich die Matlab-Runtime benötigt. Dies eignet sich vor allem für Funktionen, die fertig entwickelt sind und nicht mehr verändert werden sollen. Zur Integration dieser Bibliotheken benötigt man sowohl eine Matlab-Umgebung mit dem Deploy-Tool für .NET/C# als auch eine Entwicklungsumgebung für C#, um das Plug-in zu entwickeln.

Um eigene Matlab-Funktionen ohne weitere Kenntnisse von C# integrieren

zu können, wurde ein universelles Matlab-Plug-in entwickelt. Dieses ruft eine frei wählbare Matlab-Funktion auf (externer Matlab-Start) und übergibt dieser Informationen über die ausgewählten Daten aus dem UnisensViewer (Pfad, Entry-ID und Bereich). Die Matlab-Funktion muss dafür ein definiertes Interface implementieren und sich selbständig um das Einlesen der Daten und das Speichern der Ergebnisse kümmern. Der UnisensViewer ist wiederum in der Lage, die von Matlab geschriebenen Ergebnisse anzuzeigen.

Es ist auch eine Mischung aus dem .NET-Assembly und dem externen Matlab-Start möglich. Mit Hilfe der Matlab-Bibliotheken für C# können Variablen direkt in den Matlab-Workspace geschrieben sowie Matlab-Befehle aufgerufen werden, ohne dass Matlab hierfür gestartet werden muss (COM-Approach). Diese Version vereint aber einige Nachteile aus den beiden vorherigen Ansätzen: Auf dem ausführenden System muss sowohl eine Matlab-Installation vorliegen, gleichzeitig ist der Aufruf von Matlab-Funktionen innerhalb von C# aufwändig.

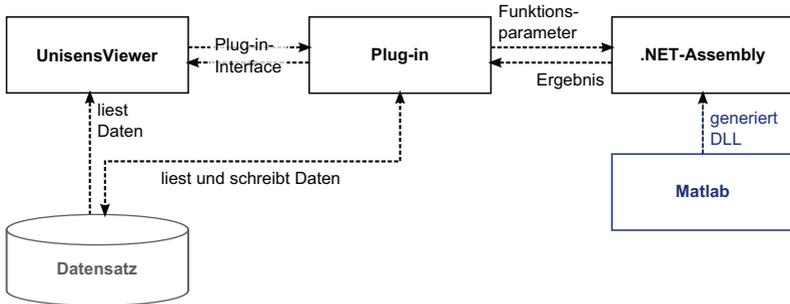
In Abbildung 4.15 sind die unterschiedlichen Verfahren als Blockdiagramm dargestellt. Es ist gut zu erkennen, welche Komponenten für den Datenzugriff zuständig sind und welche Aufgaben Matlab übernimmt.

4.2.4 Datenbankbindung

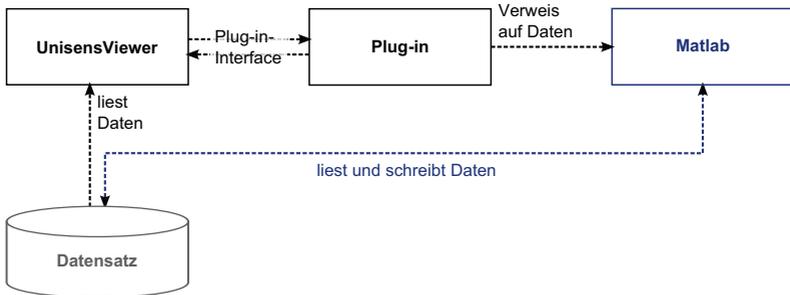
Um größere Datenbestände leichter durchsuchen zu können, wurde eine Datenbankerweiterung für Unisens realisiert. Ziel dieser Entwicklung ist die schnelle Durchsuchbarkeit der Kontextinformationen. Als Technologie für die Datenbank bietet sich MySQL an [Ora10]. MySQL ist ein relationales Datenbankverwaltungssystem, das als Open-Source-Software zur Verfügung steht. An der Entwicklung waren namhafte Firmen wie Oracle und Sun beteiligt. Eine MySQL-Datenbank ist schnell und leistungsfähig, sie unterstützt die Structured Query Language (SQL), ist für alle gängigen Betriebssysteme erhältlich und benötigt nach der Installation nur relativ wenig Speicherplatz [Dub08].

Indexierung

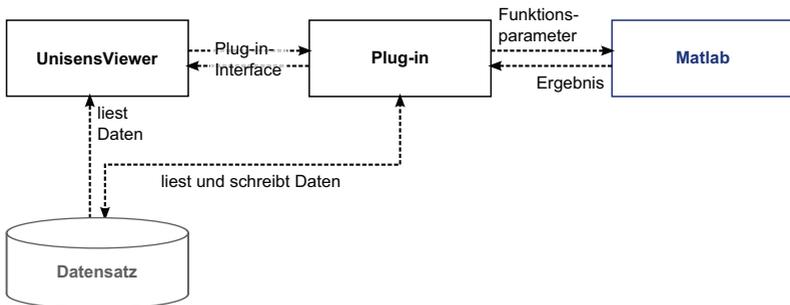
Die Datenbank wird lediglich zur Indexierung der Metadaten genutzt. Ein Indexierer liest alle Metadateien – also die Dateien unisens.xml und, sofern vorhanden, context.xml – und speichert den Inhalt in der Datenbank. Dieser Vorgang kann je nach Umfang der Datenbasis einige Minuten in Anspruch



(a) .NET-Assembly: Mit dem Matlab Deploy-Tool wird eine DLL generiert, die ohne Matlab nutzbar ist



(b) Externer Matlab-Start: Die Matlab-Funktion wird über Kommandozeilenparameter gestartet und erledigt selbständig alle Dateizugriffe



(c) COM-Approach: Das Plug-in nutzt den Matlab-Workspace direkt, um Variablen zu setzen und Funktionen aufzurufen

Abbildung 4.15: Möglichkeiten zur Integration von Matlab-Funktionen

nehmen. Der Indexierer wurde in Java entwickelt, da so die Integration der Unisens-Bibliothek am leichtesten fällt. Der Aufruf erfolgt über die Kommandozeile. Neben den Zugangsdaten für die Datenbank wird ein Ordner angegeben, der rekursiv nach allen Unisens-Datensätzen durchsucht wird, die anschließend indexiert werden.

Ist die Datenbank mit den Informationen gefüllt, können sehr schnell verschiedene Suchanfragen gestartet werden. SQL ermöglicht dabei auch komplexe Suchanfragen wie die Verknüpfung mehrerer Tabellen oder den Einsatz von regulären Ausdrücken. Der Beispiel-Query in Listing 4.3 gibt den kompletten Pfad zu allen SignalEntries zurück, die ein mit 250 Hz abgetastetes EKG beinhalten.

Listing 4.3: Suche nach allen EKG-Entries mit einer Samplerrate von 250 Hz

```
SELECT CONCAT(path, dataRecordName, '\\', entryId) FROM
  unisens, measuremententry WHERE fk_unisensId=pk_unisensId
  AND contentClass='ECG' AND sampleRate='250'
```

In den Abbildungen 4.16 und 4.17 ist die entsprechende Datenstruktur gezeigt. Die Tabellen zur Abbildung der Datei unisens.xml orientieren sich dabei am XML Document Schema (unisens.xsd). Die Tabellen für die context.xml sind im Gegensatz dazu generisch gehalten, sodass eine Kontextdatei mit beliebigem Aufbau abgebildet werden kann.

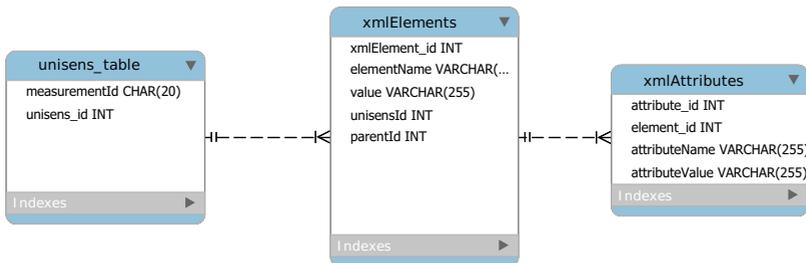


Abbildung 4.16: Struktur der Unisens-Datenbank (context.xml)

Grafische Benutzeroberfläche

Die MySQL-Datenbank kann mit allen gängigen Werkzeugen abgefragt werden. Neben dem mit MySQL ausgelieferten Kommandozeilen-Tool gibt es auch viele grafische Tools zur Datenbankverwaltung und -abfrage. Ein bewährtes

4 Framework zur Entwicklung von Analysealgorithmen

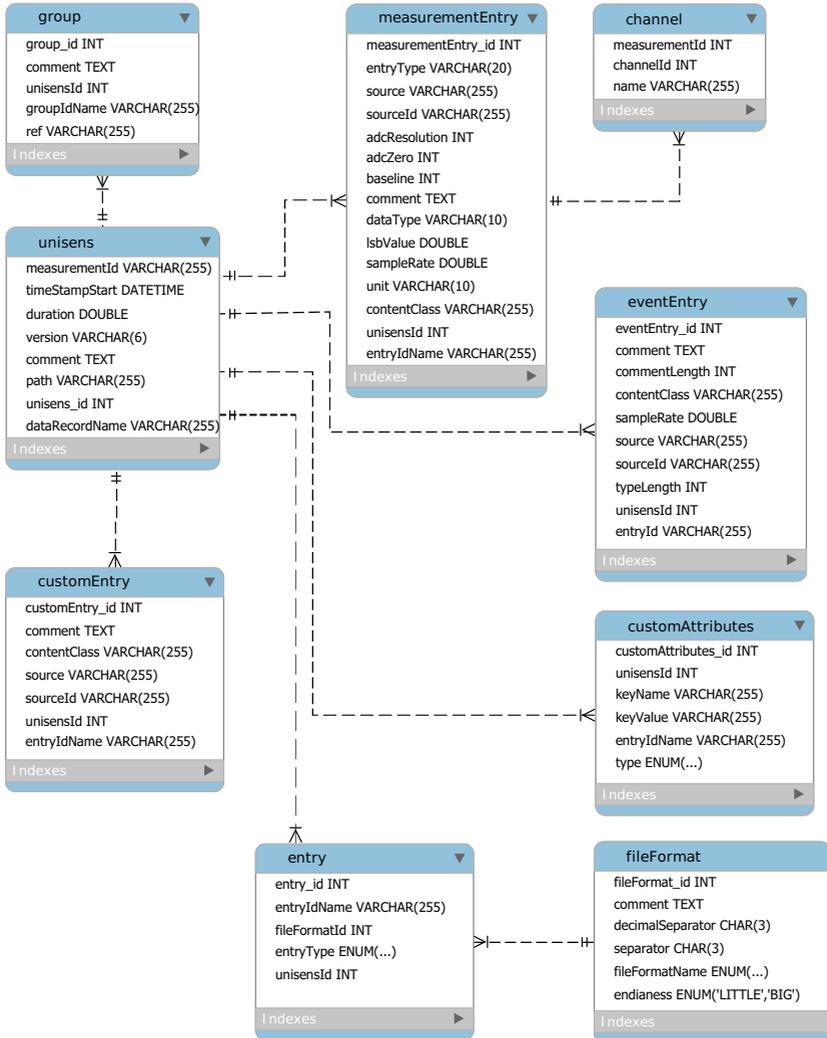


Abbildung 4.17: Struktur der Unisens-Datenbank (unisens.xml)

Open-Source-Projekt mit grafischer Benutzeroberfläche ist HeidiSQL [Bec10]. Für den speziellen Anwendungsfall der Unisens-Datenbank wurde ein eigener MySQL-Client in Java erstellt, der neben vordefinierten Suchanfragen auch die Indexierung von neuen Daten unterstützt. Ergebnisse können direkt per Drag and Drop in den UnisensViewer gezogen werden, um den Datensatz zu öffnen (s. Abb. 4.18).

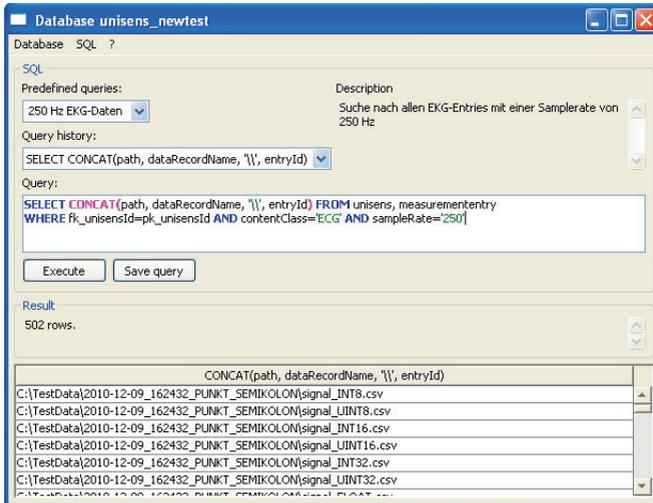


Abbildung 4.18: Benutzeroberfläche für die Abfrage der Unisens-Datenbank

Die Software UnisensDatabaseTool hat folgende Merkmale:

- Verwaltung von verschiedenen Datenbanken
- Möglichkeit zur Erstellung neuer Datenbanken
- Möglichkeit zur Indexierung von Unisens-Datensätzen (Import)
- Liste mit vordefinierten SQL-Querys und Möglichkeit zur Ergänzung dieser Liste
- Query-Historie

Neben den oben genannten Methoden kann man auch mit Hilfe von Matlab-Methoden auf die Unisens-Datenbank zugreifen. Dazu wird Matlab mit Hilfe von JDBC (Java Database Connectivity) mit der MySQL-Datenbank verbunden. Ein eigenes Set an Funktionen ermöglicht das einfache Ausführen von MySQL-Queries.

4.3 EKG-Datenbanken

In verschiedenen Studien wurden unzählige Stunden EKG-, Bewegungs- und Impedanzdaten mit unterschiedlichen Aufnahmesystemen aufgezeichnet. Ein Teil der Daten ist mit einer Referenzannotation versehen, sodass sie zu Verifikationszwecken verwendet werden können.

4.3.1 ITIV_KFA

Im Rahmen des BMBF-Projektes *CALM* wurden in Kooperation mit der Klinik für Anästhesiologie der Universitätsklinik Erlangen in einer Studie Datensätze von 90 Probanden (57 männlich, 33 weiblich) aufgenommen [Jat10, Ott10]. Jeder Proband durchlief dabei einen Parcours, der die verschiedenen körperlichen Aktivitäten Liegen, Sitzen, Stehen, Laufen, Treppensteigen, Joggen und Fahren auf dem Fahrradergometer enthielt. Die Dauer einer Aufnahme beträgt etwa 1:15 Stunde. Neben einem 1-Kanal-EKG mit Trockenelektroden (integriert in einen Brustgurt) und einem 2-Kanal-EKG mit Klebeelektroden wurden Bewegungsdaten, der Energieumsatz und die Elektrode-Haut-Impedanz des Brustgurts gemessen. Abbildung 4.19 zeigt das Setup der EKG-Messung, zusätzliche Beschleunigungssensoren befanden sich auf dem Sternum und an der Hüfte.

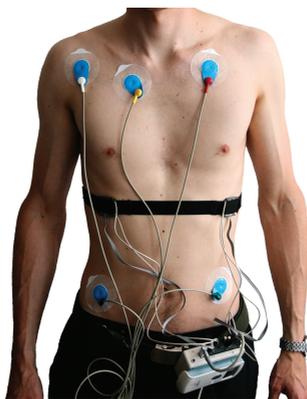


Abbildung 4.19: EKG-Aufnahme mit Brustgurt und Klebeelektroden

Alle Daten wurden entweder direkt mit 200 Hz aufgezeichnet oder wurden anschließend auf 200 Hz heruntergerechnet. Für 14 Datensätze wurde eine EKG-Referenzannotation erstellt.

ITIV_KFA###	
EKG	1-Kanal EKG mit Trockenelektroden 2-Kanal EKG mit Klebeelektroden Referenzannotation (14 Datensätze)
ACC	dreiachsiger Beschleunigungssensor Brust dreiachsiger Beschleunigungssensor Hüfte dreiachsiger Beschleunigungssensor linke Trockenelektrode dreiachsiger Beschleunigungssensor rechte Trockenelektrode Referenzannotation
IMP	Elektrode-Haut-Impedanz der Trockenelektroden

4.3.2 Holtervergleich

Mit dem *Medica-2008-System*, einem Prototyp eines textilintegrierten EKG-Systems, wurden die ersten Langzeitaufnahmen gemacht. Das EKG-System ist in ein Westen-ähnliches Kleidungsstück aus Jersey-Stoff integriert (s. Abb. 4.20). Mit Hilfe von drei Trockenelektroden werden zwei EKG-Kanäle abgeleitet, eine weitere Trockenelektrode dient als Driven Right Leg. Das EKG hat eine



Abbildung 4.20: Textilintegriertes EKG-System mit integriertem Beschleunigungssensor (links) und zugehörige Aufnahmehardware (rechts)

Auflösung von 250 Hz und 16 bit (LSB $1 \mu\text{V}/\text{bit}$). Das EKG-System ist in [Fuh09, Lam09] ausführlich beschrieben.

Neben dem EKG wurden die Beschleunigungsdaten des Elektronikgürtels und der EKG-Weste aufgezeichnet. Die dreiachsigen Sensoren haben eine Abtastrate von 50 Hz und eine Auflösung von 12 bit mit einem LSB von $0,00294 \text{ g}/\text{bit}$.

Mit diesem System, kombiniert mit einem zusätzlichen Holter-EKG (Medset Telesmart M) mit zwei geklebten bipolaren Ableitungen, wurden bei vier jungen, gesunden Probanden Langzeitaufnahmen gemacht. Dies ergab insgesamt über 61 Stunden EKG, welches durchgängig mit einer Referenzannotation versehen wurde. Zur besseren Handhabbarkeit wurden die Datensätze in 61 einstündige Datensätze zerlegt.

Holtervergleich_####

EKG	2-Kanal EKG mit Trockenelektroden
	2-Kanal EKG mit Klebeelektroden
	Referenzannotation
ACC	dreiachsiger Beschleunigungssensor Thorax (seitlich)
	dreiachsiger Beschleunigungssensor Hüfte

4.3.3 careMon

Gemeinsam mit der Universitätsklinik Tübingen (Innere Medizin III, Kardiologie) werden in der zur Zeit noch andauernden Langzeitstudie DekomTex Herzinsuffizienz- und Synkopenpatienten überwacht. Die Patienten tragen dabei neben einem Beschleunigungssensor am Arm den in einen Brustgurt integrierten *careMon*-Rekorder (s. Abb. 4.21) [Fuh10]. Dieser zeichnet unter anderem drei EKG-Ableitungen mit 256 Hz sowie Beschleunigungsdaten mit 64 Hz auf. Weitere Messdaten wie z. B. die Thoraximpedanz und die Körperoberflächentemperatur werden gemessen, sind aber für diese Arbeit weniger relevant.

Von den bisher aufgezeichneten Daten liegen 20 Datensätze von fünf männlichen Patienten mit einem durchschnittlichen Alter von $61 \pm 19,3$ Jahren vor, die eine Referenzannotation enthalten. Jeder dieser Datensätze hat eine Länge von ca. 24 h, während denen das Aufnahmesystem ununterbrochen getragen wurde.

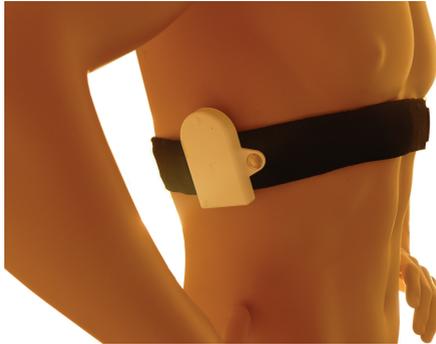


Abbildung 4.21: careMon-Gurt für das 24/7-EKG-Monitoring

DekomTex_####

EKG 3-Kanal EKG mit Trockenelektroden

ACC dreiachsiger Beschleunigungssensor Thorax (seitlich)

5 Artefaktbehandlung mit Hilfe von Kontextsignalen

Wenn man die Qualität einer EKG-Aufnahme durch verbesserte Aufnahmehardware oder Änderungen der äußeren Bedingungen nicht weiter steigern kann, so kann man wenigstens das Wissen über die Signalqualität für die EKG-Analyse nutzen. Informationen über die Signalqualität kann man direkt aus dem EKG ableiten, allerdings mit dem Risiko pathologische EKG-Veränderungen fälschlicherweise als Störung zu klassifizieren. Dieses Kapitel beschreibt, wie mit Hilfe von weiteren messbaren Signalen – den Kontextsignalen – die Qualität des EKG-Signals beurteilt oder verbessert werden kann.

5.1 Ziele der Artefaktbehandlung

Für den behandelnden Arzt ist es wichtig, dass er sich auf die Ergebnisse einer automatischen EKG-Analyse verlassen kann. Durch die alltäglichen Bewegungen, die ein Patient während einer Langzeit-EKG-Aufnahme macht, wird das Signal jedoch gestört. Dies wiederum führt zu Fehldetektion der automatischen EKG-Analyse und das Analyseergebnis ist nicht mehr verlässlich.

Dieser Problematik kann man entgegenwirken, indem man eine Artefaktbehandlung einsetzt. Eine sinnvolle Artefaktbehandlung teilt sich in zwei Bereiche: die Reduktion von Artefakten im EKG sowie die sichere Erkennung von Artefakten. Beide Maßnahmen lassen sich grundsätzlich auf Basis des EKG-Signals durchführen, Ziel dieser Arbeit ist jedoch, den Nutzen von messbaren Kontextsignalen für die automatische EKG-Analyse zu untersuchen. Deshalb liegt in diesem Kapitel der Schwerpunkt auf den Methoden zur Artefaktbehandlung, die Kontextsignale miteinbeziehen.

Die Artefaktreduktion ist im Allgemeinen kritisch zu beleuchten, da hier das EKG-Signal stark deformiert werden kann und somit die Morphologie

der einzelnen Kammerkomplexe möglicherweise nicht mehr aussagekräftig ist. Eine gut abgestimmte Artefaktreduktion sorgt aber dennoch dafür, dass Analysealgorithmen mit dem gefilterten Signal besser umgehen können als mit dem ungefilterten Signal – auch wenn das gefilterte EKG aufgrund der starken Deformation für die direkte Befundung durch einen Arzt nicht mehr verwendet werden kann.

Eine automatische Artefakterkennung sorgt dafür, dass die Signalbereiche, die nicht mehr sicher analysiert werden können, von der automatischen Analyse ausgeschlossen werden. Auf diese Art reduziert sich zwar die Länge der verwertbaren EKG-Aufzeichnung, die Ergebnisse auf den übrigen Daten werden aber sehr viel verlässlicher. Ein weiterer Vorteil der Artefakterkennung ist, dass EKG-Analysealgorithmen während der gestörten EKG-Sequenzen gestoppt werden können und damit das EKG nicht weiter untersuchen. Damit wird verhindert, dass interne Schwellwerte von Analysealgorithmen verändert werden und sich beispielsweise an hohe Artefaktamplituden anpassen.

An dieser Stelle wird deutlich, dass die automatische Artefaktbehandlung in einem sehr engen Zusammenhang zur Aufnahmehardware und zur nachgeschalteten EKG-Analyse steht. Je besser die Signalqualität ist, desto weniger wird eine Artefaktbehandlung benötigt. Bei einer geringen Signalqualität, die zu vielen Fehldetektionen bei der EKG-Analyse führt, sorgt eine darauf abgestimmte Artefaktbehandlung für erhebliche Verbesserungen.

5.2 Artefakterkennung

Es gibt verschiedene Möglichkeiten, eine verlässliche Artefakterkennung auf Basis von Kontextsignalen, also sogenannte *Second-Channel-Methoden*, zu implementieren. In Abbildung 5.1 sind die EKG-Signale von zwei verschiedenen Probanden während gleicher körperlicher Aktivität (Joggen) gezeigt. Es ist deutlich zu sehen, dass das EKG von Proband B zu viel mehr Artefakten neigt als das des Probanden A. Eine Artefakterkennung nur auf der Basis von Bewegungsinformationen ist also schwierig, es müssen immer sowohl das EKG-Signal als auch der Second Channel betrachtet werden.

Die unterschiedliche Artefaktanfälligkeit hat verschiedene Gründe. Zum einen weicht die Elektrodenposition bei jedem Anlegen eines Messsystems minimal voneinander ab, deshalb kann der Einfluss des Elektromyogramms

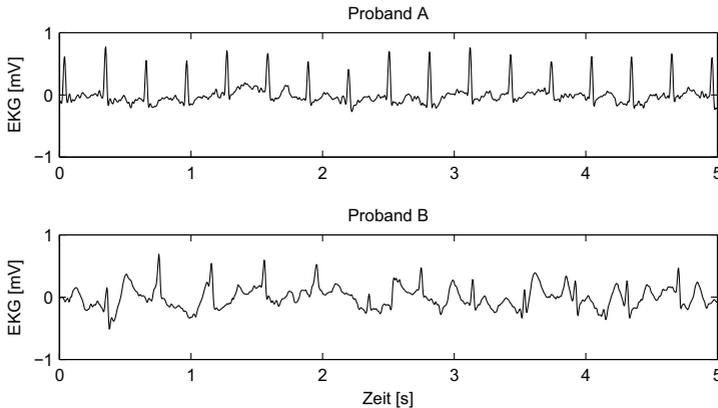


Abbildung 5.1: Bei unterschiedlichen Probanden kann trotz gleicher Aktivität (hier: Joggen) die EKG-Qualität erheblich abweichen

verschieden ausfallen. Zum anderen sind die Hauteigenschaften verschiedener Personen unterschiedlich, ebenso die Ausprägung von Fett und Muskeln. Es kommt zwar bei Hautdeformation überall zu Potentialverschiebungen, aber die Ausprägung kann individuell unterschiedlich stark sein. Des Weiteren können die Kontaktbedingungen zwischen Elektrode und Haut variieren. Dies betrifft neben der Behaarung sowohl die Feuchte als auch den Elektrolytgehalt des Schweißes. Nicht zuletzt ist die Gurtspannung zu nennen, die sich leicht unterscheiden kann. Ein locker getragener Brustgurt neigt zu mehr Artefakten als ein stramm getragener.

5.2.1 Artefaktdefinition

Wird die Artefakterkennung im Rahmen einer automatischen QRS-Detektion eingesetzt, sollte diese auch zur Definition von Artefakten herangezogen werden. Gemäß der bereits in [Ott08a, Ott08b] veröffentlichten Definition werden die EKG-Signale mit einer QRS-Referenzannotation versehen, gegen die mit Hilfe eines Beat-by-Beat-Komparators (BxB) die automatisch erstellte QRS-Triggerliste validiert wird. Für die weitere Auswertung wurde angenommen, dass QRS-Falschdetektionen nur dann auftreten, wenn Artefakte vorhanden

sind. Aus den Ergebnissen der QRS-Detektion auf dem artefaktbehafteten EKG können also Artefaktbereiche identifiziert werden: Als Artefakte werden die EKG-Passagen gekennzeichnet, in denen falsch-positive (FP_{qrs}) oder falsch-negative (FN_{qrs}) Detektionen vorliegen. Ist die QRS-Detektion korrekt (TP_{qrs}), gilt der Bereich als artefaktfrei. Diese Bereiche werden nun, wie in Abbildung 5.2 dargestellt, mit den vom Artefakterkennner gefundenen Bereichen verglichen. Auf diese Weise lassen sich folgende Werte für die Wahrheitsmatrix berechnen:

$$TP_{\text{ad}} = FN_{\text{qrs,in}} + FP_{\text{qrs,in}} \quad (5.1)$$

$$TN_{\text{ad}} = TP_{\text{qrs,out}} \quad (5.2)$$

$$FP_{\text{ad}} = TP_{\text{qrs,in}} \quad (5.3)$$

$$FN_{\text{ad}} = FN_{\text{qrs,out}} + FP_{\text{qrs,out}} \quad (5.4)$$

Die Indizes *in* bezeichnen Schläge innerhalb der von der Artefakterkennung als Artefakt markierten Bereiche, die Indizes *out* Schläge außerhalb. Mit Hilfe der so berechneten Werte lassen sich die Sensitivität Se_{ad} und Spezifität Sp_{ad} des Artefakterkenners bestimmen:

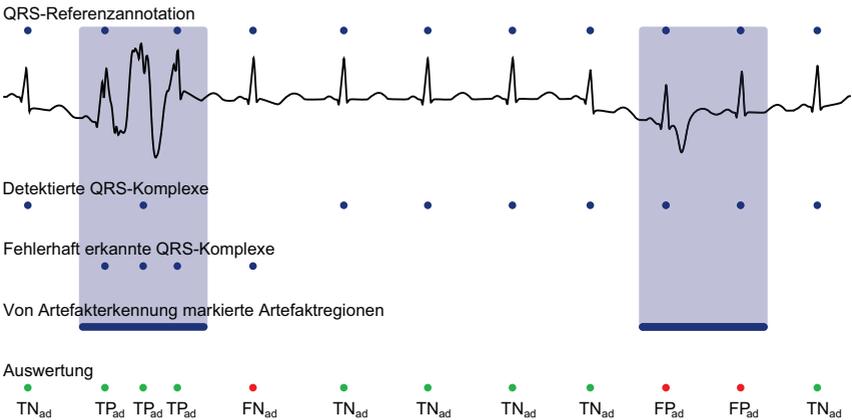


Abbildung 5.2: Die Artefaktbereiche werden auf Basis der QRS-Detektion bestimmt

$$\begin{aligned}
 Se_{ad} &= \frac{TP_{ad}}{TP_{ad} + FN_{ad}} \\
 &= \frac{FN_{qrs,in} + FP_{qrs,in}}{FN_{qrs,in} + FP_{qrs,in} + FN_{qrs,out} + FP_{qrs,out}} \quad (5.5)
 \end{aligned}$$

$$Sp_{ad} = \frac{TN_{ad}}{TN_{ad} + FP_{ad}} = \frac{TP_{qrs,out}}{TP_{qrs,out} + TP_{qrs,in}} \quad (5.6)$$

5.2.2 Artefaktschätzung mit adaptivem Filter

Da für das Auftreten von Bewegungsartefakten immer eine Bewegung verantwortlich ist, bietet sich das einfach aufzunehmende Bewegungssignal als artefaktkorrelierter Parameter an. Letztendlich ist das Vorhandensein von Bewegung aber nur eine notwendige Bedingung für Bewegungsartefakte – ein während starker körperlicher Belastung aufgezeichnetes EKG kann auch störungsfrei sein. Aus diesem Grund darf aus einer vorhandenen Bewegung nicht zwangsläufig auf vorhandene Artefakte geschlossen werden, umgekehrt kann aber davon ausgegangen werden, dass bei fehlender Bewegung eine eher gute Signalqualität vorliegt. Die folgenden Ausführungen wurden in Teilen bereits in [Kir09, Ott08b, Ott08a] veröffentlicht.

Algorithmus

In dem hier beschriebenen Ansatz zur Artefakterkennung wird deshalb das Bewegungssignal genutzt, um den Artefaktanteil im EKG zu schätzen. Dazu wird ein adaptives LMS-Filter benutzt, das neben dem EKG auch das Signal des Beschleunigungssensors erhält (s. Abb. 5.3). Im ersten Schritt werden dazu die drei Achsen des Beschleunigungssensors über arithmetische Mittelung zusammengefasst. Das so errechnete eindimensionale Beschleunigungssignal wird anschließend hochpassgefiltert und zusammen mit dem EKG dem adaptiven Filter zugeführt. Der Ausgang des adaptiven Filters wird quadriert und mit einem gleitenden Mittelwert gefiltert. Das so erhaltene Artefaktlevel kann nun als Maß genommen werden, wie stark das EKG mit Artefakten belastet ist. Überschreitet die Amplitude einen festgelegten Schwellwert, gilt das EKG als artefaktbelastet. Nach dem Unterschreiten des Schwellwertes bleibt eine

weitere Sekunde des EKGs als Artefakt markiert, um sicherzustellen, dass sich das Signal wieder eingeschwungen hat.

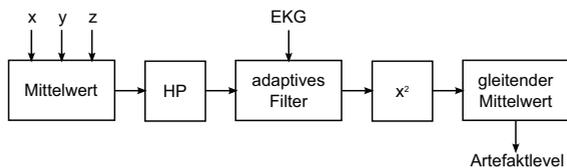


Abbildung 5.3: Das Artefaktlevel wird aus Beschleunigungs- und EKG-Daten berechnet

Ergebnisse ITIV_KFA

Das beschriebene System wurde mit den ITIV_KFA-Daten validiert. Dabei wurde das EKG über Klebeelektroden aufgenommen, der Beschleunigungssensor befand sich wahlweise am Sternum oder an der Hüfte. Dieses Szenario ist mit einem konventionellen Holterrekorder vergleichbar, der oftmals am Gürtel oder in einem Umhängebeutel vor der Brust getragen wird.

Variiert man den Schwellwert zur Artefakterkennung, hat dies unmittelbare Auswirkungen auf die Erkennungsgüte. Nach der Berechnung von Sensitivität und Spezifität kann man diese in einen ROC-Grafen (Receiver Operating Curve) eintragen. Der ROC-Graf in Abbildung 5.4 vergleicht die Ergebnisse der Artefakterkennung von beiden Beschleunigungssensorpositionen. Die Fläche unterhalb der Kurve (area under curve, AUC) ist ein allgemeines Maß für die Güte des jeweiligen Artefakterkenners. Sie beträgt für die Sensorposition an der Brust 88,84 % und für die Position an der Hüfte 90,23 %. Das System mit dem an der Hüfte getragenen Beschleunigungssensor ist geringfügig besser, was vermutlich auf die stärkeren Beschleunigungen beim Laufen an der Hüfte zurückzuführen ist.

Im optimalen Arbeitspunkt konnte mit diesem System die Anzahl der falsch detektierten QRS-Komplexe um 79,6 % reduziert werden. Dabei wurde ein Anteil von 10,2 % des EKGs als Artefakt markiert. In Tabelle 5.1 sind die Ergebnisse, gemittelt über alle Testdaten, eingetragen. Betrachtet man den Algorithmus mit der günstigeren Sensorposition genauer, kann man eine signifikante Reduktion der Fehldetektionen feststellen ($p_{FN} = 0,049$, $p_{FP} = 0,031$). Die Gesamtzahl der Fehldetektionen reduziert sich von 573 auf 117.

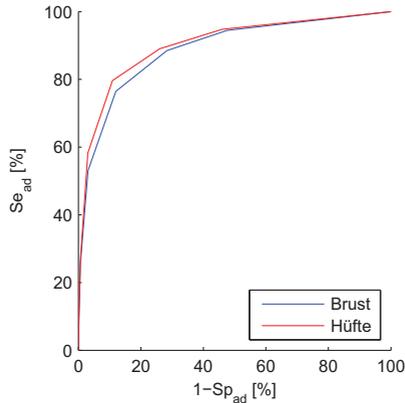


Abbildung 5.4: Je nach Schwellwert kann der Algorithmus sensitiver oder spezifischer eingestellt werden

Tabelle 5.1: Die Artefakterkennung verbessert das Ergebnis der QRS-Detektion

Sensorpos.	Se_{qrs} [%]	pP_{qrs} [%]	Se_{ad} [%]	Sp_{ad} [%]	Art.anteil [%]
Ag/AgCl-Elektroden	99,80	99,53	–	–	–
Hüfte	99,92	99,90	76,44	88,02	11,06
Brust	99,92	99,92	79,58	89,09	10,18
Trocken-elektroden	99,29	98,98	–	–	–
Impedanz	99,80	99,83	82,45	90,37	10,0

Die hier präsentierten Ergebnisse sind sehr überzeugend. Mit nur geringem hardwaretechnischen Mehraufwand kann eine deutliche Reduktion der Fehldektionen erreicht werden. Das dabei von der weiteren Analyse ausgeschlossene Signal hat mit etwa 10 % eine vertretbare Größenordnung. Das vorgestellte System lässt sich für klassische Holtersysteme mit Klebeelektroden nutzen, sofern Beschleunigungsdaten aufgenommen werden. Bei anderen Abstraten – insbesondere wenn diejenigen von Beschleunigungssensor und EKG divergieren – muss das adaptive Filter neu abgestimmt werden.

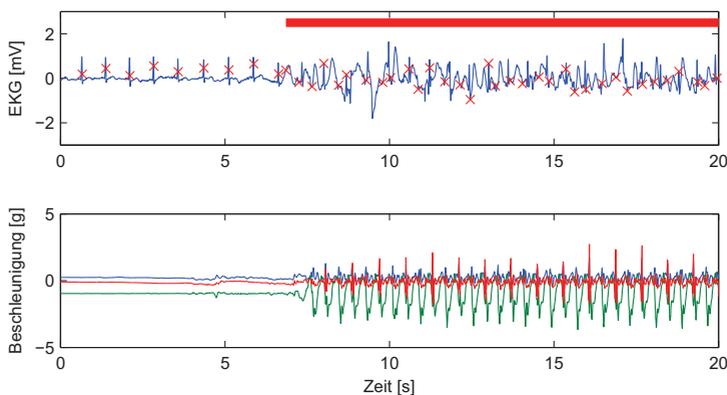


Abbildung 5.5: Mit dem Einsetzen der Bewegung (hier: Rennen) nehmen die Bewegungsartefakte zu, das EKG wird anschließend als artefaktbehaftet markiert (roter Balken)

Nutzt man statt der Beschleunigungsdaten die Elektrode-Haut-Impedanz und untersucht das stärker artefaktbehaftete EKG der Trockenelektroden, kann die Erkennungsleistung weiter gesteigert werden. Die in [Ott08b] veröffentlichten Untersuchungen ergaben einen AUC-Wert von 91,8 %. Im Arbeitspunkt konnten 82,45 % der fehlerhaft detektierten QRS-Komplexe als Artefakt erkannt werden, der als Artefakt markierte Signalanteil betrug 10 %. Der direkte Vergleich zur Beschleunigungsdaten-basierten Methode attestiert diesem Ansatz einen leichten Vorteil, nicht zuletzt aufgrund der stärkeren Korrelation zwischen Elektrode-Haut-Impedanz und Störungen. Die Aufnahme der Elektroden-Haut-Impedanz ist jedoch schaltungstechnisch aufwändiger und setzt spezielle, geteilte Elektroden voraus.

Ergebnisse Holtervergleich

Wechselt man jedoch das Aufnahmesystem, indem man auf textilintegrierte Trockenelektroden zurückgreift, ändert sich das Artefaktverhalten stark. Dieses Verhalten konnte bei den Holtervergleich-Datensätzen bestätigt werden. Das neuartige, textile Tragesystem mit integrierten trockenen Elektroden ist

deutlich artefaktan anfälliger als das konventionelle EKG mit Klebeelektroden [Fuh09]. In diesem Fall liegt das maßgeblich an der Elektrodenkonfiguration und den Trägern des Textils (vgl. Abb. 4.20 auf Seite 89). Durch die Träger werden viele Armbewegungen auf die Elektroden übertragen, ohne ein für die Artefaktdetektion ausreichendes Beschleunigungssignal zu liefern.

Das eingesetzte Artefakterkennungssystem wurde den abweichenden Abstraten angepasst und für den Einsatz auf einem mobilen System optimiert. Damit mussten an einigen Stellen Vereinfachungen vorgenommen werden, um der Wortbreite des eingesetzten 16 Bit-Prozessors gerecht zu werden. Die erreichten Ergebnisse lagen aber bezüglich der Erkennungsgüte hinter den zuvor beschriebenen Ergebnissen zurück. Die Artefakterkennung erreichte eine Güte von $AUC = 73,25\%$. Im Arbeitspunkt lag die Spezifität für die Artefakterkennung bei $81,2\%$ und die Sensitivität bei $66,5\%$. Dennoch konnte die positive Prädiktivität der QRS-Erkennung von $81,5$ auf $91,9\%$ und die Sensitivität von $89,4$ auf $93,3\%$ gesteigert werden.

5.2.3 Artefakterkennung aus dem EKG

Bei der Durchführung der DekomTex-Studie – begleitet durch den Wechsel des Messsystems und der Anwendung im Feld – wurde festgestellt, dass sich das Artefaktverhalten der EKG-Messungen erheblich verändert. Es dominieren nicht mehr die Bewegungsartefakte, sondern Störungen durch lockere oder komplett abgelöste Elektroden, was sich durch Einkoppelung des 50 Hz-Signals (von wenigen mV bis zur Aussteuerungsgrenze des EKG-Verstärkers), durch eine scheinbare Nulllinie oder durch Einkoppelung des Impedanzsignals der im Messsystem integrierten Thoraximpedanzmessung mit 8 Hz bemerkbar macht.

Eine Bewegung selbst führt zwar auch häufig zu Artefakten, der Anteil an bewegungsinduzierten Fehlerkennungen ist aber relativ gering. Hinzu kommt, dass das Patientenkollektiv weniger mobil ist und der Anteil an Bewegungen im Mittel nur ca. 9% ausmacht. Im Gegenzug kann jedoch eine kurze körperliche Bewegung der Auslöser für ein Verrutschen oder vorübergehendes Ablösen der EKG-Elektroden sein und somit das EKG in der Zeit nach der Bewegung drastisch verändern. In Abbildung 5.6 sind einige dieser Veränderungen veranschaulicht. Gezeigt sind drei verschiedene EKG-Sequenzen eines Patienten vor und nach einer kurzen Bewegung: Ein komplettes Ablösen einer EKG-Elektrode führt im Regelfall zu starken 50 Hz-Störeinkoppelung (oben), ein Verrutschen

der Elektrode kann deutliche Änderungen in der EKG-Amplitude hervorrufen (Mitte), das Ablösen einer Impedanz-Elektrode führt zu einer verstärkten Einkoppelung des 8 Hz-Impedanzsignals (unten).

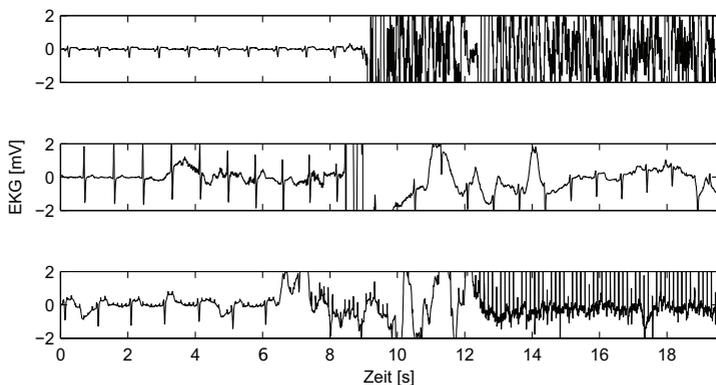


Abbildung 5.6: Nach einer kurzen körperlichen Bewegung kann sich das EKG-Signal auf verschiedene Weise drastisch verändern

Da die Bewegung zwar die Störungen verursacht, aber nicht während der Störung anhält und ein zuverlässiges Lead-Off-Signal für die einzelnen EKG-Kanäle fehlt, müssen solche Artefakte allein mit Hilfe des EKG-Signals erkannt werden. Aufgrund der charakteristischen Frequenzen bzw. der hohen Amplitude ist dieses jedoch verhältnismäßig einfach zu realisieren. Lediglich bei einer abgelösten EKG-Elektrode fern von einer 50 Hz-Netzleitung ist das eingekoppelte Störsignal so gering, dass es auf dem ersten Blick einer Asystolie gleicht, welche natürlich – insbesondere bei telemedizinisch angebundenen Systemen – nicht als Artefakt herausgefiltert werden darf.

Implementiert man eine solche Artefakterkennung – basierend auf der Frequenzanalyse von 30 s-Segmenten und einer Schwellwernererkennung vor der Aussteuergrenze des EKG-Verstärkers – werden 10 % ($\pm 20,3$ %) der careMon-Testdaten als Artefakt markiert. Betrachtet man nur Artefakte, die in allen drei Kanälen gleichzeitig vorkommen, sind lediglich 0,8 % ($\pm 1,3$ %) des Gesamtsignals als Artefakt erkannt. Auf diese Weise kann ein Großteil der Artefakte im EKG automatisch erkannt werden, das übrige EKG-Signal enthält aber nach wie vor viele Fehldetektionen, die unter anderem durch Bewegung verursacht werden.

Für dieses übrige Signal wird nun ein Artefaktlevel entsprechend Kapitel 5.2.2 berechnet, um Sequenzen mit Bewegungsartefakten zu erkennen. Der zugehörige ROC-Graf (nur Kanal 1) ist in Abbildung 5.7 zu sehen, der AUC-Wert beträgt für diese Konfiguration 80,8 %. Wegen des starken Einflusses des Beschleunigungssignals auf die Artefakterkennung ähneln sich die Artefaktbereiche zwischen den einzelnen EKG-Kanälen stark. Analysiert man die Positionen der verbleibenden Fehldetektionen, stellt sich heraus, dass 59 % der Fehldetektionen in Kanal 1 in Bereichen mit körperlicher Bewegung vorliegen, wobei nur 9 % der EKG-Aufnahmen Bewegungen enthalten. Die Fehldetektionen liegen also vermehrt – aber nicht ausschließlich – bei körperlicher Bewegung vor. Eine Artefakterkennung, die das Bewegungssignal als notwendiges Kriterium für Artefakte benötigt, wird hier schwer eine Sensitivität von über 59 % erreichen können.

Aus diesem Grund wurde nach alternativen Verfahren gesucht, die fehlerhaften EKG-Sequenzen zu detektieren. Bei genauerer Betrachtung fällt ein Zusammenhang zwischen Fehldetektionen und maximaler EKG-Amplitude auf: Übersteigt die maximale Amplitude im EKG innerhalb eines Zeitraums von 1,25 s einen kanalabhängigen Schwellwert, liegt mit hoher Wahrscheinlichkeit ein Artefakt vor. Mit dieser relativ einfachen und in Matlab sehr effizient umsetzbaren Artefakterkennung lassen sich Ergebnisse erzielen, die in derselben Größenordnung liegen, wie die mit dem Beschleunigungssignal berechneten, der AUC-Wert liegt bei 80,1 % (s. Abb. 5.7). Aufgrund des deutlich reduzierten Rechenaufwandes ist letztgenanntes Verfahren vorzuziehen. Vergleichbare Ergebnisse beider Verfahren finden sich in Tabelle 5.2.

Tabelle 5.2: Die Artefakterkennung verbessert das Ergebnis der QRS-Detektion

	ohne	adaptives Filter	EKG-Amplitude
Se_{QRS} [%]	99,80 ± 0,06	99,97 ± 0,03	99,97 ± 0,02
pP_{QRS} [%]	99,53 ± 0,36	99,83 ± 0,20	99,84 ± 0,16
Se_{ad} [%]	–	52,23 ± 28,97	51,39 ± 20,46
Sp_{ad} [%]	–	90,62 ± 4,54	96,42 ± 3,61
Artefaktanteil [%]	–	7,61 ± 3,32	7,26 ± 6,99
AUC [%]	–	80,8	80,1

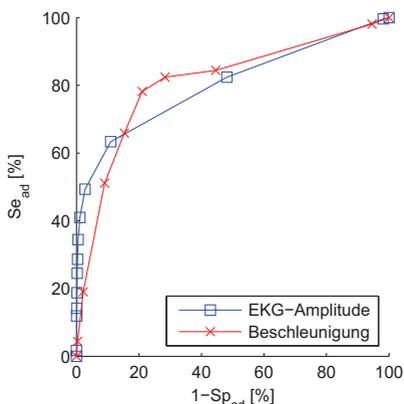


Abbildung 5.7: Artefakterkennung mit und ohne Berücksichtigung von Bewegungsinformationen bei den careMon-Daten

5.2.4 Zusammenfassung

Bevor Bewegungsinformationen als weiterer Parameter für die Artefakterkennung hinzugezogen werden, sollte das Anwendungsszenario genau überprüft werden. Bei EKG-Systemen, die überwiegend bei sportlichen Aktivitäten benutzt werden, sind viele der Bewegungsartefakte durch eine kurze und schnelle körperliche Bewegung verursacht. Ein System zum Langzeitmonitoring bei einem eher passiven Patientenkollektiv neigt zu weniger Bewegungsartefakten. Die wenigen auftretenden Artefakte können zwar durchaus durch eine körperliche Aktivität verursacht werden, weit häufiger ist jedoch ein leichtes Verrutschen der Elektroden auf dem Körper, das selten von einem auffälligen Bewegungssignal begleitet wird. Ein weiterer Faktor ist die grundsätzliche Störanfälligkeit des verwendeten Aufnahmesystems.

Die meisten lange andauernden Artefakte werden durch einen schlechten Elektrodenkontakt verursacht. Liegt ein mehrkanaliges EKG vor und wird die Artefakterkennung für jeden Kanal separat vorgenommen, überlappen sich diese Artefakte selten. Während bei den careMon-Daten die Artefaktbereiche für die einzelnen Kanäle 5–10 % betragen, liegen nur 1,4 % ($\pm 1,6$ %) der Artefakte in allen drei Kanälen gleichzeitig vor.

5.3 Artefaktreduktion

Der entscheidende Nachteil der Artefakterkennung ist der Signalausbruch, d. h. EKG-Abschnitte, die aufgrund von enthaltenden Störungen nicht mehr analysiert werden. Wenn es nun möglich ist, gezielt die Artefakte im EKG herauszurechnen oder das ungestörte EKG während der Artefakte zu schätzen, könnten solche Signalabschnitte weiterhin verwertet werden.

Bei der automatischen Artefaktreduktion können zwei Ziele verfolgt werden: Zum einen kann versucht werden, das EKG so darzustellen, wie es bei einer artefaktfreien Aufnahme der Fall wäre. Zum anderen kann durch entsprechende Filterung erreicht werden, dass eine automatische QRS-Erkennung bessere Ergebnisse liefert, während die Morphologie des Signals dabei jedoch stark deformiert wird. Beide Ansätze können auch kombiniert werden, allerdings muss ein für den menschlichen Betrachter sauber erscheinendes EKG nicht zwangsläufig für einen QRS-Detektor besser zu analysieren sein. Umgekehrt kann es sein, dass ein stark gefiltertes Signal, das fehlerfrei von einem QRS-Detektor analysiert wird, fast keine Ähnlichkeit mehr mit einem EKG besitzt und nicht mehr für eine morphologische Befundung herangezogen werden kann.

Technisch betrachtet beginnt die Artefaktreduktion bereits mit der analogen Bandbegrenzung des Aufnahmesystems und zieht sich über spezielle Notch-Filter zur Unterdrückung der kapazitiven Einkopplungen aus dem Versorgungsnetz bis hin zu komplexen Algorithmen der digitalen Signalverarbeitung zur Unterdrückung von Bewegungsartefakten.

5.3.1 Artefaktreduktion ohne Kontextsignale

Mit einfachen FIR- oder IIR-Filtern lässt sich eine Vielzahl von Störungen aus dem EKG entfernen, dazu gehören zum Beispiel langsame Grundlinienschwankungen, hochfrequentes Rauschen oder 50 bzw. 60 Hz-Einkopplungen aus dem Versorgungsnetz. Die Filterung von Bewegungsartefakten fällt jedoch schwer, da sich deren Frequenzspektrum mit dem des EKGs überlappen kann.

Mit dem Einsatz von morphologischen Filtern zur Reduktion von Bewegungsartefakten und Grundlinienschwankungen wurden im Rahmen dieser Arbeit gute Ergebnisse erzielt. Der Vorteil morphologischer Filter ist die geringere Deformation des EKGs im Vergleich zu FIR- oder IIR-Filtern. Stellenweise muss

jedoch eine Reduktion der QRS-Amplitude hingenommen werden (s. Abb. 5.8). Morphologische Filter sind stets stabil und benötigen keine Multiplikationen, was für ihren Einsatz in mobilen Systemen spricht.

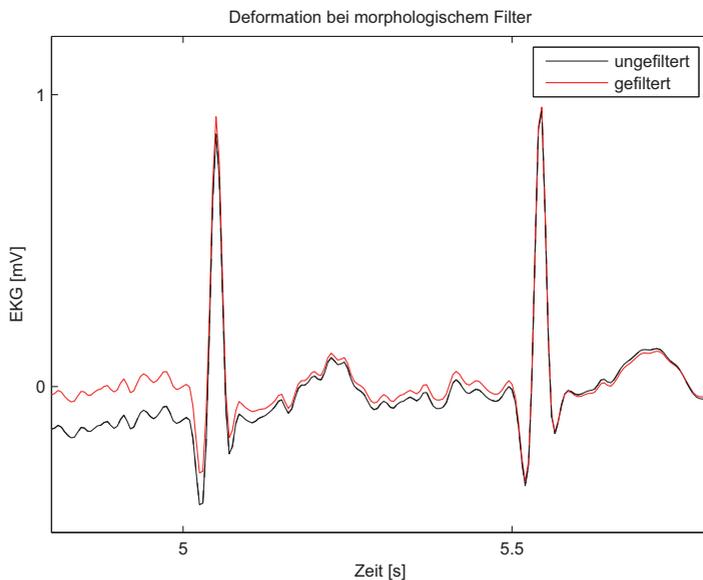


Abbildung 5.8: Die Deformation des gefilterten EKG-Signals ist minimal (Ausschnitt aus Abb. 5.9)

Bei den stark artefaktbelasteten Holtervergleich-Daten führt eine mit einem morphologischen Filter realisierte Unterdrückung der Grundlinienschwankung – und damit auch von langsamen oder niedrigamplitudigen Bewegungsartefakten – zu einer hoch signifikanten ($p < 0,0001$) Verbesserung der positiven Prädiktivität, während die Sensitivität fast unverändert bleibt (s. Tab. 5.3). Die stabilisierte Baseline des gefilterten EKGs sorgt also für eine deutliche Reduktion der falsch-positiven QRS-Detektionen.

Das EKG in Abbildung 5.9 zeigt das Prinzip der Filterung: Das morphologische Filter extrahiert aus dem EKG die Grundlinie, anschließend wird diese vom Ursprungssignal subtrahiert. Das so gefilterte EKG hat erheblich weniger Schwankungen, verliert aber – insbesondere bei breiten QRS-Komplexen – auch

Tabelle 5.3: Die Artefaktreduktion mit morphologischen Filtern führt zu einer signifikanten Verbesserung der positiven Prädiktivität

	Se [%]	pP [%]
ohne morph. Filter	88,12 ±13,82	80,69 ±19,54
mit morph. Filter	88,68 ±14,47	83,01 ±18,35

etwas an der QRS-Amplitude.

Da bei dieser Arbeit der Schwerpunkt auf der Verwendung und dem Nutzen von Kontextsignalen liegt, werden morphologische Filter nur für Vergleichszwecke herangezogen oder aber als eine Filterstufe zur Signalvor- oder Nachbearbeitung in ein anderes Verfahren integriert. Grundsätzlich ist zu beobachten, dass

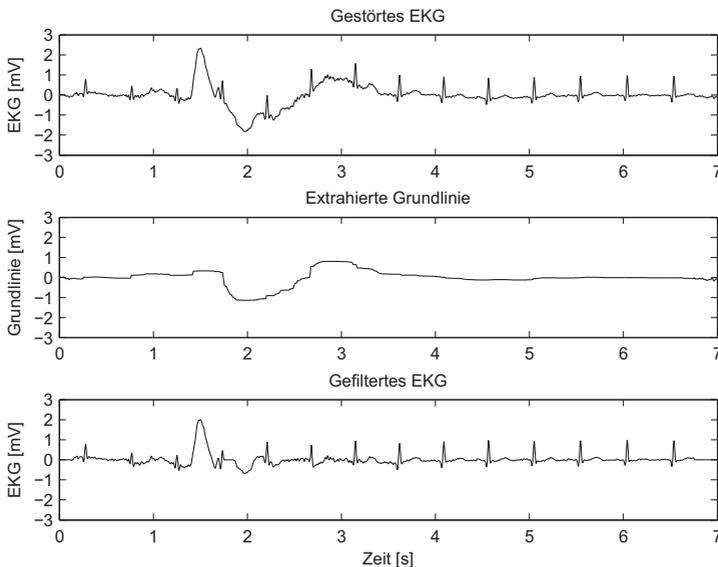


Abbildung 5.9: Morphologische Filter eignen sich zur Reduktion von Grundlinienschwankungen – ohne auf Kontextsignale angewiesen zu sein

der Einsatz morphologischer Filter nicht zwangsläufig zu einer Verbesserung der QRS-Detektion führt. Besonders einfache QRS-Erkennungsalgorithmen reagieren sehr empfindlich auf eine Baseline-Veränderung, somit ist dort die größte Verbesserung zu erkennen. Bei komplexeren Algorithmen hingegen muss es zu keiner signifikanten Veränderung der QRS-Detektion kommen. Dies ist auf die interne Signalfilterung zurückzuführen: Innerhalb des QRS-Detektors wird das Signal so stark gefiltert, dass es für den menschlichen Betrachter kaum noch als EKG identifiziert werden kann – es aber für den Algorithmus die QRS-Erkennung erheblich vereinfacht bzw. erst ermöglicht. Ebenso spielt das verwendete Aufnahmesystem eine entscheidende Rolle. Wenn die dortige Hardware schon einen sehr engen Bandpass hat und damit kaum noch Grundlinienschwankungen im aufgezeichneten EKG vorhanden sind, ist der Einsatz morphologischer Filter zur Grundlinienschwankungsunterdrückung nicht sinnvoll.

5.3.2 Adaptive Störsignalunterdrückung

Für eine adaptive Störsignalunterdrückung benötigt man neben dem gestörten Nutzsignal noch ein weiteres Signal, das mit der Störung – nicht aber mit dem Nutzsignal – korreliert. Mit Hilfe eines adaptiven Filters lässt sich der Fehler im gestörten Signal minimieren. Um ein solches System erfolgreich einzusetzen, braucht man sowohl die richtige Dimensionierung des adaptiven Filters als auch ein geeignetes Referenzsignal. Der Aufbau eines Filters zur adaptiven Störsignalunterdrückung ist in Abbildung 5.10 gezeigt.

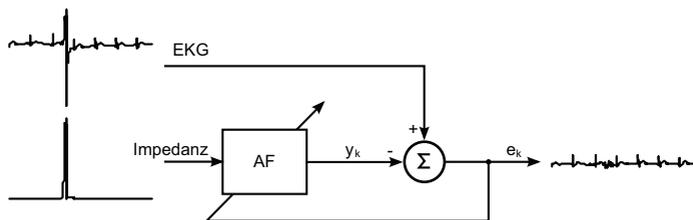


Abbildung 5.10: In der Theorie wird neben dem EKG eine Störreferenz als zusätzlicher Eingang benötigt, um das EKG von den Artefakten zu befreien

Bereits in Kapitel 4.1.2 wurde gezeigt, dass das Bewegungssignal zwar ein Indikator für Bewegungen und damit auch Bewegungsartefakte ist, aufgrund der geringen Korrelation zu den Störungen aber nicht das ideale Referenzsignal für ein adaptives Filter bildet. Die verhältnismäßig hohe Korrelation mit dem EKG führt im Gegenteil zu der Gefahr, dass die QRS-Komplexe selbst verändert bzw. entfernt werden.

Die Kreuzkorrelationsfunktion zwischen Impedanzsignal und EKG sieht zwar sehr vielversprechend aus, reicht aber in der Praxis nicht aus, um mit Hilfe von adaptiven Filtern das Signal in artefaktbehafteten Sequenzen zu rekonstruieren. Für einzelne isolierte Artefakte kann das Filter durchaus Signalverbesserungen bewirken, in der Gesamtheit ist jedoch kein zufriedenstellendes Ergebnis zu erreichen. Eine solche Signalverbesserung ist im Beispiel in Abbildung 5.11 zu sehen, bei dem ein gezielter Druck auf die Elektroden ausgeübt wurde. Das ungestörte EKG wird durch das adaptive Filter nicht beeinflusst (s. Abb. 5.12 links). Erst bei dem großen Ausschlag im Referenzsignal sorgt der adaptive Algorithmus für eine Minimierung des Fehlers im Ausgangssignal (s. Abb. 5.12 rechts). Für die abgebildeten Versuche wurde ein adaptives LMS-Filter mit $\mu = 0,1$, $N = 32$ und einem Vergessensfaktor von $\rho = 0,99$ gewählt. Die verwendeten Daten wurden in Labormessungen aufgenommen und haben eine Abtastrate von 200 Hz.

Grenzen von adaptiven Filtern

Die Praxis zeigt jedoch, dass nicht alle Artefakte auf diese Weise reduziert werden können. Es kommt sogar vor, dass im selben Datensatz an anderer Stelle der auftretende Bewegungsartefakt durch das adaptive Filter verstärkt wird, obwohl das Artefakt unter vergleichbaren Bedingungen entstanden ist. Betrachtet man Datensätze, die mit einem mobilen Messgerät im Feld aufgenommen wurden, verstärkt sich dieser Effekt. Hier kommt erschwerend hinzu, dass die Bewegungsartefakte üblicherweise von unterschiedlicher Natur und Stärke sind. Man kann in einem solchen Fall lediglich von einer Artefaktveränderung, nicht aber von einer Artefaktreduktion sprechen. Positiv ist lediglich die Tatsache, dass ungestörte EKG-Signalbereiche nicht deformiert werden, wie es bei konventionellen FIR-Filtern hoher Ordnung häufig der Fall ist. Eine wirkliche Signalverbesserung gibt es also nur in Einzelfällen und unter Laborbedingungen.

Ähnlich lassen sich auch die Ergebnisse aus [Ham97, Ham00a, Ham00b] interpretieren. Die Signale wurden hier unter sehr kontrollierten Bedingungen

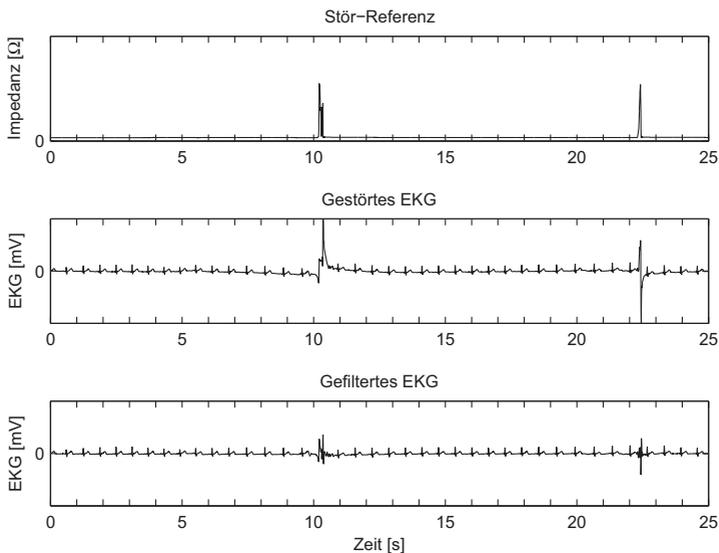


Abbildung 5.11: In Einzelfällen führt die Artefaktreduktion mit einem adaptiven Filter zu Verbesserungen

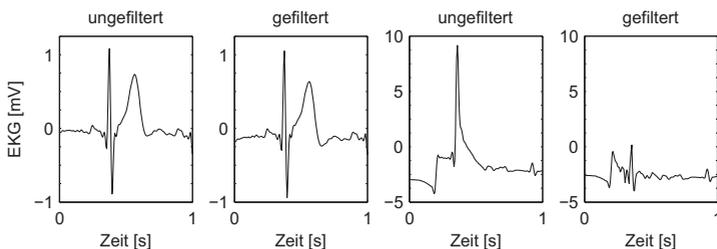


Abbildung 5.12: Das normale EKG wird durch das Filter kaum beeinflusst (links), Artefakte werden hingegen stark reduziert (rechts)

aufgezeichnet, was zu einer sehr guten Korrelation zwischen Artefakt und Referenzsignal führte. An anderer Stelle wiederum waren die Artefakte so gering oder niederfrequent, dass sie auch mit einem herkömmlichen Baseline-Wander-Removal entfernt werden könnten.

In der Arbeit von [Ton02] wurde ein dreiachsiger Beschleunigungssensor unmittelbar auf der Klebeelektrode befestigt und anschließend ein EKG abgeleitet. Die klar definierten Störungen führten zu starken Artefakten, ließen sich aber gut herausfiltern. Die Abbildungen jener Veröffentlichung lassen aber keine Details erkennen, sodass man nicht beurteilen kann, inwieweit das EKG deformiert wird.

Der Versuchsaufbau in [Liu06], wo eine EKG-Elektrode am Unterarm befestigt ist und dort durch Hautdehnung Artefakte induziert werden, entspricht ebenfalls keinem sehr realistischen Alltagsszenario. Das Referenzsignal des adaptiven Filters sind die Signale eines Dehnungssensors. Die Ergebnisse kann man als mäßig bezeichnen; ob sich die QRS-Erkennung auf dem gefilterten EKG verbessert, ist unklar.

Die in [Liu11] vorgestellten Ergebnisse (Beschleunigungssignal als Referenz) sind ebenfalls nicht überzeugend: Auch bei ungestörtem EKG gibt es eine deutliche Amplitudenreduktion und eine starke Morphologieveränderung im EKG. Die beim Gehen auftretenden Bewegungsartefakte können aber zum Teil reduziert werden. Ob dies zu einer Verbesserung der automatischen QRS-Detektion führt, bleibt unklar. Eine morphologische EKG-Interpretation ist nach der Filterung aber nicht mehr möglich.

In [Mil06] wird nur eine parallel zum Körper verlaufende Achse des verwendeten Beschleunigungssensors als Referenzsignal genutzt. Auf diese Weise wird vermutlich die Korrelation mit dem SKG minimiert, gleichzeitig ist die größte Bewegungsamplitude enthalten. Das verwendete Aufnahmeszenario entspricht mit Bewegungen wie Strecken und Gehen weitgehend den Aufnahmen im Alltag. Die Ergebnisse der Artefaktreduktion sind mäßig und stehen weit hinter der Vergleichsmethode (ICA) zurück. Leider wird nicht untersucht, ob die Filterung zu einer Verbesserung der automatischen QRS-Analyse führt. Ebenso ist nicht ersichtlich, inwieweit die Morphologie des (ungestörten) EKGs verändert wird.

Aus diesen Gründen eignen sich adaptive Filter in Verbindung mit Beschleunigungs- oder Impedanzsignalen nicht zur Reduktion von Bewegungsartefakten in Langzeit-EKG-Aufnahmen. Dies lässt sich zum einen mit einer schlechten Korrelation (bei Beschleunigungssignalen) und dem nicht-linearen Zusammenhang zwischen Kontextsignal und Artefakt im EKG begründen. Bereits Devlin

ging in [Dev84] auf diesen Umstand ein und stellte fest, dass das nicht-stationäre Artefaktsignal nicht mit Hilfe eines adaptiven Filters nachgebildet werden kann.

Die Erfolge, die die Firma Zoll mit der See-Thru CPR erzielt hat (s. Kap. 3.3.2), lassen sich wie folgt erklären: Bei der im Rahmen einer kardiopulmonalen Reanimation ausgeführten Herzdruckmassage wird der Thorax rhythmisch um ca. 5 cm komprimiert. Die dabei auftretenden Kräfte sind deutlich größer als die, die das Seismokardiogramm verursacht. Zwischen den Thoraxkompressionen ist die Koppelung zwischen Beschleunigungssensor und Körper eher schlecht. Es ist also davon auszugehen, dass das Kardioseismogramm im Beschleunigungssignal nicht wahrzunehmen ist. Die Artefakte werden zwar nicht gerade unter Laborbedingungen induziert, aber die stets gleichmäßige Herzdruckmassage ist diesen doch sehr ähnlich. Das gut korrelierte Referenzsignal ist in Abbildung 5.13 zu sehen (CPR, unten). Aus dem Rohsignal (RAW, Mitte) können die meisten Artefakte entfernt werden, sodass der QRS-Komplex das dominierende Ereignis ist (FIL, oben).

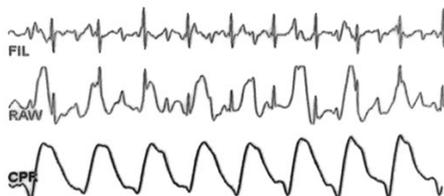


Abbildung 5.13: Die See-Thru CPR der Firma Zoll reduziert CPR-Artefakte im Rohsignal (RAW) und visualisiert das gefilterte Signal (FIL) [ZOLb]

Das Artefaktsignal im EKG ist mit ca. 100 min^{-1} vergleichsweise regelmäßig und somit leichter zu entfernen. Das während der Herzdruckmassage gemessene Beschleunigungssignal kann anschließend gut dazu verwendet werden, die Zeitpunkte der Artefakte zu bestimmen. Es ist anzumerken, dass die See-Thru CPR lediglich für die Anzeige genutzt wird – nicht aber für eine automatische EKG-Analyse während der Herzdruckmassage.

5.3.3 Zeit- und frequenzselektive Artefaktreduktion

Die Artefaktreduktion mit Hilfe eines Bandpasses führt üblicherweise zu unbefriedigenden Ergebnissen, da entweder die Störungen noch immer im EKG-Signal enthalten sind oder die EKG-Morphologie so stark gestört ist, dass eine

weitere Analyse nicht mehr sinnvoll durchgeführt werden kann. Um diese Probleme zu verhindern, ist eine gezielte Filterung der artefaktbehafteten Sequenzen notwendig – idealerweise, ohne dabei das EKG an sich zu beeinträchtigen. Mit Hilfe der Elektroden-Haut-Impedanz als artefaktkorrelierendes Signal ist dies möglich. Der hier beschriebene Ansatz bezieht sich auf [Kir11].

Ein verbreiteter Ansatz zur Artefaktentfernung mit Hilfe der diskreten Wavelet-Transformation (DWT) beinhaltet die folgenden Schritte [Sör05]:

1. Berechnung der DWT des Signals
2. Nullsetzen oder Modifizierung von Wavelet-Koeffizienten gemäß bestimmter Regeln
3. Rekonstruktion des Signals anhand der modifizierten Koeffizienten

Der zweite Schritt, das Nullsetzen bestimmter Signalbereiche, ist der interessante Teil dieses Ansatzes: Mit Hilfe der Elektroden-Haut-Impedanz lassen sich genau die Signalteile identifizieren, die gestört sind und somit modifiziert – also auf Null gesetzt – werden müssen.

Algorithmus

Abbildung 5.14 zeigt einen Überblick über den Algorithmus zur Artefaktreduktion, der sich in folgende Schritte unterteilen lässt: Die Summe der Elektroden-Haut-Impedanz beider Trockenelektroden wird ebenso wie das EKG einer Wavelet-Transformation mit vier Levels unterzogen. Alle Samples des transformierten Impedanzsignals werden in allen vier Levels mit einem Schwellwert verglichen. Wird dieser Schwellwert überschritten, werden die korrespondierenden Samples in der Wavelet-Transformierten des EKG auf Null gesetzt. Die auf Null gesetzten Sequenzen im EKG werden zusätzlich um ± 1 Sample vergrößert. Anschließend wird das gefilterte EKG-Signal mit der inversen DWT aus den modifizierten Levels rekonstruiert.

Das Nullsetzen einzelner Levels und die anschließende Signalrekonstruktion wird gerne verwendet, um nieder- oder hochfrequente Störungen aus einem Signal zu entfernen. Durch diese Maßnahme werden alle Schwingungsformen in einem bestimmten Frequenzband entfernt. In dem hier beschriebenen Algorithmus wird jedoch nicht ein ganzes Level, sondern es werden nur einzelne Werte oder Sequenzen auf Null gesetzt. Auf diese Weise wird eine frequenz- und zeitselektive Filterung erreicht.

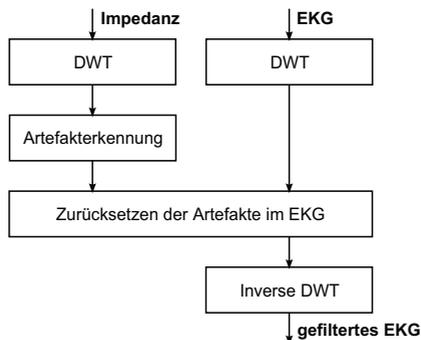


Abbildung 5.14: Der Algorithmus nutzt die DWT der Elektrode-Haut-Impedanz für die selektive Artefaktreduktion

Das Ergebnis wird dabei durch zwei Parameter maßgeblich beeinflusst: Der Schwellwert für die Artefakterkennung in der Wavelet-Transformierten des Impedanzsignals und eine zusätzliche Reduktion der Grundlinienschwankungen im EKG durch die Entfernung höherer Level in der DWT des EKG. Ohne diese zusätzliche Reduktion der Grundlinienschwankungen sind die Deformationen im gefilterten EKG minimal und beschränken sich nur auf die Stellen, die artefaktbehaftet sind (s. Abb. 5.15). Der Schwellwert wurde für die folgenden Betrachtungen auf den empirisch ermittelten Wert 2500 gesetzt. Wird die Reduktion der Grundlinienschwankung über die DWT aktiviert, verbessern sich zwar die Ergebnisse für die QRS-Detektion, das EKG ist aber aufgrund der starken Deformationen nicht mehr für die visuelle Befundung nutzbar. Dieser direkte Vergleich wird in Abbildung 5.16 gezeigt: Zwischen dem ungefilterten EKG (links) und dem gefilterten Signal (Mitte) ist kein Unterschied auszumachen. Wird zusätzlich die Reduktion der Grundlinienschwankung durch Nullsetzen der höheren Level in der DWT genutzt, sieht man deutliche Deformationen. Die auf diese Weise künstlich herbeigeführten EKG-Veränderungen könnten mit einer ascendierenden ST-Strecken-Senkung verwechselt werden. Dies ist zwar keine alarmierende Pathologie, kann jedoch ein Hinweis auf eine Reizleitungsstörung im Herzen sein. Hieraus wird deutlich, wie sensibel mit der Artefaktreduktion umgegangen werden muss, um Fehlinterpretationen bei einer anschließenden visuellen Befundung zu vermeiden.

Eine Veränderung des Schwellwertes verschiebt die Erkennungsrate für falsch-positive und falsch-negative QRS-Komplexe und somit die Sensitivität und positive Prädiktivität der nachfolgenden QRS-Erkennung (s. Abb. 5.17). Ein niedriger Schwellwert vermindert die Erkennung von falsch-positiven QRS-Komplexen, gleichzeitig werden aber sehr viele tatsächliche QRS-Komplexe übersehen. Ein höherer Schwellwert verhindert eher FN-Detektionen als FP-Detektionen.

Ergebnisse

Zur Validierung des vorangehend beschriebenen Algorithmus wurde die Verbesserung der automatischen QRS-Detektion herangezogen. Die QRS-Detektion ist der wichtigste Schritt in der automatischen EKG-Analyse, da viele weitere Analysen darauf aufbauen. Aufgrund dessen ist sie auch eine geeignete Metrik zur Quantifizierung von Artefaktreduktionsalgorithmen. In diesem Fall wurde auf den OSEA Algorithmus zurückgegriffen. Als Datenbasis dienen 14 annotierte Aufnahmen aus der ITIV_KFA-Datenbank.

In Abbildung 5.18 ist der Validierungsprozess gezeigt. Sowohl das gefilterte als auch das ungefilterte EKG werden der automatischen QRS-Erkennung un-

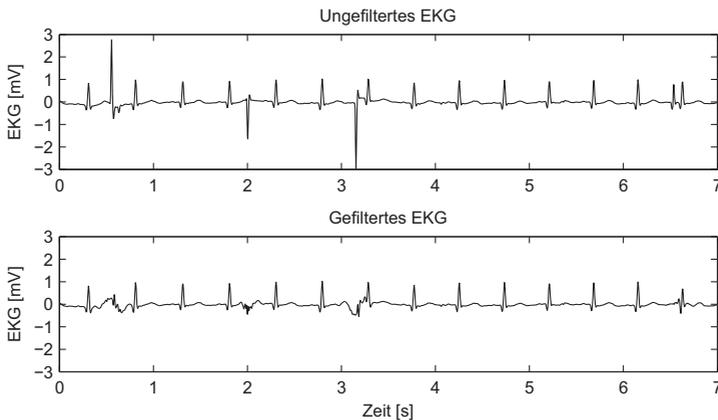


Abbildung 5.15: Durch die selektive Artefaktreduktion ist die Deformation des gefilterten EKG minimal



Abbildung 5.16: Die integrierte Reduktion der Grundlinienschwankungen verbessert zwar die automatische QRS-Erkennung, deformiert das gefilterte Signal aber stark

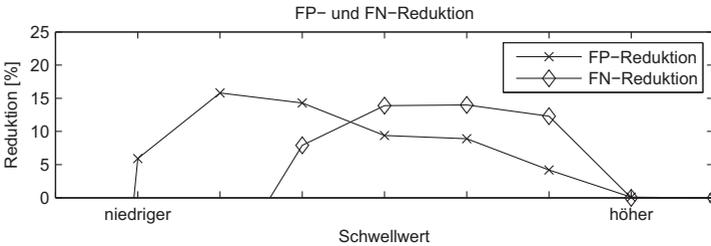


Abbildung 5.17: Eine Veränderung des Schwellwerts im Parameter-Set I verschiebt die Anzahl der FN- und FP-Detektion

terzogen. Die Ergebnisse werden mit Hilfe eines Beat-by-Beat-Vergleichs (BxB) mit der Referenzannotation verglichen, die Fensterbreite beträgt dabei 150 ms. So lässt sich die Sensitivität und positive Prädiktivität der QRS-Erkennung mit und ohne Artefaktreduktion berechnen. Als Ergebnis erhält man neben der direkten Verbesserung von Se und pP auch die Reduktion der falsch-positiven und falsch-negativen QRS-Erkennungen. Abhängig von den Einstellungen des Algorithmus konnte die Falscherkennungsrate um 10–35 % gesenkt werden. Sowohl Sensitivität als auch positive Prädiktivität konnten auf über 99 % gesteigert werden.

In Tabelle 5.4 sind die Ergebnisse der QRS-Detektion gezeigt. Die erste Reihe enthält die Ergebnisse ohne Artefaktreduktion. Das Filter mit dem Parameter-Set I reduziert die Falscherkennungen um ca. 11 %. Es ist dabei so eingestellt, dass die Deformationen im EKG minimal sind (s. Abb. 5.15). Das Parameter-Set

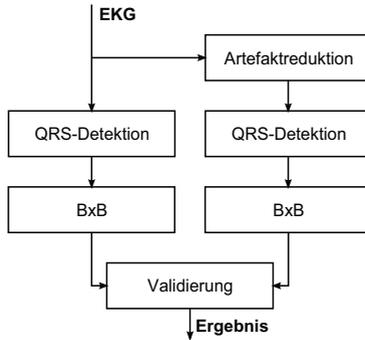


Abbildung 5.18: Die Validierung des Algorithmus erfolgt mit Hilfe des OSEA QRS-Erkenner und einem Beat-by-Beat-Vergleich (BxB)

II beinhaltet zusätzlich eine Reduktion der Grundlinienschwankungen durch Nullsetzen der hohen Level der Wavelet-Transformierten. Damit steigt die Reduktion der Falschdetektion auf etwa 35 % – allerdings ist das gefilterte Signal so stark deformiert, dass es im Anschluss nicht mehr für morphologische EKG-Befundungen genutzt werden kann.

Tabelle 5.4: Verbesserung der automatischen QRS-Erkennung durch verschiedene Methoden zur Artefaktreduktion

Algorithmus	#TP	#FP	#FN	Se [%]	pP [%]
ohne Artefakterkennung	98975	1457	1129	98,87	98,55
Parameter-Set I	99125	1325	979	99,02	98,68
Parameter-Set II	99300	888	804	99,20	99,11
Butterworth-Hochpass	99042	1367	1062	98,94	98,64
DWT Baseline Wander Removal	99043	1073	1061	98,94	98,93

Um die Güte der Artefaktreduktion besser einschätzen zu können, wurden dieselben Signale mit anderen Methoden gefiltert. Mit einem IIR-Hochpass 5. Ordnung mit Butterworth-Struktur und einer Grenzfrequenz von 5 Hz wurde eine Reduktion der Falschdetektionen um ca. 6 % erreicht. Wenn die DWT nur für die Verringerung der Grundlinienschwankungen (DWT Baseline Wander Removal) verwendet wird, kann immerhin eine Verbesserung um ca. 18 % er-

reicht werden. In beiden Fällen ist jedoch die Deformation des EKG-Signals enorm, sodass es nicht mehr für morphologische Befundungen genutzt werden kann.

Diese Verminderung der Anzahl der Fehldetektionen ist in Tabelle 5.5 gezeigt. Die Reduktion der Grundlinienschwankungen durch die DWT führt zu einer auffallend starken Reduktion der falsch-positiven Detektionen. Das gemäßigte Parameter-Set I reduziert hingegen FP- und FN-Detektionen gleichermaßen.

Tabelle 5.5: Das gefilterte EKG führt zu einer Verringerung der Fehldetektionen bei der QRS-Erkennung

Algorithmus	Gesamt [%]	FP [%]	FN [%]
Parameter-Set I	10,9	10,0	13,3
Parameter-Set II	34,6	64,1	28,8
Butterworth-Hochpass	6,1	6,6	5,9
DWT Baseline Wander Removal	17,5	35,8	6,0

Die Verbesserung der QRS-Erkennung mit dem Parameter-Set II ist zur weiteren Veranschaulichung in Abbildung 5.19 als Box-Plot aufgetragen. Bei der Sensitivität gibt es nur eine leichte Verbesserungen ($p = 0,1$) bei einer deutlich geringeren Standardabweichung nach der Filterung. Aufgrund der vielen wegfallenden falsch-positiven Detektionen ist die Verbesserung der positiven Prädiktivität hingegen sehr auffällig ($p = 0,003$). Die von sich aus soliden Ergebnisse der QRS-Detektion werden durch die Filterung geschärft und die Standardabweichung nimmt ab. Durch die hohe Reduktion von FP-Erkennungen wird der Arzt in seiner Arbeit unterstützt, da bei weniger vermeintlichen Rhythmusstörungen das EKG näher begutachtet werden muss.

Diese Methode zur Artefaktreduktion hat zwei entscheidende Vorteile: Da das artefaktkorrelierte Kontextsignal der Indikator für die Filterung ist, ist der Algorithmus unabhängig von der EKG-Morphologie. Ein pathologisches EKG mit vielen deformierten QRS-Komplexen beeinflusst also nicht die Filterung. Des Weiteren wird durch die frequenz- und zeitselektive Filterung auf Basis der DWT das Signal lediglich in den Bereichen verändert, in denen Artefakte vermutet werden. Große Signaleile bleiben also unverändert, die Filterung konzentriert sich auf die gestörten Teile.

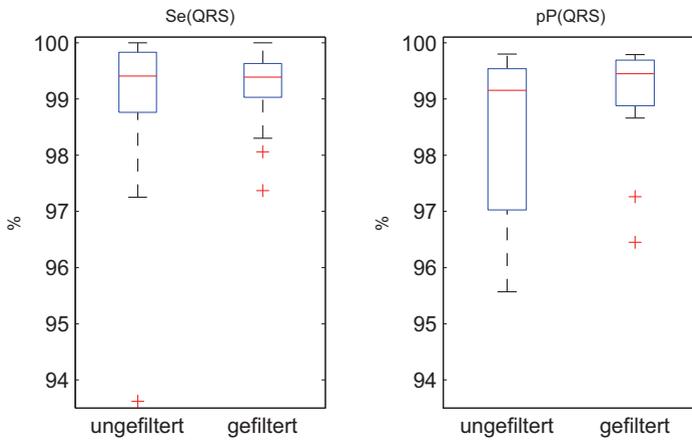


Abbildung 5.19: Die Boxplots zeigen eine signifikante Verbesserung von Sensitivität und positiver Prädiktivität nach der Artefaktreduktion (Parameter-Set II)

6 Kontextsensitive Signalanalyse

Liegen neben dem Ergebnis der EKG-Analyse auch Informationen über den Aktivitätsverlauf des Patienten vor, ist dies von zusätzlichem Nutzen für den Arzt. In diesem Kapitel wird beschrieben, wie ein einfaches, aber effizientes, Aktivitätsmonitoring aufgebaut werden kann und inwiefern diese Kontextinformation der EKG-Analyse zugutekommt.

6.1 Aktivitätsmonitoring

Aus den aufgezeichneten Beschleunigungssignalen lassen sich Informationen über das aktuelle Aktivitätsprofil des Patienten gewinnen. Damit erhält man ein weiteres Kontextsignal, das man für die automatische EKG-Analyse nutzen kann. Dieses Kapitel basiert auf den in [Kir10a, Kir10b] veröffentlichten Aussagen.

6.1.1 Ziele des Aktivitätsmonitoring

Die Informationen, die sich mit Hilfe eines Beschleunigungssensors gewinnen lassen, sind vielfältig. Die folgende Liste zeigt, welche Bewegungen oder Aktivitäten für die automatische EKG-Interpretation genutzt werden können und welchen Vorteil sie jeweils mit sich bringen:

- Änderungen der Herzfrequenz können als angemessen (z. B. während gesteigerter Aktivität) oder als unangemessen (z. B. Sinustachykardie in einer Ruhephase) beurteilt werden.
- Auftretende Arrhythmien können ggf. als belastungsinduziert markiert werden.
- Lebensbedrohliche Notfallsituationen wie ein ventrikuläres Flimmern können zuverlässiger erkannt werden, da die auftretende Bewusstlosigkeit zusätzlich als fehlende Bewegung detektierbar ist.

- Es lassen sich Hinweise auf die kardiale Belastbarkeit des Patienten ableiten.
- Stürze können detektiert und so auf mögliche kardiale Ursachen untersucht werden (z.B. kardiale Synkopen).
- Durch plötzliches Aufstehen hervorgerufene Rhythmusstörungen können leichter identifiziert werden.

Alle notwendigen Aktivitätsinformationen lassen sich mit Hilfe eines dreiachsigen Beschleunigungssensors ermitteln, der am Oberkörper getragen wird. Da das EKG ebenfalls am Oberkörper abgeleitet wird, lässt sich der Sensor in das Aufnahmesystem integrieren. Damit ist diese Sensorposition anderen denkbaren Positionen, wie z. B. Hüfte, Handgelenk oder Knöchel, vorzuziehen. Mit den aufgezeichneten Daten lassen sich Aktivitätsklassen, Aktivitätslevel oder der Energieumsatz des Patienten relativ genau bestimmen [Jat07a]. Integriert man zusätzlich einen barometrischen Höhensensor, verbessert sich diese Abschätzung, da sich anstrengende Bewegungen leichter erkennen lassen, bei denen Höhe zurückgelegt wird, wie etwa beim Treppensteigen.

Neben dem Aktivitätsmonitoring können die Beschleunigungsdaten auch zur Sturzdetektion genutzt werden. Anders als bei den in diesem Kapitel beschriebenen Aktivitätsklassen handelt es sich hierbei nicht um einen Zustand, sondern um ein für sich stehendes Ereignis. In den Arbeiten [Nou07, Yu08] sind verschiedene Ansätze zur Accelerometer-basierten Falldetektion beschrieben. Die Daten eines dreiachsigen Gyroskops können die Falldetektion präzisieren, aufgrund der verhältnismäßig hohen Stromaufnahme dieser aktiven Bauelemente sind sie für Langzeitanwendungen jedoch weniger geeignet [Leu11] und werden deshalb in der vorliegenden Arbeit nicht weiter berücksichtigt.

Auch das Aufstehen bzw. Aufrichten ist ein Event, das sich auf diese Weise erfassen lässt. Mit dem Aufstehen sinkt die Vorlast des Herzens schlagartig ab und das Herz muss mit seinem Autoregulationsmechanismus schnell darauf reagieren. Wird das Aufstehen markiert, lassen sich Unregelmäßigkeiten bei dieser Autoregulation leichter erkennen.

6.1.2 Ruheerkennung

Der korrekten Erkennung von körperlicher Ruhe wird in dieser Arbeit ein hoher Stellenwert zugeordnet. Wenn körperliche Ruhe als notwendiges Kriterium für die Erkennung von defibrillationspflichtigen Rhythmusstörungen herangezogen

wird, muss diese mit einer sehr hohen Sensitivität erkannt werden, um die Sensitivität der VT/VF-Erkennung nicht negativ zu beeinflussen (s. Kap. 6.2.2). Dabei darf auch eine passive Bewegung des Patienten, beispielsweise durch eine Autofahrt oder öffentliche Verkehrsmittel, die Ruherkennung nicht negativ beeinflussen.

Auswahl geeigneter Features

Für die sichere Unterscheidung zwischen aktiver und passiver Bewegung bzw. körperlicher Ruhe sollen die Informationen eines am Oberkörper getragenen Bewegungssensors genügen. Aus diesem dreiachsigen Beschleunigungssignal lassen sich charakteristische Features über einem festgelegten Zeitraum berechnen. Dieser Zeitraum muss so gewählt werden, dass er lang genug ist, um die statistischen Merkmale der Bewegung zu enthalten, aber gleichzeitig so kurz ist, dass das Klassifikationsergebnis zeitnah vorliegt. Eine Buffer-Größe von 80 Samples bei einer Abtastfrequenz von 50 Hz hat sich in Voruntersuchungen als guter Kompromiss herausgestellt. Um die Verzögerung zwischen Eingangssignal und Ergebnis weiter zu verkürzen, können die Zeitspannen überlappen. Durch die hier gewählte hohe Überlappung von 75 % liegt alle 0,4 s ein Ergebnis vor, welches maximal 2 s zurück liegt.

Als Merkmale werden Energie- und Amplitudeneigenschaften der drei Achsen innerhalb der Zeitspanne $n = 80$ betrachtet, die Achsenausrichtung ergibt sich aus Abbildung 4.3 auf Seite 62. Aus den jeweiligen Abtastwerten a_d lässt sich die maximale Amplitude A der einzelnen Achsen $d = \{x, y, z\}$ innerhalb des Zeitbereichs berechnen:

$$A_d = |\max(a_{di})_{i=0}^n - \min(a_{di})_{i=0}^n| \quad (6.1)$$

Ein weiteres Merkmal bildet die Signalenergie E des betrachteten Zeitraums:

$$E_d = \sum_{i=1}^n a_{di}^2 \quad (6.2)$$

Dabei bleibt anzumerken, dass die Beschleunigungsdaten immer mit der Erdbeschleunigung von 1 g überlagert sind. Um dem entgegenzuwirken, kann man den Mittelwert des Signals abziehen, womit ein weiteres Merkmalset

vorliegt:

$$E_d^* = \sum_{i=1}^n (a_d - \bar{a}_{di})^2 \quad \text{mit} \quad \bar{a}_d = \frac{1}{n} \cdot \sum_{i=1}^n a_{di} \quad (6.3)$$

Die Untersuchungen aus [Jat10, Dha07] zeigen, dass die Verfahren ANFIS (Adaptive Network-based Fuzzy Inference System) und CART (Classification and Regression Tree) die besten Ergebnisse für die Erkennung körperlicher Ruhe liefern. Mit diesem Vorwissen fiel aufgrund des geringen Ressourcenanspruchs eines Entscheidungsbaums der Entschluss, die abschließende Ruheerkennung auf Basis des CART zu implementieren.

Nach einer Feature-Reduktion erwiesen sich die Features A_x , A_z , E_x , E_z und E_x^* als am aussagekräftigsten. Mit Hilfe dieser aus einem Trainingsdatenkollektiv extrahierten Merkmale kann mit Matlab ein Entscheidungsbaum generiert werden (s. Abb. 6.1), der wiederum die Basis für die endgültige Implementierung in C++ bildet. Eine Validierung des Entscheidungsbaums erfolgt auf Basis eines getrennten Validierungskollektivs.

Implementierung

Die Ruheerkennung wurde in C++ implementiert. Die Berechnungen wurden dabei so angepasst, dass sie auf einem 16 bit Mikrocontroller lauffähig sind, ohne dass es zu Überläufen kommt. Die objektorientierte Struktur ist in Abbildung 6.2 dargestellt. Der online-fähige Algorithmus muss einmal mit dem Entscheidungsbaum und der Länge des Betrachtungszeitraums initialisiert werden, anschließend erhält er die Beschleunigungsdaten Sample für Sample. Durch die integrierten Ringspeicher hat er stets Zugriff auf die benötigte Datenhistorie zur Feature-Berechnung. Bei der verwendeten Länge von 80 Samples kann alle 20 Samples ein neues Ergebnis abgerufen werden.

Ergebnisse

Für die Validierung des Algorithmus wurden Messdaten aus der ITIV_KFA-Datenbank und der Holtervergleich-Datenbank herangezogen. Da sich beide Systeme bezüglich ihrer Sensoranordnung unterscheiden, wurde eine Achsentransformation so durchgeführt, dass Ausrichtung und Amplitude der drei

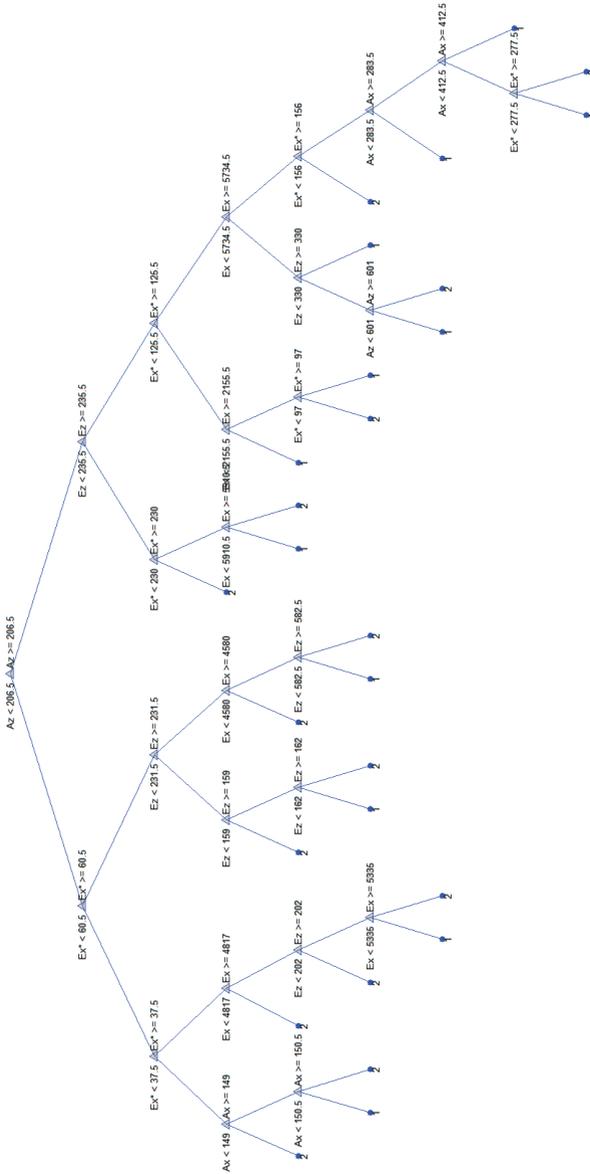


Abbildung 6.1: Mit Matlab generierter Entscheidungsbaum für die automatische Ruheerkennung

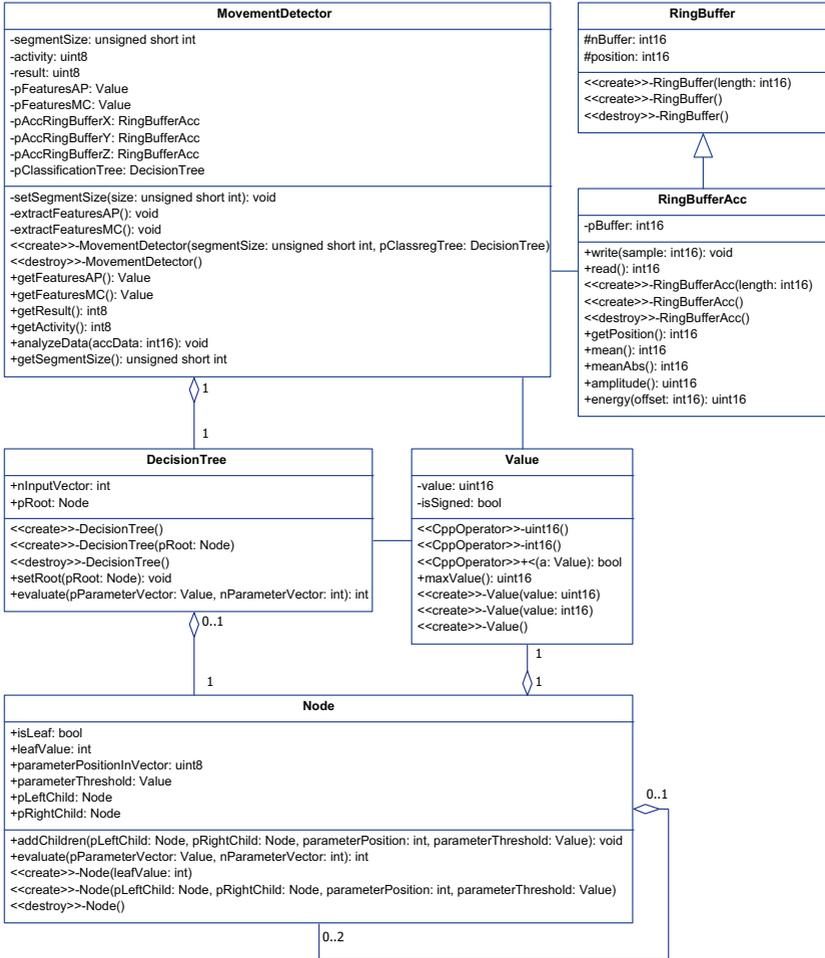


Abbildung 6.2: Klassendiagramm der Ruheerkennung

Achsen wieder vergleichbar werden. Aus den oben genannten Datenbanken wurden insgesamt 161 Datensätze mit einer Länge von je einer Minute erzeugt, die jeweils nur eine Aktivitätsklasse enthalten. Aus diesem Kollektiv wurde aus jeder Aktivitätsklasse jeder zweite Datensatz einem Trainingskollektiv zugeführt, während die übrigen das Testkollektiv bilden. Damit liegen 82 Trainings- und 79 Testdatensätze vor. Die Datensätze teilen sich wie folgt auf:

34 Datensätze *Liegen* mit Liegen in Bauch- und Rückenlage sowie Liegen in der Straßenbahn (Ruhe).

69 Datensätze *Sitzen und Stehen* mit Sitzen und Stehen in Straßenbahn, Bus und Auto, teilweise mit und gegen die Fahrtrichtung (Ruhe).

39 Datensätze *mittlerer Aktivität* mit langsamem und normalem Gehen, Hinken und langsamem Fahrradfahren (Aktivität).

19 Datensätze *hoher Aktivität* mit Joggen, schnellem Fahrradfahren, schnellem Gehen und Treppensteigen (Aktivität).

Betrachtet man das Ergebnis der Ruheerkennung gemittelt über einen Zeitraum von einer Minute, erhält man auf dem Validierungskollektiv eine hundertprozentige Unterscheidung zwischen körperlicher Ruhe und körperlicher Aktivität (s. Tab. 6.1). Für die allgemeine Erkennung von Ruhephasen stellt ein solch langer Zeitraum kein Hindernis dar – nutzt man die Ruheerkennung jedoch als notwendiges Kriterium für eine Defibrillation, ist dieser Zeitraum zu lang. Ein Zurückgreifen auf die Ergebnisse, die der Algorithmus alle 0,4 s berechnet, liefert die Ergebnisse in Tabelle 6.2. Aufgrund der etwas schlechteren Performanz bei einem kurzen Betrachtungsintervall, muss für eine sichere VT/VF-Entscheidung der Verlauf der Aktivität mit berücksichtigt werden (s. Kap. 6.2.2).

Tabelle 6.1: Ruheerkennung der 79 Testdatensätze, gemittelt über eine Minute

	Ruhe	Aktivität
Ruhe erkannt	51	0
Aktivität erkannt	0	28

Den kritischsten Zustand stellt das Autofahren dar, hier wurden bis zu 20 % der Samples falsch klassifiziert. Insbesondere das Fahren auf schlechten Straßen führt zu Beschleunigungen, die in Frequenz und Amplitude physiologischen Bewegungen ähneln können. Die übrigen Testdatensätze sind fast alle fehlerfrei.

Tabelle 6.2: Ruheerkennung der 79 Testdatensätze

	Ruhe	Aktivität
Ruhe erkannt	7363	77
Aktivität erkannt	83	4011
Sensitivität [%]	98,9	98,1
Spezifität [%]	99,0	98,0

6.1.3 Aktivitätserkennung

Die Unterscheidung zwischen körperlicher Ruhe und Aktivität ist das wichtigste Ergebnis einer Aktivitätserkennung. Mit einer weiteren Unterteilung in die folgenden vier Aktivitätsklassen liegen für die meisten Anwendungsfälle alle benötigten Informationen vor:

1. keine Aktivität (Liegen)
2. geringe Aktivität (Sitzen, Stehen)
3. mittlere Aktivität (Gehen)
4. hohe Aktivität (Laufen, Rennen)

Obwohl dieser Ansatz deutlich primitiver als eine vollständige Bewegungsanalyse ist, bei der oft 5–10 verschiedene Aktivitäten unterschieden werden [Jat10, Fis10], ist der Informationsgehalt enorm. In Abbildung 6.3 ist der konkrete Nutzen der einzelnen Aktivitätsklassen dargestellt.



Abbildung 6.3: Nutzen des Aktivitätsmonitorings für die EKG-Analyse

Die Bewegungskategorie *keine Aktivität* kann dazu genutzt werden, Ruhephasen wie z. B. Schlafen zu erkennen. Gemeinsam mit der Klasse *geringe Aktivität* ist

sie eine notwendige Bedingung, um lebensgefährliche, defibrillationspflichtige Rhythmusstörungen wie Kammerflimmern zu erkennen. Steigt die körperliche Aktivität, können vermehrt belastungsinduzierte Herzrhythmusstörungen wie Extrasystolen auftreten. Bei einer *hohen Aktivität* ist es zudem möglich, die Schwellen für erkannte Tachykardien nach oben zu verschieben, da hier ein Anstieg der Herzfrequenz physiologisch ist.

Eine mögliche Realisierung eines solchen vierstufigen Aktivitätsklassifikators ist in Abbildung 6.4 dargestellt. Die Berechnung der einzelnen Aktivitätslevel baut auf der zuvor beschriebenen Ruherkennung auf, sodass ebenfalls auf Abschnitten von 1,6 s Länge gearbeitet wird, die sich um 75 % überlappen. Die Validierung erfolgt auf den in Kapitel 6.1.2 genannten Daten.

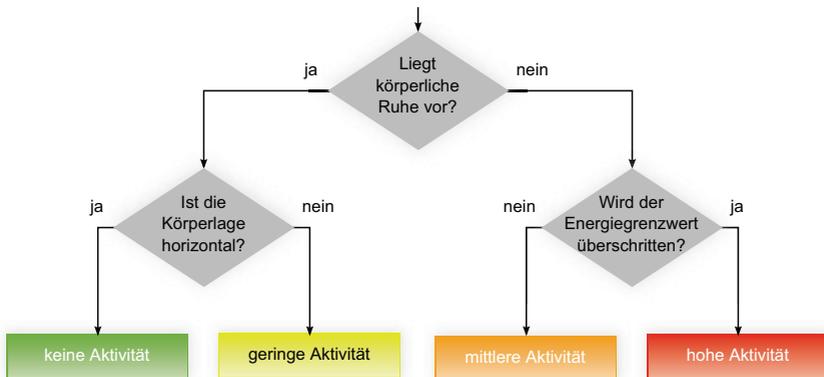


Abbildung 6.4: Aufbau eines Algorithmus zur vierstufigen Aktivitätsklassifikation auf Basis eines Beschleunigungssensors

Unterscheidung zwischen Aktivitätslevel 1 und 2

Wenn körperliche Ruhe vorliegt, wird lediglich zwischen horizontaler und aufrechter Körperlage unterschieden. Hierfür wird die Erdbeschleunigung als Indikator verwendet, deren vertikale 1 g-Komponente die Messung von jedem Beschleunigungssensor überlagert. Zur Berechnung wird die arithmetisch gemittelte Beschleunigung jeder Achse in einem Berechnungsintervall untersucht. Die Werte der x- und y-Achse werden geometrisch addiert, gemittelt und mit

dem Mittelwert der z-Achse (Hochachse) verglichen:

$$\sqrt{a_x^2 + a_y^2} > k \cdot \bar{a}_z \quad \text{mit } k = \tan(\alpha) \quad (6.4)$$

Ist die Ungleichung 6.4 erfüllt, liegt der Patient. Mit Hilfe der Konstanten k kann man einen Winkel einstellen, ab wann die Aktivität als Liegen gewertet werden soll. α entspricht dabei dem Winkel zwischen der Hochachse des Sensors und dem Lot. Als praktikabel hat sich ein Wert von $k = 2$ herausgestellt, was einem Winkel von etwa 63° entspricht. Damit wird ein Liegen mit leichter Oberkörperhochlage wie beispielsweise beim Lesen noch als Liegen gewertet, während entspanntes Sitzen in einem Sessel als aufrechte Körperhaltung gilt. Ein Winkel von 45° hat sich als verwirrend herausgestellt, da viele der Testpersonen nicht immer aufrecht saßen, und somit große Teile eines normalen Arbeitstages als Liegen klassifiziert wurden. Letztendlich ist die Unterscheidung zwischen Liegen und Sitzen jedoch stets subjektiv und wird im allgemeinen Sprachgebrauch zusätzlich durch die Position der Unterschenkel bestimmt, die für uns nicht messbar ist.

Aufgrund der geometrischen Mittelung der x- und y-Achse und des kurzen Analyseintervalls beeinflusst ein Verrutschen des Brustgurts, in dem der Beschleunigungssensor integriert ist, das Ergebnis nicht. Die Richtung der z-Achse ist durch das Hardwaredesign vorgegeben und kann durch den Patienten nicht verändert werden. Ein spiegelverkehrtes Anlegen des Brustgurtes kann durch die dauerhaft negative Beschleunigung in z-Richtung erkannt werden.

Ein typisches Signal für eine Lageänderung ist in Abbildung 6.5 zu sehen. Beim Wechsel zwischen Sitzen (0–4 s) und Liegen (7–10 s) ist ein kurzer Bereich, in dem eine mittlere körperliche Aktivität vorliegt. Die Abbildung zeigt deutlich, wie sich durch die Lageänderung die 1 g-Komponente der Erdbeschleunigung auf den Achsen des Beschleunigungssensors verschiebt.

Unterscheidung zwischen Aktivitätslevel 3 und 4

Für die Unterscheidung zwischen mittlerer und hoher Aktivität wird eine einfache Energieabschätzung aus dem Beschleunigungssignal, in der Literatur häufig

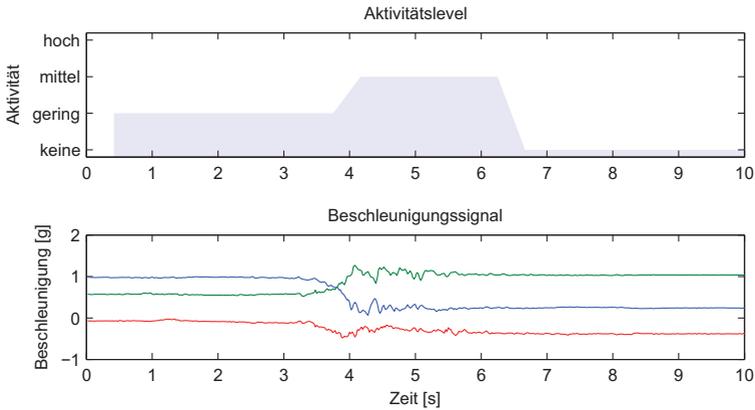


Abbildung 6.5: Bei Sekunde 4 ist der Wechsel zwischen Sitzen und Liegen deutlich im Beschleunigungssignal zu erkennen

abgekürzt mit EEAC, herangezogen:

$$EEAC = \frac{1}{n} \cdot \sum_{i=1}^n \sqrt{a_{x_i}^2 + a_{y_i}^2 + a_{z_i}^2} \quad (6.5)$$

Dafür wird der EEAC-Wert eines Betrachtungsintervalls ($n = 80$) berechnet und mit einem Schwellwert verglichen. Übersteigt der EEAC-Wert den Schwellwert, liegt eine hohe Aktivität vor (Aktivitätsklasse 4), anderenfalls eine mittlere Aktivität (Aktivitätsklasse 3). Der Schwellwert wurde auf Basis von Testaufnahmen empirisch ermittelt. Da das Empfinden zwischen mittlerer und hoher Aktivität sehr subjektiv ist, lässt sich rechnerisch kein allgemein gültiger Schwellwert ermitteln. Vielmehr ist der Schwellwert bzw. sind die beiden resultierenden Aktivitätsklassen 3 und 4 als Indikator für ‚mehr‘ oder ‚weniger‘ starke Aktivität zu sehen.

In Abbildung 6.6 ist das Beschleunigungssignal während eines Wechsels zwischen Aktivitätslevel 3 und 4 dargestellt. In diesem Beispiel handelt es sich um Treppensteigen. An jedem Treppenabsatz nimmt die Signalenergie ab, das Aktivitätslevel fällt dabei zurück auf 3.

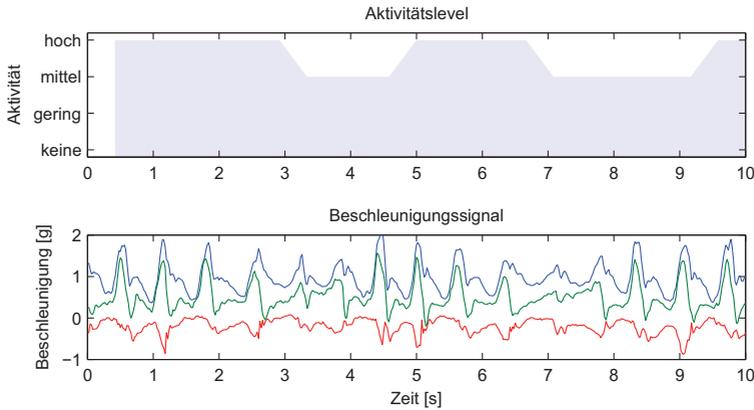


Abbildung 6.6: Beim Treppensteigen ändert sich die körperliche Aktivität mehrfach zwischen *mittel* und *hoch*

Da der EEAC-Wert die Signalenergie und nicht den Energieumsatz des Menschen widerspiegelt, kommt es bei einigen Bewegungen zu Fehlklassifikationen. Langsames Fahrradfahren auf einer schlechten Straße führt z. B. zu einer höheren Signalenergie als schnelles Radfahren auf gutem Straßenbelag. Ebenso ist die Signalenergie beim Treppeherablaufen oftmals höher als beim Treppensteigen. Diese Ungenauigkeit spiegelt sich auch in Tabelle 6.4 wider, wo alle Ergebnisse der Aktivitätsklassifizierung aufgelistet sind.

Da die wesentliche Information der Aktivitätsklassen 3 und 4 ist, dass gerade körperliche Aktivität verrichtet wird, lässt sich die teilweise fehlerhafte Unterscheidung zwischen Klasse 3 und 4 vertreten, da ja beide Klassen Indikatoren für Aktivität sind. Legt man beide Klassen mit der Argumentation zusammen, sie seien mit den vorhandenen Mitteln nicht präzise trennbar, geht die Information über die Signalenergie verloren. Alternativ kann man mit leistungsfähigeren Algorithmen und gegebenenfalls zusätzlichen Sensoren die Analyse verbessern, wie es beispielsweise in [Jat10, Fis10] gemacht wurde.

Ergebnisse

Mit Hilfe der 79 Testdatensätze wurde der Algorithmus automatisch validiert. Jeder einminütige Testdatensatz wird durch den Algorithmus in 150, sich um 75 % überlappende Sequenzen unterteilt, für die einzeln die Bewegungsklasse bestimmt wird. Die Ergebnisse der ersten drei Sequenzen von jedem Datensatz werden ignoriert, da der Ringspeicher des Algorithmus hier noch nicht vollständig gefüllt ist, sodass pro Datensatz 147 analysierte Sequenzen vorliegen.

Die Tabelle 6.3 zeigt die Ergebnisse der Validierung. Es ist sofort ersichtlich, dass die Anzahl der Fehldetektionen mit einem höheren Aktivitätslevel zunimmt. Der zuvor erwähnten Problematik bei der Unterscheidung mittlerer und hoher Aktivität nur über den EEAC-Wert wird hier Rechnung gezollt. Bei den Testdatensätzen wurde das Trepppeheruntergehen und einige Datensätze mit normalem Gehen als Klasse 4 anstatt 3 gewertet. Herabgestuft von 4 auf 3 wurden Datensätze mit schnellem Gehen, Joggen und Fahren auf dem Fahrrad-Ergometer.

Die Lageerkennung arbeitet hingegen sehr zuverlässig, allerdings werden einige Sequenzen der Ruhedatensätze als Bewegung erkannt und umgekehrt. Betrachtet man die entsprechenden Datensätze, kann man tatsächlich sehr kurze Bewegungen finden.

Tabelle 6.3: Aktivitätserkennung der 79 Testdatensätze

	keine	niedrige	mittlere	hohe
keine erkannt	2482	0	0	0
niedrige erkannt	0	4881	77	0
mittlere erkannt	0	83	2013	462
hohe erkannt	0	3	684	852
Sensitivität [%]	100	98,3	72,6	64,9
Spezifität [%]	100	98,4	78,7	55,6

Einen Signalabschnitt von etwa dreieinhalb Minuten zeigt Abbildung 6.7. In diesem Beispiel sind sehr schön verschiedene Bewegungsmuster zu erkennen, besonders eindrucksvoll ist das Treppensteigen im Bereich von 0:50 bis 1:20 min. Deutlich sichtbar sind hier die Treppen mit hoher Aktivität und den dazwischen liegenden Treppenabsätzen mit niedrigerer Aktivität. Das anschließende „gemütliche Sitzen auf dem Sofa“ wird hier – aufgrund der sehr horizontalen

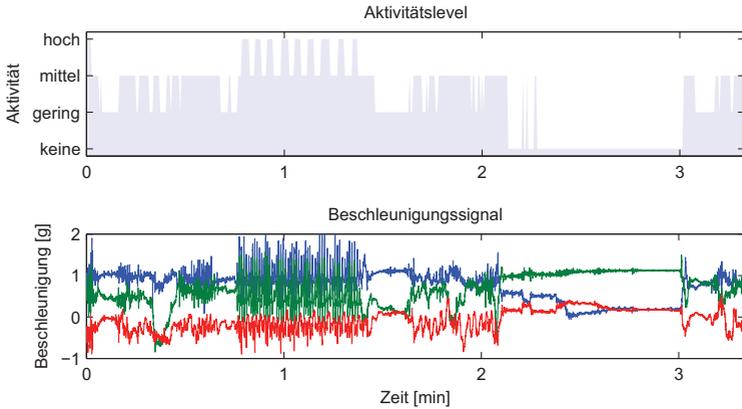


Abbildung 6.7: Aktivitätsdaten aus dem Alltag

Körperlage – als Liegen (keine Aktivität) gewertet (2:10 bis 3:10 min).

Betrachtet man einen 24 h-Datensatz, ist es nicht mehr sinnvoll, die Aktivität mehrfach pro Sekunde zu berechnen, sondern man ist eher an der durchschnittlichen Aktivität innerhalb eines Zeitraums, beispielsweise einer oder fünf Minuten interessiert. Die Vorteile dieser Betrachtungsweise sind, dass sich kleine Fehldetektionen durch die Mittelung aufheben und gleichzeitig der Aktivitätsverlauf über einen so langen Zeitraum überhaupt darstellbar ist. Mittelt man nun die Ergebnisse aller Sequenzen eines Testdatensatzes und trägt diese in einer Matrix auf, erhält man sehr viel überzeugendere Werte bezüglich der Trennung zwischen den niedrigen Aktivitätsleveln, bei den hohen Aktivitäten gibt es aber nach wie vor Fehlklassifikationen (s. Tab. 6.4).

Das geglättete Aktivitätslevel ist in Abbildung 6.8 gezeigt: Die blaue Linie entspricht den über eine Minute gemittelten Aktivitätsklassen, während die 0,4-sekündlichen Werte der Fläche im Hintergrund sichtbar mehr schwanken. Sehr kurze Aktivitäten wie das Aufsetzen lassen sich in diesem Maßstab gar nicht mehr darstellen und müssen bei Interesse gesondert markiert werden (s. Kap. 6.1.4).

Tabelle 6.4: Aktivitätserkennung der 79 Testdatensätze, gemittelt über eine Minute

	keine	niedrige	mittlere	hohe
keine erkannt	17	0	0	0
niedrige erkannt	0	34	0	0
mittlere erkannt	0	0	14	3
hohe erkannt	0	0	5	6

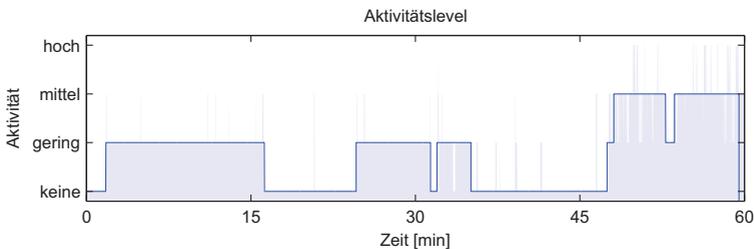


Abbildung 6.8: Bei der Betrachtung der Aktivitätsdaten eines längeren Zeitraums ist die Mittelung über eine Minute sinnvoll

6.1.4 Eventerkennung

Bei der Erkennung der körperlichen Aktivität handelt es sich um eine Zustandserkennung. Davon unterscheidet sich die Erkennung bestimmter Ereignisse, die vereinzelt oder regelmäßig auftreten können. Von medizinischer Bedeutung sind die Ereignisse *Sturz* und *Aufstehen*.

Erkennung von Stürzen

Die automatische Sturzerkennung mit Hilfe eines kleinen, tragbaren Sensors ist im Hausnotruf-Bereich weit verbreitet. Aber auch bei telemedizinischen Anwendungen ist sie eine interessante Ergänzung. Für die retrospektive Analyse von EKG-Daten kann die Sturzerkennung beim Auffinden von Synkopen behilflich sein. Aus diesem Grund soll im Rahmen dieser Arbeit eine einfache, auf Beschleunigungsdaten basierende Sturzerkennung implementiert werden.

Die Implementierung eines Sturzerkenners richtete sich zu weiten Teilen nach dem Stand der Technik [Ber09]. Mit Hilfe einer erstellten Matlab-Anwendung kann die nötige Referenz-Signatur an Hand von annotierten Beschleunigungsdaten trainiert werden (s. Abb. 6.9). Dabei werden die im Unisens-Format vor-

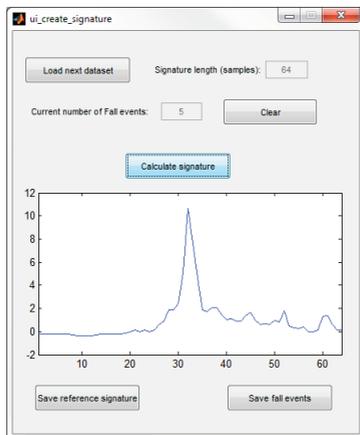


Abbildung 6.9: Benutzeroberfläche für die automatische Generierung der Referenz-Signatur für die Sturzdetektion

liegenden Trainingsdatensätze in der Sekunde um einen annotierten Sturz automatisch eingelesen und daraus die benötigte Referenz-Signatur berechnet.

Für Training und Validierung der Sturzerkennung lagen nur zwei Datensätze mit jeweils fünf Stürzen vor. aufgrund des kleinen Datenkollektivs lassen sich keine endgültigen Aussagen über die Güte des Algorithmus treffen. Um den Algorithmus dennoch zu validieren, wurde wechselseitig ein Datensatz für die Erstellung der Referenzsignatur und der andere für eine Validierung genutzt. Mit dieser Methode konnte eine Sensitivität von 100 % und eine positive Prädiktivität von 55,6 % festgestellt werden. Bei den falsch-positiven Stürzen handelt es sich um Hüpfen und schnelles Treppelaufen.

Die positive Prädiktivität lässt sich verbessern, wenn man als weiteren Parameter die Aktivitätsklassifizierung berücksichtigt. Mit der Bedingung, dass in einem bestimmten Zeitfenster nach einem Sturz für kurze Zeit körperliche Ruhe vorliegen muss, kann eine positive Prädiktivität von 100 % bei einer Sensitivität von 80 % erreicht werden. Die Länge des empirisch ermittelten Zeitfensters

beträgt 3 s. Diese zusätzliche Bedingung ist besonders für das Auffinden von zu einem Sturz führenden kardialen Synkopen interessant: Aufgrund des schwachen Kreislaufs ist die gestürzte Person nicht in der Lage, unmittelbar nach dem Ereignis wieder schnell aufzustehen.

Die Ergebnisse werden in Abbildung 6.10 veranschaulicht: Während die reine Sturzerkennung auch vereinzelt Ereignisse wie schnelles Treppenlaufen oder Springen markiert, kann dies durch Hinzunahme der Ruheerkennung verhindert werden.

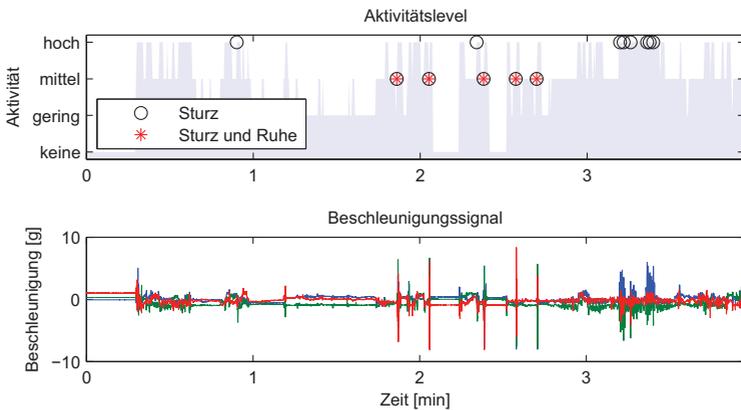


Abbildung 6.10: Kombiniert man die Sturzerkennung mit der Ruheerkennung, lässt sich die Erkennungsgüte steigern, hier werden ausschließlich die fünf Stürze zwischen 1,8 s und 2,8 s detektiert

Erkennung von Aufstehen bzw. Aufrichten

Neben der automatischen Erkennung von Stürzen ist auch das Erkennen des Wechsels von der horizontalen in die vertikale Körperlage von Bedeutung. Durch die Verlagerung von ca. 500 ml Blut in die unteren Extremitäten sinkt die Vorlast des Herzens plötzlich ab. Die Folge ist ein reflektorischer Anstieg der Herzfrequenz innerhalb von wenigen Sekunden. Solche Regulationsmechanismen werden in der Klinik bei sogenannten Kipptisch-Untersuchungen, bei denen der Patient schnell aus der Horizontalen in die Vertikale gebracht wird, provoziert [Beh10].

Die Erkennung des Aufstehens wird nicht direkt aus den Beschleunigungsdaten berechnet, sondern nimmt die Ergebnisse einer Körperlage-Erkennung als Basis. Die Körperlage wird wie bei der Unterscheidung zwischen Aktivitätslevel 1 und 2 über die Formel 6.4 bestimmt. Um ein häufiges Hin-und-her-Wechseln zwischen beiden Positionen zu verringern, wird eine Hysterese eingeführt. Befindet man sich in aufrechter Position und legt sich hin, wird der Faktor $k = 2$ eingesetzt, was einem Winkel von ca. 63° zum Lot entspricht. Für den Wechsel von horizontaler zu aufrechter Körperlage wird $k = 0,5$ gesetzt, damit muss ein Winkel von ca. 27° unterschritten werden. Durch diese geschickte Wahl von k ist die Realisierung des Algorithmus – insbesondere für mobile Systeme – besonders effizient, da auf Bitshift-Operationen zurückgegriffen werden kann.

Der in Abbildung 6.11 gezeigte Algorithmus betrachtet die letzten zehn Sekunden der Körperlage: Wird dieser Zeitraum uneingeschränkt als Liegen bewertet und erfolgt anschließend ein Wechsel in die Vertikale, der länger als 0,8 s anhält, so wurde ein Aufstehen erkannt.

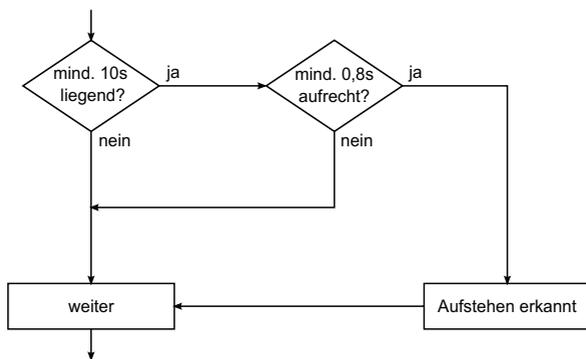


Abbildung 6.11: Die Erkennung des Aufstehens basiert auf den Ergebnissen der Aktivitätserkennung der letzten Sekunden

Die Größe der Zeitbereiche und der Thresholds wurde empirisch bestimmt. Dabei geht es maßgeblich darum, dass eine Bewegung im Liegen nicht als Aufstehen gewertet wird und dass man vor dem Aufstehen eine gewisse Zeit lang lag.

Zur Validierung des Algorithmus wurden aus den ITIV-KFA-Datensätzen jeweils die ersten zwölf Minuten als Testdatensatz verwendet. Jeder dieser 13 Datensätze enthält etwa zu gleichen Teilen die Aktivitäten Liegen, Sitzen,

Stehen und Gehen. Bei allen Datensätzen wird das Aufstehen korrekt erkannt. Abbildung 6.12 zeigt das Ergebnis an einem Datensatz, die magentafarbene Linie markiert dabei das Aufstehen.

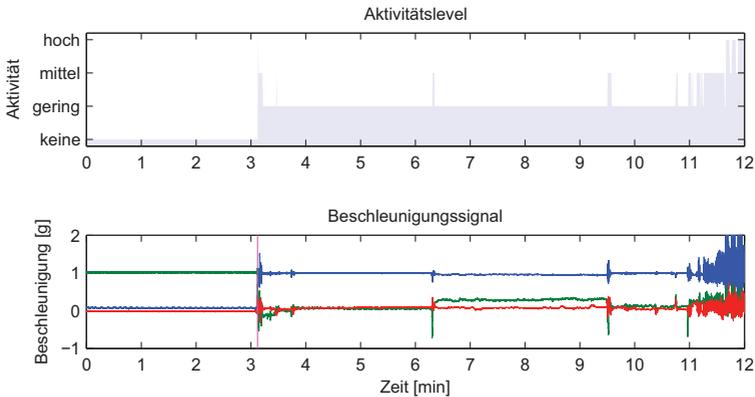


Abbildung 6.12: Die magentafarbene Linie bei 3,1 s markiert das automatisch erkannte Aufstehen

6.2 EKG-Analyse

Bei der klassischen automatisierten EKG-Analyse wird allein das EKG mit einem oder mehreren Kanälen betrachtet. Dies betrifft sowohl die Schlag- und Rhythmusanalyse als auch die Erkennung von Artefakten. Sind aber Kontextsignale vorhanden, können diese direkt in die automatische EKG-Analyse einfließen und damit die Qualität verbessern.

Eine verlässliche EKG-Analyse hängt im Wesentlichen von den verwendeten Analyse-Algorithmen und der Qualität der vorliegenden Signale ab (s. Abb. 6.13). Kann man die Signalqualität aufgrund von Randbedingungen, wie z. B. textiler Integration, Hardware-Design oder langzeitstauriger Elektroden, nicht mehr technisch verbessern, ist es möglich, das Wissen über die Signalqualität in die Analyse-Algorithmen einzubringen.



Abbildung 6.13: Bedingungen für verlässliche Ergebnisse der EKG-Analyse

6.2.1 Artefaktinformationen für die QRS-Erkennung

Eine Möglichkeit, Information über Signalqualität bzw. Artefakte zu nutzen, ist die adaptive QRS-Erkennung, die sich an die jeweilige Signalsituation anpasst. Für die Realisierung eines adaptiven QRS-Erkenners gibt es verschiedene Möglichkeiten, die im Folgenden diskutiert werden sollen.

Aussetzen der Analyse

Ein einfacher, aber sehr effektiver Ansatz ist das Aussetzen der QRS-Erkennung während einer Störung. Dazu muss als zusätzlicher Eingang ein binäres Artefaktsignal vorliegen, das die EKG-Sequenzen markiert, die mit allergrößter Wahrscheinlichkeit nicht mehr analysierbar sind.

Bei einer herkömmlichen QRS-Erkennung können Artefakte schnell die internen Schwellwerte verändern, sodass nach einer Störung für mehrere Sekunden keine QRS-Detektion erfolgt, da der QRS-Erkennner erneut einschwingen muss. Dieses Phänomen ist in Abbildung 6.14 dargestellt: Die verhältnismäßig kurze Störung sorgt für eine Detektionspause von fünf Sekunden. Es wird also – obwohl das Signal bereits wieder analysierbar ist – ein falsches Ergebnis präsentiert. Auch wenn man nachträglich die Störung als Artefakt markiert und die falsch-positiven Trigger entfernt, bleibt eine vermeintliche Pause nach dem Artefakt. Solche Beispiele lassen sich häufig in automatisch analysierten EKGs finden.

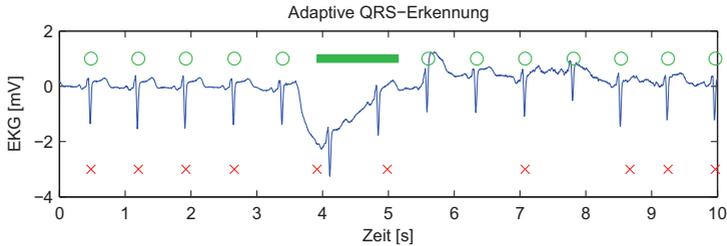


Abbildung 6.14: Das nach einem Artefakt auftretende Einschwingen des QRS-Detektors (rot) kann vermieden werden, wenn die gestörte Sequenz gezielt ausgeblendet wird (grün)

Wenn der verwendete QRS-Detektor die entsprechende EKG-Sequenz gar nicht erst zu Gesicht bekommt, kann er auch nicht falsch darauf reagieren. Blendet man ihn also für die ca. zwei Sekunden der Störung aus, kann er im Anschluss sofort wieder valide Ergebnisse mit unveränderter Güte liefern; der fehlerhaft oder gar nicht analysierte Bereich wird auf diese Art praktisch halbiert.

Ein entscheidender Vorteil dieser Methode ist, dass sie sich mit nahezu jedem QRS-Detektor kombinieren lässt, ohne den Quellcode des verwendeten QRS-Detektors zu verändern. Insbesondere bei online-fähigen Algorithmen fällt eine Integration leicht, auch wenn diese nur als Bibliothek vorliegen. Zu beachten ist lediglich, dass sich der Ausgang eines online-fähigen QRS-Erkenners auf einen Wert aus der Vergangenheit bezieht und damit die Position, die unmittelbar nach dem Artefakt gefunden wurde, verworfen werden muss. Dasselbe kann für den QRS-Komplex gelten, der unmittelbar vor dem Artefaktbereich liegt: Durch die retrospektive Erkennung kann dessen Position aufgrund der fehlenden Daten verfälscht werden, sodass hier eine falsch-negative Detektion auftreten kann.

Mit dieser Maßnahme kann die absolute Anzahl der Fehldetektionen im EKG zwar nur sehr gering beeinflusst werden, allerdings wird deren Position voraussagbarer. Eine falsch-negative Erkennung inmitten des Signals wird von der erweiterten Analyse als Pause oder plötzlicher Herzfrequenzwechsel erkannt – liegt dieser Bereich aber in unmittelbarer Nähe zu einer Artefaktmarkierung, kann dies bei der Herzfrequenz- und Pausenberechnung berücksichtigt werden.

Einfrieren von internen Schwellwerten

Um den verwendeten QRS-Detektor vor einer fehlerhaften Veränderung von Schwellwerten zu schützen, können die Schwellwerte auch für die Dauer des Artefakts eingefroren werden. Auf diese Weise läuft die QRS-Erkennung während des Artefakts weiter und detektiert mit großer Wahrscheinlichkeit auch die unmittelbar den Artefakt umgebenden QRS-Komplexe. Während des Artefaktbereichs kommt es allerdings zu Fehldetektionen, die hinterher wieder entfernt werden müssen.

Will man diese Methode bei einem bestehenden QRS-Erkennungsalgorithmus nachrüsten, muss dieser im Quelltext vorliegen, was die Einsatzmöglichkeiten erheblich einschränken kann. In dieser Arbeit wurde die Veränderung des Thresholds `det_thresh` des OSEA QRS-Detektors verhindert. Dadurch lässt sich die Sensitivität der QRS-Detektion gegenüber der zuvor genannten Methode verbessern. Im Gegenzug dazu wurde eine leichte Abnahme der positiven Prädiktivität in den nur leicht gestörten EKG-Sequenzen beobachtet.

Vergleich beider Verfahren

In Tabelle 6.5 sind die Ergebnisse der verschiedenen Verfahren gegenüber gestellt, getestet auf einem Kanal eines 24-Stunden-Datensatzes. Alle QRS-Trigger, die in einen automatisch detektierten Artefaktbereich fallen, wurden entfernt. Eine Berücksichtigung der Artefakte im QRS-Detektor führt also zu einer stark verbesserten Sensitivität, während die positive Prädiktivität weit weniger stark beeinflusst wird. Dies passt zu dem in Abbildung 6.14 beobachteten Verhalten: Durch das Verhindern der Schwellwertanpassung an eine Störung finden nach dem gestörten Abschnitt deutlich weniger falsch-negative Detektionen statt. Dass sich die Sensitivität so drastisch verbessert, liegt daran, dass hochamplitudige Artefakte den QRS-Erkennen so stark beeinflussen, dass über lange Bereiche keine Analyse mehr durchgeführt werden konnte.

6.2.2 Bewegungsinformationen für die VT/VF-Erkennung

Die automatische Erkennung von lebensbedrohlichen Herzrhythmen wie der VT/VF ist insbesondere für Mobilsysteme, die an ein telemedizinisches Servicecenter angebunden sind, von großer Bedeutung. Tritt eine solche pulslose

Tabelle 6.5: Fließen die Kenntnisse über artefaktbehaftete Bereiche in die QRS-Detektion mit ein, lässt sich das Ergebnis verbessern

Verfahren	TP	FN	FP	Se [%]	pP [%]
ohne	70104	4114	365	94,46	99,48
Ausblenden	73987	231	126	99,69	99,83
Einfrieren	74099	119	152	99,84	99,80

Rhythmusstörung auf, wird der Patient bereits nach wenigen Sekunden bewusstlos. Unterbleibt die Hilfeleistung, führt dies bei Fortbestehen der Rhythmusstörung unweigerlich zum Tod. Wird aber die VT/VF erkannt und automatisch Hilfe alarmiert, kann der Patient gerettet werden. In diesem Abschnitt soll die VT/VF-Erkennung für mobile, am Körper tragbare Systeme betrachtet werden.

Die Situation verdeutlicht sich, wenn das EKG-System des Patienten in der Lage ist, selbständig eine Defibrillation auszulösen, um damit die VT/VF zu durchbrechen [Lam10]. Da die Defibrillation mit Schmerzen und unter Umständen auch mit Verbrennungen der Haut einhergehen kann, muss eine Defibrillation bei Bewusstsein unbedingt vermieden werden. Bei einem externen Defibrillator kann die Schockabgabe durch entsprechende Interaktion unterdrückt werden, doch auch dies kann bei zu häufigem Auftreten eine unnötige Belastung für den Patienten sein.

Betrachtet man Abbildung 6.15, erkennt man, dass ein EKG durch Bewegung durchaus so gestört werden kann, dass es aussieht, als ob ein Kammerflattern vorliegt. Eine konventionelle VT/VF-Erkennung, wie sie in automatischen externen Defibrillatoren (AED) zum Einsatz kommt, stößt hier an ihre Grenzen und würde eine solche Sequenz falsch-positiv als defibrillationspflichtig erkennen.

Betrachtet man nun aber neben dem EKG auch die Bewegungssignale, kann man solche Fehldetektionen verhindern: Neben dem EKG-Signal wird von der VT/VF-Erkennung auch das Ergebnis der in Kapitel 6.1.2 beschriebenen Ruheerkennung miteinbezogen (siehe Abbildung 6.16). Um eine VT/VF-Sequenz zu erkennen, wird körperliche Ruhe als notwendiges Kriterium festgelegt. Durch Bewegung verursachte Artefakte, die einem Kammerflattern ähneln, führen somit durch den negativen Ausgang der Ruheerkennung nicht mehr zu einer falsch-positiven VT/VF-Detektion. Tritt aber tatsächlich ein Kammerflimmern auf, sinkt das Herzzeitvolumen und damit der arterielle Blutdruck schlagartig

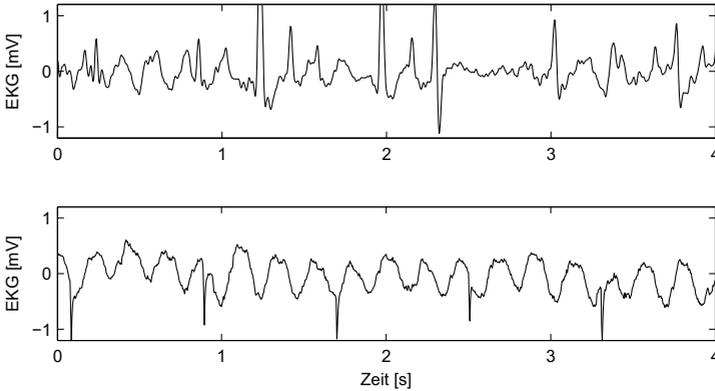


Abbildung 6.15: Bewegungsartefakte im EKG (oben) können einem Kammerflattern (unten), hier bei einem Schrittmacher-Patienten, ähneln

ab. Innerhalb von wenigen Sekunden wird der Patient bewusstlos, gefolgt von Atemstillstand und Muskelrelaxierung. Durch die mangelnde Sauerstoffversorgung des Gehirns (zerebrale Hypoxie) kann es vereinzelt zu Krampfanfällen kommen [Ohl08]. Durch die Entspannung der Muskeln sackt der Patient in sich zusammen. Die Ruheerkennung erkennt diesen bewegungslosen Zustand, sodass bei einer detektierten VT/VF sofort die Defibrillation freigegeben werden kann.

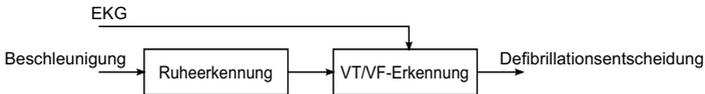


Abbildung 6.16: Körperliche Ruhe ist ein notwendiges Kriterium für die Erkennung von VT/VF

In diesem Szenario werden schnell die Anforderungen an die beteiligten Analyse-Algorithmen deutlich: Die Ruheerkennung muss sehr sensitiv sein, um nicht die Sensitivität der VT/VF-Erkennung zu beeinträchtigen. Die VT/VF-Erkennung wiederum kann ebenfalls sensitiver als gewöhnlich sein, da sie weniger stark durch artefaktbehaftete Signale herausgefordert wird. Zweitran-

gig ist eine hohe Spezifität bei einem EKG mit Bewegungsartefakten, da dies bereits durch die Ruherkennung unterbunden wird.

Die VT/VF-Erkennung auf einem ICD folgt meist anderen Regeln [Kog05]. Da hier die EKG-Elektroden direkt im Herzen liegen – bei einem modernen Zweikammer-ICD sowohl im Atrium als auch im Ventrikel – kennt das Gerät Fernfeld und Nahfeld der elektrischen Herzaktivität. Durch das hochwertige Signal der intrakardialen Elektroden stellen Bewegungsartefakte eine untergeordnete Rolle dar. Problematisch hingegen ist das Oversensing im Ventrikel aufgrund intrakardialer Signale, wie z. B. einer hohen P-Welle oder das Undersensing im Atrium, das zu einer falsch-positiven ventrikulären Klassifikation, z. B. bei Sinustachykardien, führt. Die Zahl der inadäquaten Schockabgaben von ICDs wird in der Literatur mit 10–41 % angegeben [Kog05].

Der Algorithmus in Abbildung 6.17 zeigt einen möglichen Ansatz, wie man Ruherkennung und VT/VF-Erkennung sinnvoll kombinieren kann. Start für eine VT/VF-Analyse ist dabei der Beginn einer detektierten Ruhephase. Erst wenn die Ruhephase länger als die durch $\Delta t_{\max, \text{mov}}$ festgelegte Zeit unterbrochen wird, wird die VT/VF-Analyse abgebrochen. Da das Zielkollektiv eher körperlich passiv ist, läuft die VT/VF-Analyse über etwa 90 % des Tages mit. Da sich die EKG-Störungen aber auf die Sequenzen mit körperlicher Aktivität konzentrieren, steigt die Güte der Analyse in den Ruhephasen.

Eine vollständige Validierung des vorgeschlagenen Algorithmus kann nur

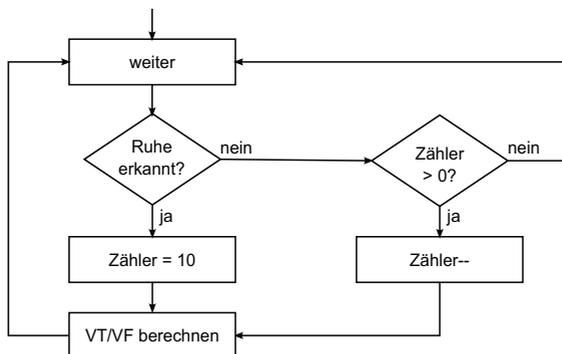


Abbildung 6.17: Der Algorithmus zur VT/VF-Erkennung berücksichtigt körperliche Ruhe

mit Daten erfolgen, die sowohl Bewegungs- als auch EKG-Daten mit VT/VF-Sequenzen enthalten. Da solche Daten nicht vorliegen, kann nur eine Abschätzung über die Spezifität vorgenommen werden. Im Rahmen dieser Arbeit wurde der in [Jek04] vorgestellte Algorithmus zur VT/VF-Erkennung implementiert und auf die careMon-Daten angewendet. Auf den Rohdaten werden von diesem sensitiven Algorithmus sehr viele falsch-positive Sequenzen gefunden. Berücksichtigt man aber alle drei EKG-Kanäle und schließt artefaktbehaftete Sequenzen aus, fallen die wenigen FP-Sequenzen in Bewegungsphasen. Wenn man bedenkt, dass diese Algorithmen für den Einsatz in AEDs gedacht sind, ist das Verhalten nachvollziehbar, denn ein AED kommt nur bei bewussten, nicht ansprechbaren Personen zum Einsatz – Bewegungsartefakte spielen hier eine untergeordnete Rolle. Eine Bewegung durch Ersthelfer oder Rettungsdienstpersonal während der Analyse muss – ebenso wie bei AEDs – durch entsprechende Hinweise verhindert werden.

6.3 Kontextbezogene Interpretation

Um bei der Befundung eines Langzeit-EKGs das Signal in einen besseren Kontext zu bringen, ist bisher die Zeitachse das am meisten verbreitete Mittel. Durch eine genaue Angabe der Uhrzeit und oft auch durch einen speziell markierten Bereich für die Nachtruhe kann sich der Mediziner einigermaßen orientieren. Eine zeitgleich aufgetragene Herzfrequenzkurve ergänzt dieses Bild.

In dieser Arbeit liegen aber weitaus mehr Informationen vor, eine der wichtigsten ist das Bewegungsprofil, dessen Erstellung in Kapitel 6.1.3 ausführlich beschrieben wurde. Trägt man wie in Abbildung 6.18 Herzrate und Bewegungsprofil übereinander auf, kann jede EKG-Veränderung nicht nur in einen zeitlichen, sondern auch in einen Aktivitätskontext gebracht werden. So ist der Herzfrequenzanstieg bei ca. 8,5 h durch eine erhöhte Aktivität verursacht. Mit der Erkennung bestimmter Aktivitätsereignisse lassen sich kombinierte Parameter ableiten.

6.3.1 Autoregulation der Herzfrequenz nach dem Aufstehen

Die automatische Erkennung von Aufstehen bzw. Aufrichten wurde bereits in Kapitel 6.1.4 motiviert. Sind die Aufstehereignisse erst einmal detektiert,

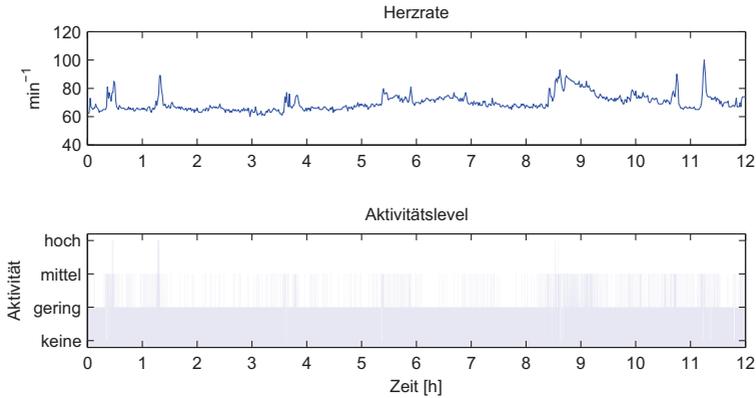


Abbildung 6.18: Herzrate und Aktivitätsprofil über einen Zeitraum von zwölf Stunden

kann man sehr einfach die dem Event benachbarten Herzschläge in der QRS-Triggerliste finden und auslesen. Auf diese Weise lässt sich die Veränderung der Herzrate unmittelbar nach dem Aufstehen untersuchen.

In Abbildung 6.19 ist dieser Verlauf zu sehen. Dafür wurden von den 332 erkannten Aufsteh-Ereignissen einer siebentägigen Aufnahme alle verwendet, bei denen das EKG als artefaktfrei gilt. Von den 295 artefaktfreien Ereignissen wird der mittlere RR-Abstand (ΔRR) der umliegenden Schläge berechnet und – bezogen auf den Herzschlag, der dem Aufsteh-Event unmittelbar folgt – aufgetragen.

In der resultierenden Kurve sieht man deutlich den Anstieg der Herzfrequenz in den Schlägen nach dem markierten Ereignis. Nach etwa 20 Schlägen sinkt die Frequenz wieder leicht und stellt sich auf einem der Belastung entsprechenden Niveau ein. Die Kurven verschiedener Patienten unterscheiden sich in der Steigung und Amplitude des Herzfrequenzanstiegs. Diese Parameter lassen sich zur Beurteilung der autonomen Funktion des Herzens heranziehen.

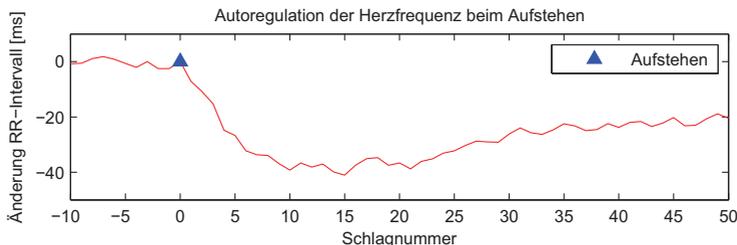


Abbildung 6.19: Autoregulation der Herzfrequenz eines Patienten gemittelt über 295 Aufsteh-Ereignisse eines Tages

6.3.2 Rhythmusstörungen im Aktivitätskontext

Bestandteil einer üblichen Holter-EKG-Auswertung sind die Anzahl und die Dauer von Brady- und Tachykardien. Verwendet man für deren Bestimmung die in der Literatur angegebene Schwelle von 60 Schlägen pro Minute für Bradykardien, werden oft lange Abschnitte während des Schlafens als bradykard gekennzeichnet. Definitionsgemäß ist dies natürlich richtig, allerdings üblicherweise von keiner diagnostischen Relevanz. Viel interessanter sind die Passagen tagsüber, bei denen die Herzfrequenz einer ansteigenden Belastung nicht folgen kann.

Aus diesem Grund werden in dieser Arbeit die Bradykardien in Ruhe und in Belastung getrennt betrachtet. Dazu wird das zuvor berechnete Aktivitätsprofil herangezogen: Liegt die Aktivität auf Level 1 oder 2, liegen Bradykardien in Ruhe vor, die mit hoher Wahrscheinlichkeit eine gesunde physiologische Reaktion sind. Liegt die Aktivität höher, handelt es sich um Bradykardien unter mittlerer oder gar hoher Belastung, die vom Mediziner eingehend betrachtet werden sollten.

Für das automatische Erkennen von Tachykardien gilt Entsprechendes: Die ansteigende Herzfrequenz aufgrund einer körperlichen Belastung ist die physiologische Reaktion des Herzens. Steigt allerdings die Herzfrequenz in einer Ruhephase stark an, ist dies ein Hinweis auf eine Herzrhythmusstörung und sollte näher untersucht werden.

Für den in dieser Arbeit entwickelten Report wird mit verschiedenen Farben gearbeitet: Die relevanten Brady- und Tachykardien sind blau hervorgehoben, während die weniger relevanten grau unterlegt sind (s. Abb. 6.23).

Eine andere Möglichkeit zur kontextsensitiven Bewertung von Tachykardien ist die automatische Verschiebung der Tachykardieschwelle während einer Belastung [Jat10]. Zur Erreichung optimaler Ergebnisse muss hierfür ein Modell erstellt werden, das den physiologischen Herzfrequenzanstieg während einer Belastung abbildet. Aufgrund der Simplizität und der Transparenz für den auswertenden Mediziner wird in dieser Arbeit die zuvor beschriebene Methode verwendet.

Wird die Anzahl aller nicht-normalen Schläge in einer Tabelle aufgeführt, lassen sich diese nach Aktivitätsklassen trennen. Ebenso kann die Aktivität vor einer Rhythmusstörung bestimmt werden. Auf diese Weise lassen sich belastungsinduzierte Herzrhythmusstörungen sehr einfach quantifizieren. In Tabelle 6.6 ist eine solche Übersicht dargestellt, zusätzlich ist die mittlere Herzrate für jedes Aktivitätslevel angegeben.

Tabelle 6.6: In Tabellenform lassen sich belastungsinduzierte Herzrhythmusstörungen quantifizieren

Aktivität	alle	keine	niedrig	mittel	hoch
Anteil		42,2 %	41,3 %	16,2 %	0,2 %
mittl. Herzrate	59 min ⁻¹	52 min ⁻¹	60 min ⁻¹	76 min ⁻¹	88 min ⁻¹
SVPB	265	105	91	69	0
TACHYCARDIA	410	0	11	399	0
BRADYCARDIA	6501	6496	5	0	0
PAUSE	10	4	3	3	0
PVC	212	100	77	34	1
VT	0	0	0	0	0
COUPLET	6	0	0	6	0
TRIPLET	0	0	0	0	0
SALVE	0	0	0	0	0

6.3.3 Chronotrope Inkompetenz

Die chronotrope Inkompetenz (CI) ist eine zusätzliche Kenngröße für die Risikoabschätzung bei Patienten mit koronarer Herzkrankheit [Lö99]. Für deren sichere Erkennung ist der Patient einem Belastungs-EKG zu unterziehen. Dennoch kann versucht werden, ein Langzeit-EKG als Screening-Werkzeug zur

Auffindung von CIs bei ansonsten symptomlosen Patienten zu nutzen. Die große Schwierigkeit besteht darin, die Schwere der Belastung exakt zu bestimmen und ein geeignetes Modell zu erstellen, mit dessen Hilfe auf die erwartete Herzfrequenz geschlossen werden kann.

Laut der Studie von [San95] kann man von chronotroper Inkompetenz sprechen, wenn unter Belastung der Frequenzanstieg weniger als 40 % der Ruheherzfrequenz beträgt. Definiert man die mittlere Herzrate im Aktivitätslevel *niedrig* als Ruhepuls, kann man die zu erreichende Belastungsfrequenz berechnen:

$$HF_{\text{Ruhe}} \cdot 1,4 \leq HF_{\text{Belastung}} \quad (6.6)$$

Setzt man das Zahlenbeispiel aus Tabelle 6.6 ein, erhält man $60 \cdot 1,4 = 84$ für die zu erreichende Belastungsfrequenz, was unter der mittleren Belastungsfrequenz von 88 Schlägen pro Minute im höchsten Aktivitätslevel liegt.

6.3.4 Stürze und Synkopen

Für die Aufklärung von Synkopen unklarer Genese ist ein Langzeit-EKG unerlässlich. Wird das Auftreten der Synkope vom Patienten zeitlich genau dokumentiert, lässt sich das Ereignis sehr einfach auf eine kardiologische Ursache hin untersuchen – dies kann beispielsweise eine Pause von über 3 s, eine pulslose ventrikuläre Tachykardie, Vorhofflimmern oder eine extreme Bradykardie sein. Lässt sich kein hämodynamisch unwirksamer Herzrhythmus im EKG finden, liegt mit großer Wahrscheinlichkeit eine andere Ursache der Synkope zugrunde – oder aber, die zeitliche Dokumentation des Patienten war ungenau.

Bei Synkopen, die mit einem Sturz einhergehen, lässt sich auch das Aktivitätssignal zur zeitlichen Lokalisation nutzen. Auf diese Weise kann gezielt das EKG im Bereich eines Sturzes untersucht werden. In Abbildung 6.20 ist eine mit dem careMon-System aufgezeichnete Synkope gezeigt. Zwei Pausen von jeweils über 7 s Länge sorgen für eine kurze Bewusstlosigkeit – der Sturz ist gut im Bewegungssignal und als Artefakt im EKG zu sehen. Fällt der Sturz in die Pause, würde er von der Artefakterkennung als Artefakt gekennzeichnet werden. Damit würde auch die Pause nicht beachtet werden, da sie als Artefakt angesehen würde. Mit einer Sturzerkennung auf dem Beschleunigungssignal kann man diese Sequenzen dennoch detektieren und auswerten.

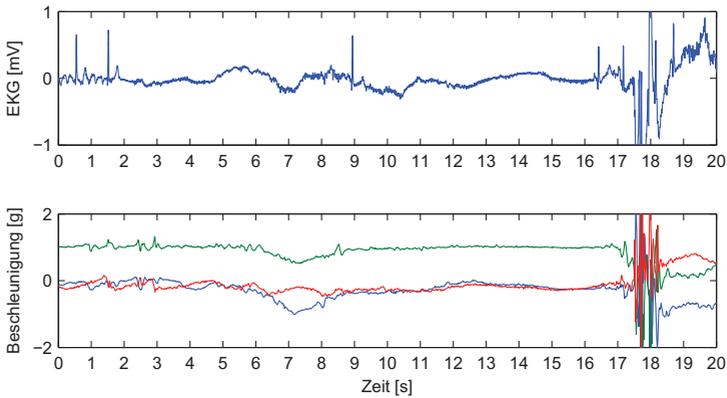


Abbildung 6.20: Zwei lange Pausen sind die Ursache für eine kurze Bewusstlosigkeit

6.3.5 Ruhephasen und Ruhepuls

Mit Hilfe der Lageerkennung kann versucht werden, die Schlafens- bzw. Ruhezeiten des Patienten zu bestimmen. Für die Erkennung von Ruhephasen wurde ein einfaches Regelwerk aufgestellt. Danach ist eine Ruhephase mindestens 30 Minuten lang, während dieser Zeit muss durchgehend eine horizontale Körperlage vorliegen. Eine Ruhephase kann durch kurzes Aufstehen, wie z. B. bei einem nächtlichen Toilettengang, unterbrochen werden. Diese Unterbrechungen werden zwar gezählt und gespeichert, aber nicht einzeln annotiert, sodass man für die Nacht eine durchgängige Ruhephase erhält.

Vom Hinzuziehen weiterer Sensorinformationen wie der Herzfrequenz (Absinken der Herzfrequenz im Schlaf) oder einer zeitlichen Information wurde abgesehen, da zum einen die Schlafgewohnheiten der Patienten stark unterschiedlich sind, zum anderen die Herzfrequenz im pathologischen Fall wie z. B. bei Vorhofflimmerepisoden während der Nacht keinen geeigneten Parameter darstellt. Mit Hilfe von Techniken, die in der Schlafmedizin zur Schlafphasenerkennung genutzt werden, könnte eine Unterscheidung von körperlicher Ruhe und tatsächlichem Schlafen möglich sein. Die Berechnung von HRV-Parametern und das Verhältnis zwischen Atem- und Herzfrequenz sind vielversprechende

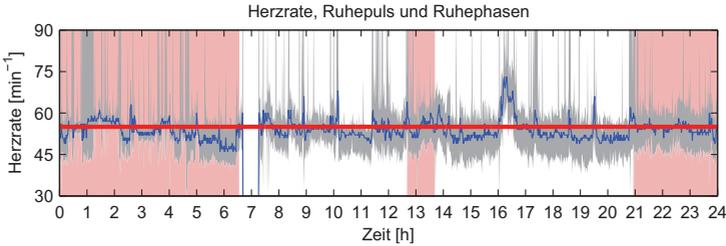


Abbildung 6.21: Die Ruhephasen werden zur Bestimmung des Ruhepulses (rote Linie) genutzt

Ansätze – jedoch können auch sie bei kardial geschädigten Patienten nicht interpretierbar sein.

Wenn die Ruhephasen bekannt sind, kann darüber hinaus der Ruhepuls ermittelt werden. Da es in der Medizin keine exakte Definition gibt, wann der Ruhepuls zu messen ist, wurde die mittlere Herzrate in der Minute vor dem Aufstehen ausgelesen. Dies entspricht dem morgendlichen Pulsmessen in der Klinik. Der Median aller Ruhepulse eines Datensatzes kann als patientenspezifischer Ruhepuls angesehen werden.

Der Ruhepuls ist ein wichtiger Vergleichswert, um den täglichen Herzfrequenzverlauf besser einordnen zu können und wird unter anderem im Rahmen der Bewertung der chronotropen Kompetenz verwendet (s. Kap. 6.3.3).

6.4 Berichte und Darstellungsformen

Die in den vorherigen Kapiteln beschriebenen Algorithmen wurden in weiten Teilen für die automatische Analyse der careMon-Daten eingesetzt. Hierfür wurde ein Berichtsgenerator in Matlab implementiert, der alle Analysen durchführt, die Ergebnisse dem Unisens-Datensatz hinzufügt und anschließend einen PDF-Report erstellt. Die Implementierung der einzelnen Algorithmen erfolgte teilweise in Matlab, zum Teil aber auch in C und C++, was zu einem erheblichen Performancegewinn führt. Kompilierte C- und C++-Funktionen können über das von Mathworks zur Verfügung stehende MEX-Interface in Matlab eingebunden werden.

Da die careMon-Daten keine Daten zur Elektroden-Haut-Impedanz enthalten, können die darauf aufbauenden Methoden zur Artefaktbehandlung nicht angewendet werden. Bei der Artefaktreduktion und Artefakterkennung wurde deshalb auf andere Verfahren zurückgegriffen. Dennoch kann ein zuverlässiger erweiterter Report für jeden aufgezeichneten Datensatz erstellt werden.

6.4.1 Analyse-Framework

Das implementierte Analyse-Framework wurde speziell auf die vorhandenen DekomTex-Daten abgestimmt. Damit kann ein sehr hoher Automatisierungsgrad erreicht werden, ohne die Implementierung unnötig zu verkomplizieren. Dies betrifft insbesondere die feststehenden Abtastfrequenzen und die bekannten Namen der vorhandenen Signale.

Die einzelnen Algorithmen und deren Abhängigkeiten sind in Tabelle 6.7 dargestellt. Das Prefix *dtr* steht für *DekomTex-Report* und kennzeichnet alle beteiligten Funktionen, welche durchgängig nur mit dem Pfad zur Unisens-Datei als Parameter aufgerufen werden. Im Folgenden soll kurz auf die einzelnen Funktionen eingegangen werden.

Tabelle 6.7: Funktionen und Abhängigkeiten des DekomTex-Reportgenerators

Funktion	Abhängigkeiten
EKG-Amplitude	EKG
Aktivitätserkennung	Beschleunigung
Körperlage	Beschleunigung
System abgelegt	Lead-Off, Temperatur
Artefakte	EKG-Amplitude, EKG
QRS-Erkennung	Artefakte, EKG
Gesamttriggerliste	QRS-Erkennung
Herzrate	Gesamttriggerliste
Tachogramm	Gesamttriggerliste
Rhythmus	Gesamttriggerliste
Sturzerkennung	Beschleunigung, Aktivitätserkennung
Aufstehen	Körperlage
Ruhephasen	Körperlage, System abgelegt
Ruhepuls	Herzrate, Ruhephasen

Die Hauptfunktion wird mit dem Pfad zum Datensatz als Argument aufgerufen. Sie erzeugt aus den aufgezeichneten Sensordaten alle Dateien mit Zwischenergebnissen, die für einen Bericht notwendig sind.

Aus dem EKG wird für jeden Kanal die EKG-Amplitude innerhalb eines 320-Sample-Fensters berechnet. Dieses Zwischenergebnis wird – neben den EKG-Rohdaten – für die Artefakterkennung verwendet. Für jeden EKG-Kanal liegen anschließend zwei Artefaktsignale vor: Zum einen die Artefakte, die durch 8 bzw. 50 Hz-Störungen und durch Erreichen der Ausstaugergrenzen des Verstärkers hervorgerufen werden. Zum anderen Bewegungsartefakte, die starke Baseline-Änderungen verursachen. Jedes Artefaktsignal enthält getrennte Informationen für die drei EKG-Kanäle. Anschließend werden die Artefakte pro Kanal durch ein logisches ODER verknüpft und als Annotation gespeichert. Bei diesem Schritt werden Pausen von weniger als 2,5 s zwischen zwei Artefaktbereichen entfernt.

Der verwendete erweiterte OSEA-QRS-Detektor benötigt neben dem EKG die oben genannten Artefaktannotationen als Eingang, da das EKG während der Artefaktbereiche ausgeblendet wird. Pro EKG-Kanal werden QRS-Detektion und Schlagklassifikation gespeichert. Um die Ausführungsgeschwindigkeit zu erhöhen, wird die Berechnung auf jedem der drei Kanäle parallel auf einem eigenen Prozessorkern vorgenommen.

Zur Vereinigung der drei Triggerlisten und der drei Artefaktlisten wurde eine Methode aus [Rei11] übernommen. Es werden die drei QRS-Triggerlisten und die drei Artefaktannotationen eingelesen und als jeweils ein neues Event-Entry abgespeichert. So erhält man eine Gesamttriggerliste und eine globale Artefaktliste.

Die Herzrate wird aus den globalen QRS-Triggern berechnet. Dabei wird jeweils eine Minute betrachtet und anschließend Minimum, Maximum und Median der Herzfrequenz berechnet. Ausreißer über 220 und unter 30 Schlägen pro Minute werden ignoriert. Die berechnete Herzrate wird als dreikanaliges Signal-Entry gespeichert. Neben der Herzrate wird noch ein Tachogramm berechnet, allerdings wird hier das Schlag-zu-Schlag-Intervall als ValuesEntry gespeichert. Herzfrequenzänderungen, wie z. B. eine respiratorische Sinusarrhythmie oder Vorhofflimmern, sind in diesem Signal sehr gut zu erkennen.

Die Bestimmung von Rhythmusstörungen erfolgt ebenfalls auf Basis der globalen Triggerliste. Dabei wird auf die Schlagklassifikation des OSEA zurückgegriffen, die Einordnung der Rhythmusstörungen erfolgt nur über Schlagursprung (supraventrikulär oder ventrikulär) und RR-Abstand. Eine Einordnung

in den Aktivitätskontext erfolgt erst bei der Erstellung des PDF-Reports durch eine entsprechende Kennzeichnung. Alle Rhythmusstörungen werden als Ereignisse pro Minute in einem `SignalEntry` gespeichert. Die erkannten Pausen werden von Artefakten bereinigt und separat als Events abgelegt.

Die vierstufige Aktivitätserkennung wurde in Kapitel 6.1.3 beschrieben. Als Eingangssignal dient das dreiachsige Beschleunigungssignal des EKG-Gurts. Die Aktivitätsklassifizierung wird als `SignalEntry` mit einer Frequenz von 3,2 Hz gespeichert. Der eigentliche Algorithmus ist in C++ implementiert und liegt als MEX-Datei vor, die von einem M-File eingebunden wird. Dasselbe gilt auch für die Erkennung der Körperlage: Aus den Beschleunigungsdaten wird die Körperlage mit Hilfe der erstellten MEX-Datei bestimmt und als Signal mit 3,2 Hz gespeichert.

Die Aufsteherkennung (s. Kap. 6.1.4) detektiert anhand der zuvor berechneten Körperlage die entsprechenden Ereignisse und speichert diese als eigenes `EventEntry`. Die Sturzerkennung benötigt dagegen das Beschleunigungssignal als Eingang, das Ergebnis wird ebenfalls als `EventEntry` abgelegt.

Auf Basis der Körpertemperatur und des Lead-Off-Signals werden die Sequenzen erkannt, in denen das System nicht getragen wurde. Da das Lead-Off-Signal der vorhandenen Datensätze nicht zuverlässig genug für eine sichere Erkennung war, musste auf das Temperatursignal zurückgegriffen werden. Durch das Ablegen des EKG-Gurtes sinkt die gemessene Temperatur schlagartig ab, während sie beim Anlegen wiederum sehr schnell ansteigt.

Die Erkennung von pulslosen VT/VF-Sequenzen ist in der retrospektiven EKG-Analyse weniger bedeutsam, sodass darauf in diesem Zusammenhang verzichtet wurde. Zur Erkennung von Vorhofflimmer-Sequenzen wurde der in [Kai10, Kai09] veröffentlichte Algorithmus eingesetzt.

6.4.2 Berichte

Die durch das Analyse-Framework erstellten Ergebnisse können durch einen automatischen Reportgenerator zu einem PDF-Report zusammengefasst werden. Der PDF-Report erstellt für jeden angebrochenen Kalendertag der Messung zwei DIN A4-Seiten mit Informationen über den Tag, die über einer Zeitachse angeordnet sind.

Die erste Seite ist ein allgemeiner Rhythmus-Report mit dem Schwerpunkt auf Extrasystolen und Vorhofflimmern (s. Abb. 6.22). Im obersten Plot wird die

Herzrate im Tagesverlauf gezeigt, gemittelt über jeweils eine Minute. Neben der mittleren Herzrate werden auch maximale und minimale Herzrate dargestellt, um Episoden mit starken Schwankungen hervorzuheben. In der Herzratenansicht sind Artefakte und Zeitbereiche, in denen das Messsystem nicht getragen wurde, orange hinterlegt.

Es folgt eine Histogrammanzeige von supraventrikulären und ventrikulären Extrasystolen, inklusive der Unterscheidung zwischen singulären ventrikulären Extrasystolen, Couplets, Triplets und ventrikulären Salven. Zusätzlich wird die Gesamtzahl der jeweiligen Ereignisse pro Tag angezeigt, da dies ein üblicher klinischer Parameter zur Risikostratifizierung bei KHK-Patienten darstellt (Lown-Klassifikator). Zwischen monomorphen und polymorphen Extrasystolen kann jedoch nicht differenziert werden.

Komplettiert wird die Seite durch die Markierung von Sequenzen, in denen Vorhofflimmern vorliegt. Durch das Auftragen aller Ereignisse über einer Zeitachse kann das Auftreten der einzelnen Sequenzen schnell im Tachogramm überprüft werden. Für eine wirklich sicherere Aussage muss jedoch immer das EKG direkt betrachtet werden.

Die zweite Seite des Reports (s. Abb. 6.23) enthält die Rhythmusstörungen, die in einen Aktivitätskontext gebracht werden können. Neben der identischen Herzfrequenzanzeige werden supraventrikuläre Tachykardien, Bradykardien, Pausen und ventrikuläre Tachykardien in einer Histogrammansicht angezeigt. Die Tachy- und Bradykardien werden farblich hervorgehoben, wenn sie der physiologischen Reaktion des aktuellen Aktivitätsprofils widersprechen.

Zusätzlich werden verschiedene Aktivitätsinformationen über derselben Zeitachse angezeigt. Damit lassen sich alle Herzfrequenzänderungen direkt mit dem Aktivitätsprofil abgleichen. Das Aktivitätsprofil beinhaltet die vierstufige Aktivitätsanzeige (sowohl Sample-genau als auch auf eine Minute gemittelt), die aktuelle Körperlage sowie die erkannten Aufsteh- und Sturzereignisse. Insbesondere bei Stürzen kann so schnell eine mögliche kardiale Ursache wie eine bradykarde oder pulslose Rhythmusstörung untersucht werden.

Bei einer siebentägigen Aufnahme werden auf diese Weise 16 Seiten Bericht generiert, die in einem PDF-Dokument zusammengefasst werden. Die Erstellung erfolgt vollautomatisch ohne weitere Interaktion. Patienten-ID und Datum im Dateinamen ermöglichen ein schnelles Auffinden des Dokuments.

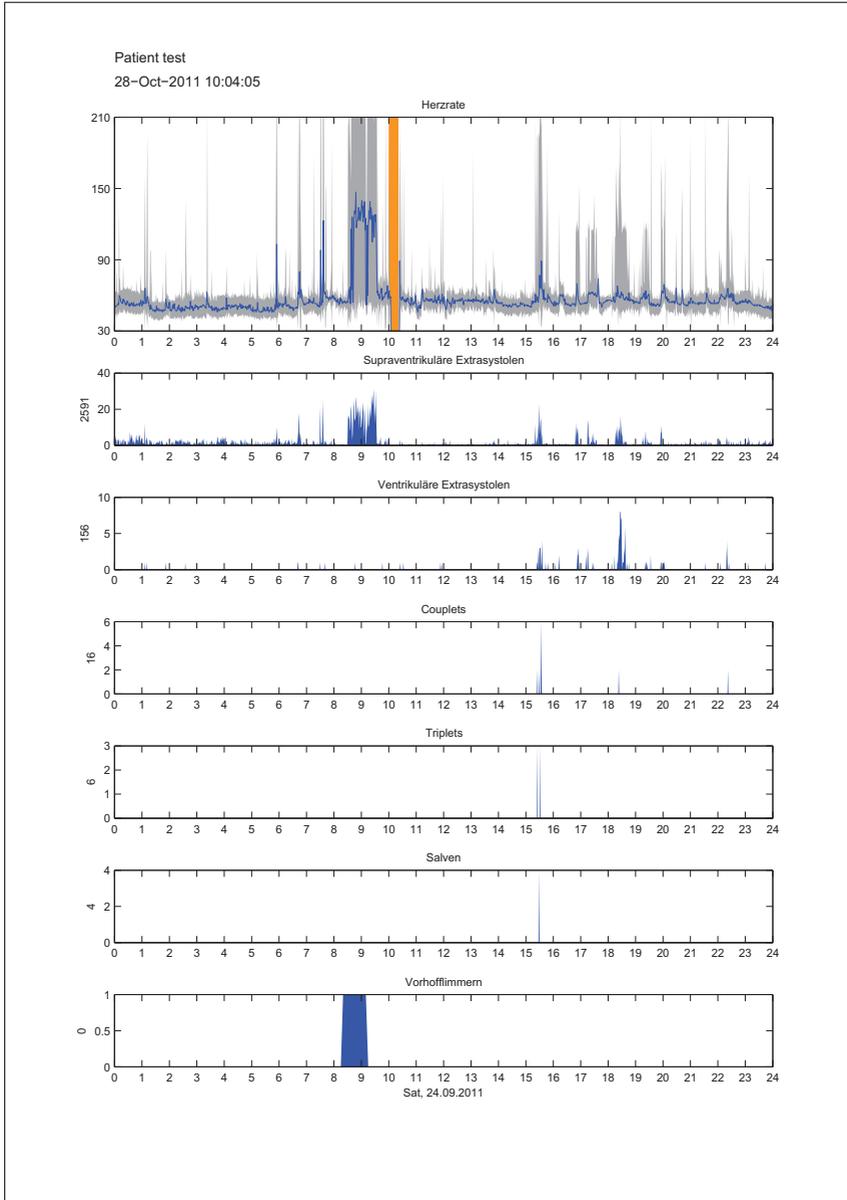


Abbildung 6.22: Rhythmus-Report

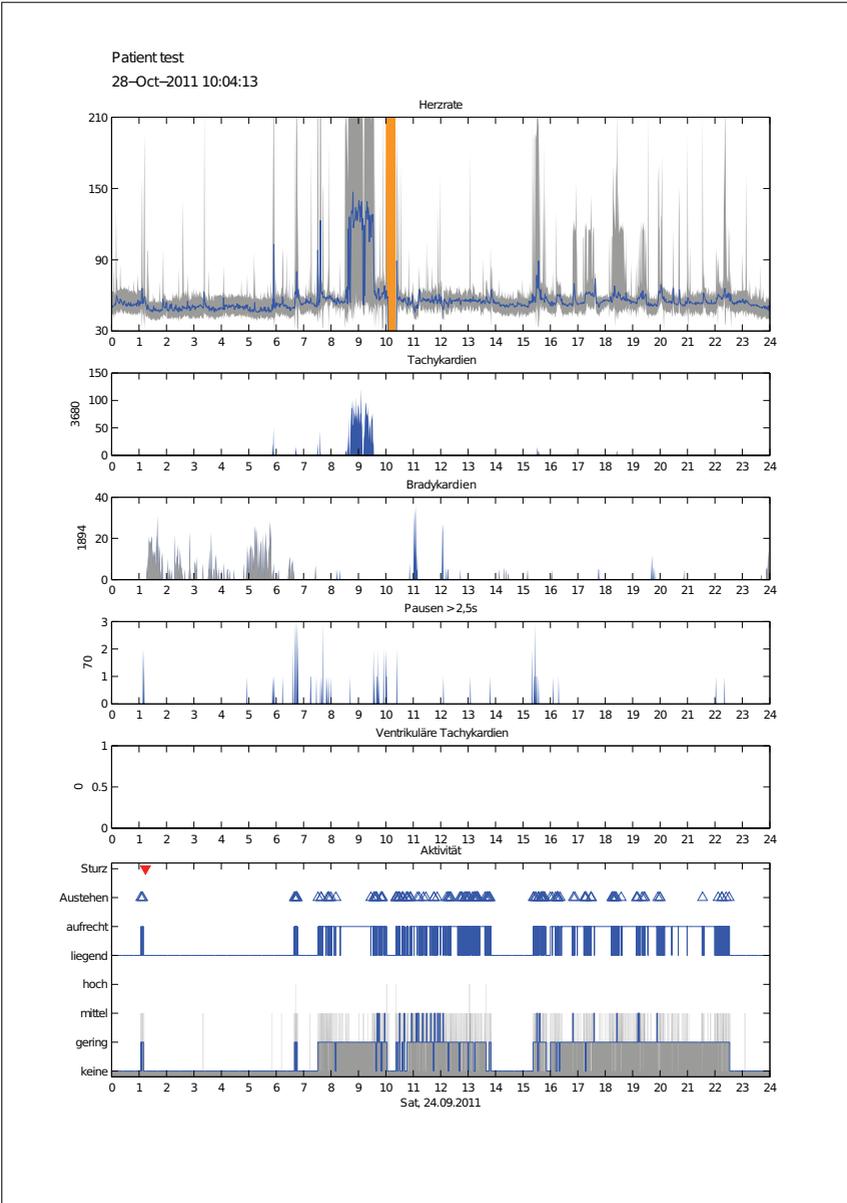


Abbildung 6.23: Frequenz-Report

6.4.3 Softwaregestützte Darstellung

Die Ergebnisse der kontextsensitiven EKG-Analyse können auch mit entsprechender Software dargestellt werden. Der EKG-Editor (s. Kap. 4.2.2) ist auf die Darstellung des EKG-Signals und einiger Annotationen spezialisiert. Nicht nur durch die in der Klinik übliche Darstellung auf Millimeterpapier ist er das von Medizinern bevorzugte Betrachtungswerkzeug, auch in anderen Gesichtspunkten ähnelt die Software gängigen Produkten. Die integrierte Tachogramm-Ansicht erleichtert das Auffinden auffälliger EKG-Sequenzen. Ebenso können alle Ereignisse des Unisens-Datensatzes als Liste geladen werden, sodass das EKG an dieser Stelle direkt angesprungen werden kann. In Abbildung 6.24 ist eine solche Liste mit zwei erkannten Pausen innerhalb des Datensatzes geladen. Wird eine Pause markiert, springt die EKG-Ansicht zur entsprechenden Zeit und stellt das Signal links und rechts des Ereignisses dar. Bei vielen Events lässt sich komfortabel mit den Cursor-Tasten durch die Liste blättern.

Durch seine Spezialisierung ist der EKG-Editor aber in seiner Funktionalität

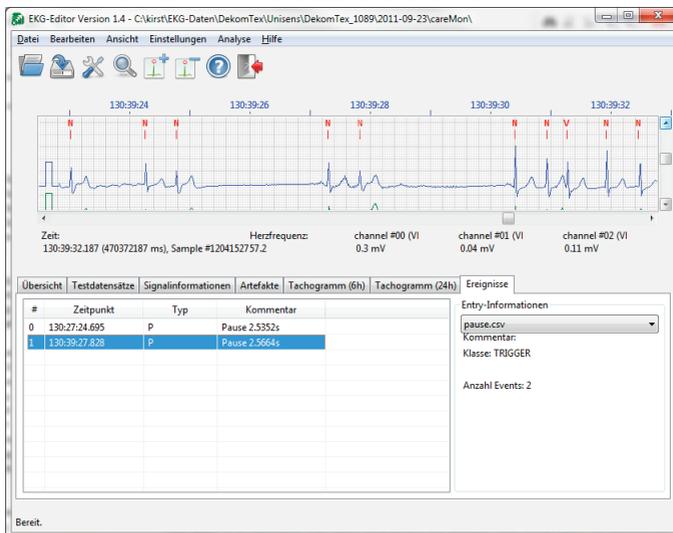


Abbildung 6.24: Der EKG-Editor ermöglicht das gezielte Anspringen von Events, wie zum Beispiel zuvor detektierte Pausen

beschränkt. Neue Ansichten von Signalen oder Auswertungen müssen erst aufwändig implementiert werden – wenn sie aber integriert sind, sind sie optimal auf die Bedürfnisse der Anwender angepasst.

Der UnisensViewer (s. Kap. 4.2.3) kann hingegen das gesamte Repertoire eines Unisens-Datensatzes anzeigen, ist aber in seiner Bedienung eher unkonventionell und spricht damit primär Wissenschaftler und Entwickler an. Alle Einträge eines Datensatzes werden über einer gemeinsamen Zeitachse dargestellt und stehen somit in einem zeitlichen Kontext. Hier kann man beispielsweise nicht nur eine markierte Pause erkennen, sondern erkennt gleichzeitig, dass der Patient zuvor eine Minute lag und die Pause unmittelbar nach dem Aufstehen aufgetreten ist (s. Abb. 6.25).

Die Anzeige von großen Datensätzen ist jedoch nicht immer unproblematisch: Während einige Informationen wie beispielsweise die Herzrate über einen großen Zeitraum betrachtet werden (Stunden oder Tage), können andere Signale wie das EKG nur über einem sehr kleinen Zeitraum (etwa eine Minute) sinnvoll interpretiert werden.

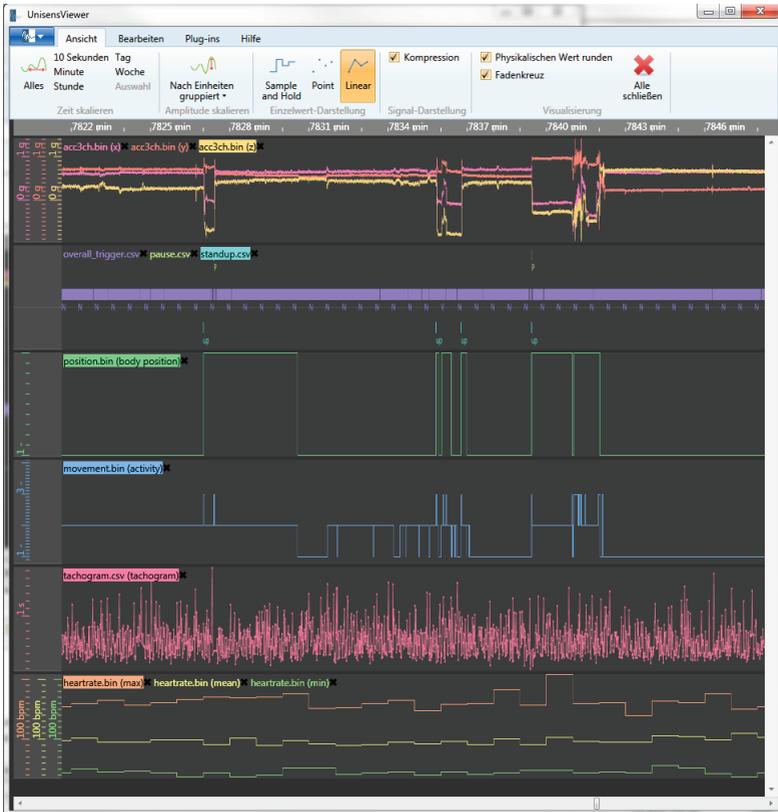


Abbildung 6.25: Der UnisenViewer kann alle im Datensatz enthaltene Informationen anzeigen, hier Beschleunigungssignal, verschiedene Ereignisse (Pausen, QRS-Trigger, Aufstehen), Körperlage und Bewegung sowie Tachogramm und Herzrate

7 Diskussion der Ergebnisse

Abschließend sollen die erreichten Ergebnisse dieser Arbeit diskutiert und dabei die drei wesentlichen Punkte Framework, Artefaktbehandlung und kontextsensitive EKG-Analyse betrachtet werden.

7.1 Framework

Das aufgebaute Framework rund um das Datenformat Unisens hat sich in der Praxis als sehr hilfreich herausgestellt. Wurden die aufgezeichneten Messdaten in früheren Projekten oft proprietär und leider häufig unzureichend dokumentiert abgespeichert, liegen nun alle erfassten Daten im selben Datenformat vor. Durch die vorgesehenen Attribute in der Header-Datei ist eine Dokumentation der wesentlichen Signaleigenschaften ohne großen Aufwand möglich. Die vielfältigen Annotationsmöglichkeiten und die flexible Erweiterung bestehender Datensätze um neue Entries, z. B. mit berechneten Zwischenergebnissen, sprechen ebenfalls für die Verwendung von Unisens. Dies sind gleichzeitig die entscheidenden Vorteile gegenüber dem Quasi-Standard EDF+. Ein weiteres Unterscheidungsmerkmal, das jedoch als Vor- und Nachteil angesehen werden kann, ist die Aufspaltung des Datensatzes in verschiedene Dateien. Durch diese Struktur wird die Gefahr erhöht, einen inkonsistenten Datensatz zu erhalten, wenn einzelne Dateien gelöscht werden. Der entscheidende Vorteil ist aber, dass sich alle diese Dateien auch ohne Bibliothek über Standardprogramme bzw. Standardfunktionen öffnen und editieren lassen.

Ein projektübergreifendes, einheitliches Datenformat ist ausschlaggebend für das gemeinsame Nutzen von Softwarewerkzeugen, ohne unnötige Konvertierungen durchführen zu müssen. Dies wiederum verbessert die Qualität der eingesetzten Werkzeuge, da sie häufiger benutzt werden und einen längeren Lebenszyklus haben. Mit dem EKG-Editor und dem UnisensViewer wurden zwei Werkzeuge geschaffen, die inzwischen seit mehreren Jahren in

der Arbeitsgruppe und bei Projektpartnern erfolgreich eingesetzt werden. Mit der Entwicklung des Unisens-DataPlugins durch National Instruments halten Unisens-Datensätze sogar Einzug in die kommerzielle Software LabVIEW.

Neben diesen großen Anwendungen ist aber auch der Synergieeffekt vieler kleiner, inzwischen entwickelter Tools spürbar. Für Unisens-Dateien implementierte Matlab-Funktionen lassen sich auch für Messdaten anderer Sensoren nutzen, sofern diese im Unisens-Format vorliegen. Auf diese Weise lassen sich auch innerhalb der Arbeitsgruppe bereits implementierte Funktionen austauschen.

Darüber hinaus hat sich die Unisens-Datenbank bei großen Studien bewährt. Wenn beispielsweise Probanden-Informationen in einer Kontextdatei im Datensatz gespeichert sind, lassen sich diese sehr effektiv über die Datenbank durchsuchen. Der entscheidende Vorteil ist, dass die Datenbank einfach mit den tatsächlichen Datensätzen synchron gehalten werden kann. So können jederzeit statistische Informationen abgerufen werden.

7.2 Artefaktbehandlung

Eine Langzeit-EKG-Aufnahme im alltäglichen Umfeld ist immer wieder von Artefakten durchsetzt. Art und Häufigkeit dieser Artefakte sind sehr stark vom verwendeten Aufnahmesystem abhängig: Ein konventionelles Holter-EKG ist zwar bzgl. der geklebten Ag/AgCl-Elektroden besonders artefaktresistent, hier bieten jedoch die Elektrodenkabel eine große Angriffsfläche für die Entstehung von Artefakten. Nicht perfekt positionierte Kabel ziehen an den Elektroden und können, auch aufgrund ihres relativ hohen Eigengewichts, für vermehrte Artefakte bei körperlicher Aktivität sorgen. Bei textilintegrierten Trockenelektroden ist die Artefaktresistenz in erster Linie vom verwendeten Elektrodenmaterial und dem Schnitt des Tragesystems abhängig. Der careMon-Brustgurt mit integriertem EKG-System erwies sich als besonders artefaktresistent.

Das Aufnahmesystem und das Anwendungsszenario bestimmen auch die Art der Artefakte: Bei sportlicher Aktivität sind mehr Bewegungsartefakte zu erwarten, bei passiven Probanden ist eher mit einem Ablösen von Elektroden und der damit verbundenen Einkopplung von Störungen aus dem Versorgungsnetz zu rechnen. Anhand dieser Erfahrungen wird deutlich, wie eng das Anwendungsszenario, das Aufnahmesystem und die Signalanalyse verknüpft sind und somit stets aufeinander abgestimmt sein müssen.

Das zuverlässige Identifizieren von Artefakten ist ein wesentlicher Schritt für eine verbesserte QRS-Erkennung. Bei mehreren unabhängigen EKG-Kanälen ist die Wahrscheinlichkeit groß, dass nicht alle Kanäle gleichzeitig gestört sind. Mit Hilfe der artefaktfreien Kanäle lässt sich das EKG weiterhin analysieren.

Das Hinzuziehen eines Second Channel für die Artefakterkennung brachte in dieser Arbeit zwar eine leichte Verbesserung, jedoch ist der rechnerische und technische Mehraufwand nicht immer gerechtfertigt. Alternativ empfiehlt es sich, die Artefakterkennung allein über das EKG-Signal zu realisieren. Grundsätzlich sollte die Artefakterkennung immer den Aufnahmebedingungen angepasst sein.

Anders sieht es wiederum bei der Reduktion von Artefakten aus: Nutzt man dabei nur das EKG-Signal, besteht die Gefahr, dass eine Pathologie im EKG als Artefakt erkannt und entfernt wird. Setzt man einen Second Channel ein, wird diese Gefahr minimiert. Hier hat sich die Elektrode-Haut-Impedanz als artefaktkorreliertes Signal bewährt und ist einem Bewegungssignal vorzuziehen. Ob sich jedoch der erhöhte Aufwand bzgl. Aufnahmesystem und geteilter EKG-Elektroden rechtfertigt, hängt vom geplanten Einsatzszenario ab. Bei einem 24/7-Screening, wo problemlos auf eine Stunde EKG pro Tag verzichtet werden kann, ist dies sicherlich nicht gegeben. Bei einem telemedizinischen Gerät, das auf lebensgefährliche Rhythmusstörungen reagiert und Hilfe herbeiholen kann, hat eine möglichst vollständige und korrekte EKG-Analyse einen ganz anderen Stellenwert.

7.3 Kontextsensitive Signalanalyse

Von der Artefakterkennung profitiert auch die EKG-Analyse: Ein a-priori-Wissen über Artefakte – also nicht mehr analysierbare EKG-Sequenzen – kann die EKG-Analyse vor einem ungewollten Verändern interner Schwellwerte schützen. Ein Ausblenden der artefaktbehafteten Stellen bedeutet zwar einen bewussten Verzicht auf ein potentielles Analyseergebnis, davon profitiert aber die Glaubwürdigkeit der übrigen Analyse. Die Sequenz, die mit hoher Wahrscheinlichkeit nicht vollständig korrekt analysiert werden kann, wird bewusst nicht ausgewertet und führt somit zu weniger Fehlern. Zudem enthält die Analyse des nachfolgenden Signals weniger Fehler, da sich interne Schwellen nicht aufgrund einer hohen Artefaktamplitude unnötig verändert haben.

Eine Artefakterkennung in Verbindung mit einem darauf abgestimmten QRS-Detektor ist deshalb ein sinnvoller Bestandteil eines Auswertewerkzeugs für Langzeit-EKG-Aufnahmen.

Die Aufzeichnung von Bewegungsinformationen ermöglicht eine EKG-Analyse im Aktivitätskontext. Dies bietet dem befundenden Mediziner zum einen die Möglichkeit, Herzfrequenzveränderungen als angemessen oder unangemessen zu beurteilen, zum anderen können aber auch ganz neue Parameter aus dem EKG extrahiert werden, die auf eine Aktivitätsinformation angewiesen sind. Dazu gehört z. B. die Beurteilung der chronotropen Kompetenz oder das Einschwingverhalten der Herzrate nach einer Belastungsänderung, wie z. B. dem Aufstehen. Mit Hilfe der Sturz-Erkennung können Synkopen leichter gefunden werden, insbesondere, wenn das kardiale Ereignis selbst durch Artefakte überlagert wird.

Die Aktivitätsinformationen können dabei auf unterschiedliche Weise aufbereitet werden. In dieser Arbeit werden vier Aktivitätslevel definiert. Diese verhältnismäßig wenigen Stufen reichen aus, das EKG-Signal in einen Aktivitätskontext zu bringen. Eine weitere Klassifizierung in genaue Aktivitäten bringt in diesem Zusammenhang keinen Mehrwert. Will man allerdings herausfinden, wie stark sich der Patient ausbelasten kann, ist eine Energieumsatzschätzung notwendig. Wenn diese präzise genug ist, kann sie zur weiteren Beurteilung der chronotropen Kompetenz herangezogen werden.

Für ein mobiles System, wie einen dauerhaft tragbaren, externen Defibrillator, sind diese Bewegungsinformationen sehr nützlich. Mit ihrer Hilfe lassen sich Tachykardie-Warnschwellen bei Aktivität nach oben verschieben, sodass es weniger falsch-positive Alarme gibt. Für die Defibrillationserkennung ist die Ruheerkennung ein sehr hilfreiches Instrument, um trotz sensitiver VT/VF-Erkennung keine falsch-positiven Alarme während Bewegungen zu geben.

Die einfach aufgebauten Algorithmen sind für ein mobiles System besonders von Vorteil, da sie sich weniger stark auf die Systemlaufzeit auswirken. Soll ein Langzeit-EKG lediglich offline ausgewertet werden, kann der Einsatz aufwändigerer Verfahren, wie auch einer präzisen Energieumsatzschätzung, interessant sein, da unter diesen Bedingungen die Rechenleistung weniger ausschlaggebend ist.

8 Zusammenfassung und Ausblick

Das EKG ist eine der wichtigsten Untersuchungsmethoden in der Kardiologie. Mit einem sich entwickelnden Trend zu länger andauernden EKG-Aufzeichnungen, wie es in telemedizinischen Szenarien der Fall ist, steigen die Anforderungen an die Auswertungen: Große Mengen anfallender Daten müssen verlässlich automatisch analysiert werden, um weiterhin kostendeckend arbeiten zu können. Diese Arbeit stellt verschiedene Werkzeuge und Methoden vor, um die automatische Analyse von Langzeit-EKG-Aufnahmen unter Hinzunahme von Kontextsignalen zu verbessern.

8.1 Zusammenfassung

Um den Umgang mit Multisensordaten zu erleichtern, wurde im Rahmen dieser Arbeit ein umfassendes Software-Framework spezifiziert und implementiert. Die Basis bildet dabei das Datenformat Unisens 2.0, das besonders auf den Umgang mit annotierten Multisensordaten abgestimmt ist. Für dieses Datenformat wurden Bibliotheken in Java, C# und Matlab erstellt, die das Lesen und Schreiben von Unisens-Daten erleichtern.

Der UnisensViewer kann einen kompletten Unisens-Datensatz über einer gemeinsamen Zeitachse darstellen. Mit Hilfe dieses Werkzeuges können beispielsweise aufgezeichnete Messdaten gesichtet oder berechnete Zwischenergebnisse visualisiert werden. Ein flexibles Plug-in-Interface erlaubt ein einfaches Nachrüsten von weiteren Funktionen, unter anderem ist darüber die Einbindung von Matlab-Code möglich. Der EKG-Editor hat sich als unverzichtbares Werkzeug für die Erstellung von QRS-Referenzannotationen herausgestellt. Die Unisens-Datenbankanbindung für MySQL-Datenbanken erlaubt einen schnellen Zugriff auf alle Metadaten und hilft bei der Datenorganisation großer Studien. Mit diesen Werkzeugen konnte die Entwicklung von Algorithmen für die Datenanalyse effizient durchgeführt werden.

Ein mobil aufgezeichnetes EKG ist häufig durch Artefakte so gestört, dass es nicht mehr analysiert werden kann. In dieser Arbeit werden deshalb EKG-Sequenzen verwendet, die in Alltagssituationen – und nicht unter Laborbedingungen – aufgezeichnet wurden. Für die automatische Artefaktbehandlung wurden Beschleunigungssignale und die Elektrode-Haut-Impedanz auf ihre Tauglichkeit als artefaktkorrelierter Parameter untersucht. Die Bewegungsinformationen lassen sich zwar sehr einfach aufzeichnen und Artefakte finden sich auch überproportional häufig während Bewegungssequenzen, dennoch ist die Elektrode-Haut-Impedanz der geeignetere Parameter für die Artefaktbehandlung. Mit diesem Second Channel konnte ein System vorgestellt werden, das auf Basis der diskreten Wavelet-Transformation eine zeit- und frequenzselektive Artefaktreduktion vornimmt und dadurch das Auftreten von Fehldetektionen um 35 % reduzieren konnte.

Die Artefakterkennung kann zwar durch Kontextsignale gestützt werden, dies bringt aber keinen signifikanten Vorteil gegenüber Verfahren, die nur das EKG auswerten. Viel entscheidender ist das Nutzen der Artefaktinformationen für die automatische QRS-Erkennung: Es konnte gezeigt werden, dass ein bewusster Verzicht der Analyse von artefaktbehafteten EKG-Sequenzen das Ergebnis der QRS-Detektion auf dem restlichen Datensatz nachweislich verbessert.

Um das EKG in den Aktivitätskontext stellen zu können, wurde eine einfache Aktivitätsklassifizierung implementiert, die die körperliche Aktivität in vier Stufen einteilt: keine, geringe, mittlere und hohe Aktivität. Die unteren beiden Stufen beinhalten passive Bereiche wie Liegen, Sitzen und Stehen, während die beiden oberen Stufen aktive Bereiche mit verschieden hoher körperlicher Auslastung kennzeichnen. Zusätzlich werden Stürze und Aufstehen als Ereignisse erkannt. Mit diesen Informationen kann sowohl das EKG und insbesondere die Herzrate in einen Aktivitätskontext gestellt als auch die kardiale Reaktion auf bestimmte Ereignisse wie z. B. das Aufstehen analysiert werden. Auf diese Weise lassen sich neue EKG-relevante Parameter gewinnen.

Die gewonnenen Erkenntnisse werden schließlich mit Hilfe eines Reportgenerators zusammengeführt, der für 24/7-EKG-Aufnahmen einen umfassenden Bericht erstellt. Pro Tag werden auf zwei Seiten Herzrate, Rhythmusstörungen und Aktivitätsinformationen über einer gemeinsamen Zeitachse dargestellt und zeigen dem Mediziner auf einen Blick alle Auffälligkeiten. Ebenso können die Ergebnisse des Berichts in den zuvor genannten Software-Werkzeugen betrachtet werden.

8.2 Ausblick

Diese Arbeit stellt einen relativ breiten Überblick dar, inwieweit aufgezeichnete Kontextsignale die Analyse einer Langzeit-EKG-Aufnahme verbessern können. Die vorgestellten Verfahren können in Zukunft weiter optimiert werden und müssen sich dem Praxistest stellen.

Die EKG-Analyse im Aktivitätskontext bietet das Potential für neue Parameter zur Beurteilung des Gesundheitszustandes, insbesondere die kardiale Reaktion auf Belastungsänderung sollte weiter untersucht werden. In diesem Zusammenhang ist auch eine präzise Energieumsatzschätzung eine interessante Ergänzung. Da bereits die ersten Holter-Rekorder mit integriertem Beschleunigungssensor erhältlich sind, wird an dieser Stelle das größte Marktpotential gesehen.

Mit dem Hinzufügen weiterer Sensordaten kann insbesondere die Bewegungs- und Aktivitätserkennung verbessert werden. Genannt werden können an dieser Stelle Gyroskop und barometrischer Höhsensor. Mit ersterem können Stürze präziser erfasst werden, letzterer ist für die Energieumsatzschätzung interessant, aber auch die Detektion von Stürzen könnte dadurch verbessert werden.

Das Datenformat Unisens hat sich zunehmend in der Arbeitsgruppe etabliert und wird auch darüber hinaus eingesetzt. Da die Java-Bibliothek für den Unisens-Datenzugriff als Open-Source-Projekt zur Verfügung steht und das Datenformat sowohl von kommerziellen Sensoren als auch von kommerzieller Software unterstützt wird, kann davon ausgegangen werden, dass es auch in Zukunft gepflegt wird.

Literaturverzeichnis

- [Afo99] AFONSO, V.X.; TOMPKINS, W.J.; NGUYEN, T.Q. und LUO, Shen: ECG beat detection using filter banks. *Biomedical Engineering, IEEE Transactions on* (1999), Bd. 46(2): S. 192 –202
- [Art91] ARTIS, S.G.; MARK, R.G. und MOODY, G.B.: Detection of Atrial Fibrillation using Artificial Neural Networks, in: *IEEE Proceedings on Computers in Cardiology*, S. 173–176
- [Bar98] BARRO, S.; FERNANDEZ-DELGADO, M.; VILA-SOBRINO, J.A.; REGUEIRO, C.V. und SANCHEZ, E.: Classifying multichannel ECG patterns with an adaptive neural network. *Engineering in Medicine and Biology Magazine, IEEE* (1998), Bd. 17(1): S. 45 –55
- [Bec10] BECKER, Ansgar; DINDORP, David; TEIXEIRA, Francisco Ernesto; NIJENHOF, Martijn; LORENZ, Sven; GERHARDT-PEDERSEN, Mikkel M. und PENG, Tony: HeidiSQL : A Lightweight MySQL Client (2010), URL <http://www.heidisql.com>
- [Beh10] BEHRENDTS ET. AL.: *Duale Reihe Physiologie*, Georg Thieme Verlag, 1. Aufl. (2010)
- [Ben95] BENSADOUN, Y.; NOVAKOV, E. und RAOOF, K.: Multidimensional adaptive method for cancelling EMG signal from the ECG signal, in: *Engineering in Medicine and Biology Society, 1995., IEEE 17th Annual Conference*, Bd. 1, Montreal, Que., S. 173–174
- [Ber09] BERTSCHI, Mattia und ROSSINI, Leopoldo: Wrist-Worn Fall Detection Device, in: *Biosignals 2009 : Second International Conference on Biomedical Electronics and Devices*, S. 368–371
- [Big04] BIGAN, C. und WOOLFSON, M.: Independent component extraction methods in biosignal processing, in: *26th Annual International Conference of the Engineering in Medicine and Biology Society*, Bd. 1, S. 511–513
- [Bol02] BOLZ, Armin und URBASZEK, Wilhelm: *Technik in der Kardiologie: Eine interdisziplinäre Darstellung für Ingenieure und Mediziner*, Springer, Berlin; Heidelberg; New York u.a., 1. auflage Aufl. (2002)

- [Bro00] BRONZINO, Joseph D. (Herausgeber): *The biomedical engineering handbook*, CRC Press, 2. auflage Aufl. (2000)
- [Bro06] BROUSE, C.; DUMONT, G.A.; HERRMANN, F.J. und ANSERMINO, J.M.: A wavelet approach to detecting electrocautery noise in the ECG. *IEEE Engineering in Medicine and Biology Magazine* (2006), Bd. 25(4): S. 76–82
- [cam] CAMNTECH: *Heart Rate Variability, Sleep Analysis and Energy Expenditure with Actiwave CardioTM and Cardio Viewer Software*, camNtech
- [Cam77] CAMPBELL, Steven D; KRANING, Kenneth K; SCHIBLI, Eugen G und MO-MII, Steven T: Hydration Characteristics and Electrical Resistivity of Stratum Corneum Using a Noninvasive Four-point Microelectrode Method. *Journal of Investigative Dermatology* (1977), Bd. 69: S. 290–295
- [Che07] CHEN, X.; HO, C. T.; LIM, E. T. und KYAW, T. Z.: Cellular phone based online ECG processing for ambulatory and continuous detection, in: *Computers in Cardiology*, Durham, NC, S. 653–656
- [Chi90] CHIA, C. W.; GREENWALD, S. D. und MARK, R. G.: A comparison of human experts and computer algorithms in detecting and classifying beats in noise-corrupted electrocardiograms, in: *Computers in Cardiology 1990, Proceedings.*, Chicago, IL, S. 465–468
- [Chi07] CHIARUGI, F.; SAKKALIS, V.; EMMANOUILIDOU, D.; KRONTIRIS, T.; VARANINI, M. und TOLLIS, I.: Adaptive Threshold QRS Detector with Best Channel Selection Based on a Noise Rating System, in: *Computers in Cardiology*, 34, S. 157–160
- [Chr04] CHRISTOV, Ivaylo: Real time electrocardiogram QRS detection using combined adaptive threshold. *BioMedical Engineering OnLine* (2004), Bd. 3(1): S. 28, URL <http://www.biomedical-engineering-online.com/content/3/1/28>
- [Chu89] CHU, C.-H.H. und DELP, E.J.: Impulsive noise suppression and background normalization of electrocardiogram signals using morphological operators. *IEEE Transactions on Biomedical Engineering* (1989), Bd. 36(2): S. 262–273
- [Cla93] CLAYTON, R.H.; MURRAY, A. und CAMPBELL, R.W.: Comparison of four techniques for recognition of ventricular fibrillation from the surface ECG. *Med Biol Eng Comput* (1993), Bd. 31: S. 111–117
- [Dev84] DEVLIN, Philp H.; MARK, Roger G. und KETCHUM, John W.: Detecting

- electrode motion noise in ecg signals by monitoring electrode impedance, in: *Computers in Cardiology, 1984*, S. 51–56
- [Dha07] DHARMADJI, Arnold: *Entwicklung von Algorithmen zur Unterscheidung von aktiven und passiven Körperbewegungen*, Studienarbeit, Universität Karlsruhe (TH) (2007)
- [Dju05] DJUWARI, D.; KUMAR, D.K. und PALANISWAMI, M.: Limitations of ICA for Artefact Removal, in: *27th Annual International Conference of the Engineering in Medicine and Biology Society*, S. 4685–4688
- [DRK98] DRK-LANDESVERBAND NIEDERSACHSEN E. V.: *Notfallrettung und qualifizierter Krankentransport : ein Lehrbuch (nicht nur) für angehende Rettungssanitäterinnen und Rettungssanitäter*, DRK-Landesverb. Niedersachsen, Rettungsssschule Goslar, Goslar, 2., überarb. Aufl. (1998)
- [dT96] DE TALHOUE, Hughes und WEBSTER, John G.: The origin of skin-stretch-caused motion artifacts under electrodes. *Physiological Measurement* (1996), Bd. 17: S. 81–93
- [Dub08] DUBOIS, Paul: *MySQL*, Addison-Wesley, 4. Aufl. (2008)
- [DV84] DE VEL, Olivier Y.: R-Wave Detection in the Presence of Muscle Artifacts. *IEEE Transactions on Biomedical Engineering* (1984), Bd. 31(11): S. 715–717
- [Fal04] FALLER, Adolf und SCHÜNKE, Michael: *Der Körper des Menschen*, Georg Thieme Verlag, 14 Aufl. (2004)
- [Fis10] FISCHER, W.-J.; HOLLAND, H.-J.; HEINIG, A. und ZAUNSEDER, S.: 3-Kanal EKG-Gerät für die Langzeitüberwachung mit integrierter EKG-Vorauswertung und Bewegungsmustererkennung, in: *Biomed Tech 2010*
- [Fot00] FOTUHI, Parwis; COMBS, William; SHELDON, Todd; THERES, Heinz; STANGL, Karl und BAUMANN, Gert: Utility of an accelerometer sensor integrated into a Holter monitoring system. *Annals of noninvasive electrocardiology* (2000), Bd. 5(1): S. 73–78
- [Fri90] FRIESEN, M., G.; JANNETT, C., T.; JADALLAH, A., M.; YATES, L., S.; QUINT, R., S. und NAGLE, T., H.: A Comparison of the Noise Sensitivity of Nine QRS Detection Algorithms. *IEEE Transactions on Biomedical Engineering* (1990), Bd. 37(1): S. 85–98
- [Fuh09] FUHRHOP, Silvester; LAMPARTH, Stefan; KIRST, Malte; VON WAGNER, Gero und OTTENBACHER, Jörg: Ambulant ECG Recording with Wet and Dry Electrodes: A Direct Comparison of two Systems, in:

- O. Dössel und W. C. Schlegel (Herausgeber) *IFMBE Proceedings*, Bd. 25, S. 305–307
- [Fuh10] FUHRHOP, Silvester und LAMPARTH, Stefan: careMon (2010), hausinterne Mitteilung
- [Get] URL <http://de.red-dot.org/>
- [GN03] GÖTZ-NEUMANN, Kirsten: *Gehen verstehen*, Georg Thieme Verlag (2003)
- [Gon99] GONSKA, Bernd-Dieter und HEINECKER, Rolf: *EKG in Klinik und Praxis: Das Referenzwerk zur elektrokardiographischen Diagnostik*, Georg Thieme Verlag, Stuttgart, New York, 14. Aufl. (1999)
- [Gri97] GRIMM, W. und KÖHLER, U.: Das Langzeit-EKG, in: *Der Internist*, Bd. 38, Springer, S. 742–746
- [Gri00] GRIMNES, Sverre und MARTINSEN, Ørjan G.: *Bioimpedance and bioelectricity basics*, Academic Press, London (2000)
- [Ham97] HAMILTON, P. S. und CURLEY, M. G.: Adaptive removal of motion artifact, in: *Proceedings of the 19th Annual International Conference of the IEEE Engineering in Medicine and Biology society*, Bd. 1, Chicago, IL, USA, S. 297–299
- [Ham00a] HAMILTON, P. S.; CURLEY, M. G.; AIMI, R. M. und SAE-HAU, C.: Comparison of methods for adaptive removal of motion artifact, in: *Computers in Cardiology 2000*, IEEE, Cambridge, MA, S. 383–386
- [Ham00b] HAMILTON, Patrick S.; CURLEY, Micheal und AIMI, Roberto: Effects of Adaptive Motion-Artifact Reduction on QRS-Detection, in: *Biomedical instrumentation & technology: BI&T / Association for the Advancement of Medical Instrumentation*, Hanley & Belfus, Philadelphia, S. 197–202
- [Ham02] HAMILTON, P.: Open source ECG analysis, in: *Computers in Cardiology*, S. 101–104
- [Har02] HARLAND, C. J.; CLARK, T. D. und PRANCE, R. J.: Remote detection of human electroencephalograms using ultrahigh input impedance electric potential sensors, in: *Applied Physics Letters*, Bd. 81, 17, S. 3284–3286
- [Har04] HARLAND, C. J.; CLARK, T. D. und PRANCE, R. J.: Non-invasive Human Body Electrophysiological Measurements using Displacement Current Sensors, in: *International workshop on wearable and implantable body sensor networks*, London
- [Hea05] HEALEY, Jennifer und LOGAN, Beth: Wearable Wellness Monitoring

- Using ECG and Accelerometer Data. *Wearable Computers, IEEE International Symposium* (2005), Bd. 0: S. 220–221
- [Hoh05] HOHNLOSER, Stefan; GRÖNEFELD, Gerian und ISRAEL, Carsten W.: *Prohylaxe und Therapie von Vorhofflimmern*, UNI-MED, 1 Aufl. (2005)
- [Hol61] HOLTER, Norman J.: New Method for Heart Studies: Continuous electrocardiography of active subjects over long periods is now practical. *Science* (1961), Bd. 134(3486): S. 1214–1220
- [iC05] I CARÓS, J. Solà; CHÉTELAT, O.; CELKA, Patrick und DASEN, S.: Very Low Complexity Algorithm for Ambulatory Activity Classification, in: *European Medical & Biological Engineering Conference and IFMBE European Conference on Biomedical Engineering*
- [Ira02] IRAVANIAN, S. und TUNG, L.: A novel algorithm for cardiac biosignal filtering based on filtered residue method. *IEEE Transactions on Biomedical Engineering* (2002), Bd. 49: S. 1310–1317
- [Jäc08] JÄCKEL, Achim: *Telemedizinführer Deutschland* (2008), URL <http://www.telemedizinfuhrer.de>
- [Jan92] JANE, R.; LAGUNA, P.; THAKOR, N. V. und CAMINAL, P.: Adaptive baseline wander removal in the ECG: Comparative analysis with cubic spline technique, in: *Computers in Cardiology 1992. Proceedings.*, IEEE, Durham, NC, S. 143–146
- [Jat07a] JATOBÁ, L.; GROSSMANN, U.; OTTENBACHER, J.; STORK, W. und MÜLLER-GLASER, K.: Development of a Self-Constructing Neuro-Fuzzy Inference System for Online Classification of Physical Movements, in: *e-Health Networking, Application and Services, 2007 9th International Conference on*, Taipei, Taiwan, S. 332–335
- [Jat07b] JATOBÁ, Luciana; KLEIN, T.; STORK, W. und MÜLLER-GLASER, K.: Including Physical Activity Information into Cardiac Diagnostic Systems, in: *Biomedizinische Technik*, Bd. 52
- [Jat10] JATOBÁ, Luciana: *Assessment of Human Physical Activity Using Mobile Sensors*, Dissertation, Karlsruher Institut für Technologie (KIT) (2010)
- [Jek00] JEKOVA, I.: Comparison of five algorithms for the detection of ventricular fibrillation from the surface ECG. *Physiol Meas* (2000), Bd. 21: S. 429–439
- [Jek04] JEKOVA, I. und KRASTEVA, V.: Real time detection of ventricular fibrillation and tachycardia. *Physiol Meas* (2004), Bd. 25: S. 1167–1178
- [Jek08] JEKOVA, I.; BORTOLAN, G. und CHRISTOV, I.: Assessment and compa-

- parison of different methods for heartbeat classification. *Med Eng Phys* (2008), Bd. 30: S. 248–257
- [Kai09] KAISER, Stefanie; KIRST, Malte und KUNZE, Christophe: Automatic Detection of Atrial Fibrillation and Flutter, in: *BIOSIGNALS 2009 : Second International Conference on Bio-inspired Systems and Signal Processing*, Porto
- [Kai10] KAISER, Stefanie; KIRST, Malte und KUNZE, Christophe: Automatic Detection of Atrial Fibrillation for Mobile Devices, in: Ana Fred; Joaquim Filipe und Hugo Gamboa (Herausgeber) *Biomedical Engineering Systems and Technologies*, Bd. 52 von *Communications in Computer and Information Science*, Springer Berlin Heidelberg (2010), S. 258–270, URL http://dx.doi.org/10.1007/978-3-642-11721-3_20, 10.1007/978-3-642-11721-3_20
- [KB10] KRÜGER-BRAND, Heike und OSTERLOH, Falk: Telemedizinstudie: Patientenauswahl ist wichtig. *Deutsches Ärzteblatt* (2010), Bd. 48: S. B2060–B2061
- [Kem92] KEMP, B.; VÄRRI, A.; ROSA, A.C.; NIELSEN, K.D. und GADE, J.: A simple format for exchange of digitized polygraphic recordings. *Electroencephalogr Clin Neurophysiol* (1992), Bd. 82: S. 391–393
- [Kem03] KEMP, B. und OLIVAN, J.: European data format 'plus' (EDF+), an EDF alike standard format for the exchange of physiological data. *Clin Neurophysiol* (2003), Bd. 114: S. 1755–1761
- [Kim06] KIM, Hyun; MIN, Chul und KIM, Tae: Adaptable Noise Reduction of ECG Signals for Feature Extraction, in: Jun Wang; Zhang Yi; Jacek Zurada; Bao-Liang Lu und Hujun Yin (Herausgeber) *Advances in Neural Networks - ISNN 2006*, Bd. 3973 von *Lecture Notes in Computer Science*, Springer Berlin / Heidelberg (2006), S. 586–591, URL http://dx.doi.org/10.1007/11760191_86
- [Kir08a] KIRST, Malte und OTTENBACHER, Jörg: Unisens – a universal data format (2008), URL <http://www.unisens.org>
- [Kir08b] KIRST, Malte; OTTENBACHER, Jörg und NEDKOV, Radoslav: UNISENS – Ein universelles Datenformat für Multisensordaten, in: *Tagungsband Biosignalverarbeitung*, Universität Potsdam, S. 106–108
- [Kir09] KIRST, Malte; LAMPARTH, Stefan; FUHRHOP, Silvester; OTTENBACHER, Jörg und KUNZE, Christophe: Transferring an Artifact Handling System into a Mobile Long-term ECG Device with Dry Electrodes, in: O. Dössel und W. C. Schlegel (Herausgeber) *IFMBE Proceedings*,

- Bd. 25, S. 942–945
- [Kir10a] KIRST, Malte; OTTENBACHER, Jörg; FUHRHOP, Silvester; LAMPARTH, Stefan und KUNZE, Christophe: Kontextsignale zur Verbesserung der automatischen EKG-Analyse in Telemonitoringsystemen, in: Frank Duesberg (Herausgeber) *e-Health 2011 : Informationstechnologien und Telematik im Gesundheitswesen*, Medical Future Verlag (2010), S. 303–306
- [Kir10b] KIRST, Malte; OTTENBACHER, Jörg; LAMPARTH, Stefan; FUHRHOP, Silvester und STORK, Wilhelm: The Use of Body Acceleration and Electrode-skin Impedance Data for ECG Analysis in Telemonitoring Systems, in: Walter de Gruyter (Herausgeber) *Biomed Tech 2010*, Bd. 55
- [Kir11] KIRST, Malte; GLAUNER, Bastian und OTTENBACHER, Jörg: Using DWT for ECG Motion Artifact Reduction with Noise-correlating Signals, in: *33rd Annual International Conference of the IEEE EMBS, Boston, Massachusetts USA, August 30 - September 3*, S. 4804–4807
- [Kis07] KISHIMOTO, Y.; KUTSUNA, Y. und OGURI, K.: Detecting Motion Artifact ECG Noise During Sleeping by Means of a Tri-axis Accelerometer, in: *Engineering in Medicine and Biology Society, 2007. EMBS 2007. 29th Annual International Conference of the IEEE*, S. 2669–2672
- [Kog05] KOGLEK, W. und BRANDL, J.: *Herzschrittmacher- und Defibrillator-Therapie: Indikation – Programmierung – Nachsorge*, Kap. ICD-Detektionsalgorithmen, Georg Thieme Verlag (2005), S. 354–380
- [Koh02] KOHLER, B. U.; HENNIG, C. und ORGLMEISTER, R.: The principles of software QRS detection. *IEEE Engineering in Medicine and Biology Magazine* (2002), Bd. 21(1): S. 42–57
- [Lam09] LAMPARTH, Stefan; FUHRHOP, Silvester; KIRST, Malte; VON WAGNER, Gero und OTTENBACHER, Jörg: A Mobile Device for Textile-integrated Long-term ECG Monitoring, in: O. Dössel und W. C. Schlegel (Herausgeber) *IFMBE Proceedings*, Bd. 25, S. 278–281
- [Lam10] LAMPARTH, Stefan; FUHRHOP, Silvester und KIRST, Malte: Kontinuierliches EKG-Monitoring mit integrierter Frühdefibrillation, *Medica Media Forum – Young Potential Nachwuchspreis* (2010)
- [Lee09] LEE, S.-Y.; SCHULTZ, C.; MURIN, M. und KORB, H.: Bedeutung Telemedizinischer Service Center für die Arzt-Patienten-Beziehung : Mehr Nähe statt Ferne?, in: *Telemedizinführer Deutschland, Ausgabe 2009*, Achim Jäckel (Hrsg.), 10. Aufl. (2009), S. 100–104

- [Leu11] LEUENBERGER, Kaspar und GASSERT, Roger: Low-Power Sensor Module for Long-Term Activity Monitoring, in: *33rd Annual International Conference of the IEEE EMBS*, S. 2237–2241
- [Li95] LI, Cuiwei; ZHENG, Chongxun und TAI, Changfeng: Detection of ECG characteristic points using wavelet transforms. *Biomedical Engineering, IEEE Transactions on* (1995), Bd. 42(1): S. 21 –28
- [Li07] LI, Huaming und TAN, Jindong: Body Sensor Network Based Context Aware QRS Detection, in: *Pervasive Health Conference and Workshops*, Innsbruck, S. 1–8
- [Liu06] LIU, Yan und PECHT, Michael G.: Reduction of Skin Stretch Induced Motion Artifacts in Electrocardiogram Monitoring Using Adaptive Filtering, in: *Engineering in Medicine and Biology Society, 2006. EMBS '06. 28th Annual International Conference of the IEEE*, S. 6045–6048
- [Liu11] LIU, Shing-Hong: Motion Artifact Reduction in Electrocardiogram Using Adaptive Filter. *Journal of Medical and Biological Engineering* (2011), Bd. 31: S. 64–72
- [Lö99] LÖLLGEN, Herbert: Chronotrope Inkompetenz. *Deutsches Ärzteblatt* (1999), Bd. 33: S. A–2089–A–2092
- [Log05] LOGAN, B. und HEALEY, J.: Robust Detection of Atrial Fibrillation for a Long Term Telemonitoring System, in: *IEEE Computers in Cardiology*, S. 391–394
- [Lov10] LOVELL, N.H.; REDMOND, S.J.; BASILAKIS, J. und CELLER, B.G.: Biosignal quality detection: An essential feature for unsupervised telehealth applications, in: *e-Health Networking Applications and Services (Healthcom), 2010 12th IEEE International Conference on*, S. 81–85
- [Luo95] LUO, Shen und TOMPKINS, Willis J: Experimental Study: Brachial Motion Artifact Reduction in the ECG, in: *Computers in Cardiology*, IEEE, S. 33–36
- [Mai04] MAIER, Robert und KRAXNER, Wilfried: Langzeit-EKG in der Praxis. *Ärztetmagazin* (2004), Bd. 37, URL <http://www.aerztetmagazin.at/dynasite.cfm?dsmid=60653&dspaid=435744>
- [Mal95] MALMIVUO, Jaakko und PLONSEY, Robert: *Bioelectromagnetism – Principles and Applications of Bioelectric and Biomagnetic Fields*, Oxford University Press (1995), URL <http://www.bem.fi/book/index.htm>
- [Med06] MEDSET MEDIZINTECHNIK GMBH: Webseite der Firma Medset Medizintechnik GmbH (2006), URL <http://www.medset.com>

- [Mil83] MILLINGTON, P. F. und WILKINSON, R.: *Skin*, Cambridge University Press, Cambridge, London, New York, New Rochelle, Melbourne, Sydney (1983)
- [Mil06] MILANESI, M.; MARTINI, N.; VANELLO, N.; POSITANO, V.; SANTARELLI, M. F.; PARADISO, R.; DE ROSSI, D. und LANDINI, L.: Multichannel Techniques for Motion Artifacts Removal from Electrocardiographic Signals, in: *Engineering in Medicine and Biology Society, 2006. EMBS '06. 28th Annual International Conference of the IEEE*, S. 3391–3394
- [Mil08] MILANESI, M.; MARTINI, N.; VANELLO, N.; POSITANO, V.; SANTARELLI, M. F. und LANDINI, L.: Independent component analysis applied to the removal of motion artifacts from electrographic signals. *Med Biol Eng Comput* (2008), Bd. 46: S. 251–261
- [Moo82] MOODY, George B. und MARK, Roger G.: Development and evaluation of a 2-Lead ECG analysis program, in: *Computers in Cardiology, 1882*, Massachusetts Institute of Technology, Cambridge, S. 39–44
- [Moo08] MOODY, George B.: WFDB Programmer's Guide, <http://www.physionet.org/physiotools/manuals.shtml> (2008)
- [Mos00] MOSCHYTZ, George S. und HOFBAUER, Markus: *Adaptive Filter: Eine Einführung in die Theorie mit Aufgaben und MATLAB-Simulationen auf CD-ROM*, Springer, Berlin, Heidelberg, New York (2000)
- [mov] MOVISENS: movisens GmbH, URL <http://www.movisens.com/>
- [Müh04] MÜHLSTEFF, J.; SUCH, O.; SCHMIDT, R.; PERKUHN, M.; REITER, H.; LAUTER, J.; THIJS, J.; MUSCH, G. und HARRIS, M.: Wearable approach for continuous ECG- and activity patient-monitoring, in: *26th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, San Francisco, CA, S. 2184–2187
- [Mül09a] MÜLLER, A.; NEUZNER, J.; OEFF, M.; PFEIFFER, D.; SACK, S.; SCHWAB, J. O. und ZUGCK, C.: VDE/DGK-Thesenpapier TeleMonitoring-Systeme in der Kardiologie, Frankfurt am Main (2009)
- [Mül09b] MÜLLER, Axel; SCHWAB, Jörg Otto; OEFF, Michael; HELMS, Thomas M.; PFEIFFER, Dietrich; SACK, Stefan und ZUGCK, Christian: Telemedizin in der Kardiologie 2010 – Möglichkeiten und Perspektiven, in: Frank Duesberg (Herausgeber) *e-Health 2010 : Informationstechnologien und Telematik im Gesundheitswesen*, Medical Future Verlag, Solingen (2009), S. 183–189
- [MW85] MEYER-WAARDEN, Karsten: *Bioelektrische Signale und ihre Ableitver-*

- fahren*, Schattauer, 1 Aufl. (1985)
- [Nou07] NOURY, N.; FLEURY, A.; RUMEAU, P.; BOURKE, A. K.; LAIGHIN, G. O.; RIALLE, V. und LUNDY, J. E.: Fall detection – Principles and Methods, in: *Engineering in Medicine and Biology Society, 2007. EMBS 2007. 29th Annual International Conference of the IEEE*, Lyon, S. 1663–1666
- [Ohl08] OHLY, Albrecht: *EKG endlich verständlich*, Elsevier Academic Press (2008)
- [Ora10] ORACLE: MySQL : Die populärste Open-Source-Datenbank der Welt (2010), URL <http://www.mysql.de>
- [Ott06] OTTENBACHER, Jörg; JATOBÁ, Luciana; GROßMANN, Ulrich; STORK, Wilhelm und MÜLLER-GLASER, Klaus: ECG electrodes for a context-aware cardiac permanent monitoring system, in: *World Congress on Medical Physics and Biomedical Engineering*, Seoul
- [Ott08a] OTTENBACHER, Jörg; KIRST, Malte; JATOBÁ, Luciana; GROßMANN, Ulrich und HUFLEJT, Michal: Artefakterkennung für ambulante EKG-Monitoring-Systeme, in: *Tagungsband Biosignalverarbeitung*, Universität Potsdam, S. 52–54
- [Ott08b] OTTENBACHER, Jörg; KIRST, Malte; JATOBÁ, Luciana; HUFLEJT, Michal; GROßMANN, Ulrich und STORK, Wilhelm: Reliable Motion Artifact Detection for ECG Monitoring Systems with Dry Electrodes. *Conf Proc IEEE Eng Med Biol Soc* (2008), Bd. 2008: S. 1695–1698
- [Ott10] OTTENBACHER, Jörg: *Mobile Langzeit-EKG-Messung : Elektroden und Methoden zum Umgang mit Artefakten*, Dissertation, Universität Karlsruhe (2010)
- [Pah84] PAHLM, O. und SÖRNMO, L.: Software QRS detection in ambulatory monitoring – a review. *Medical and Biological Engineering and Computing* (1984), Bd. 22: S. 289 – 297
- [Pal09] PALAZZOLO, James Adam; BERGER, Ronald D.; HALPERIN, Henry R. und SHERMAN, Darren R.: System for estimating the actual ECG of a patient during CPR (2009)
- [Pan85] PAN, J. und TOMPKINS, W. J.: A real-time QRS detection algorithm. *IEEE Transactions on Biomedical Engineering* (1985), Bd. 3: S. 230–236
- [Paw07a] PAWAR, T.; ANANTAKRISHNAN, N. S.; CHAUDHURI, S. und DUTTA-GUPTA, S. P.: Impact Analysis of Body Movement in Ambulatory ECG, in: *Engineering in Medicine and Biology Society, 2007. EMBS 2007. 29th Annual International Conference of the IEEE*, Lyon, S.

5453–5456

- [Paw07b] PAWAR, T.; ANANTAKRISHNAN, N. S.; CHAUDHURI, S. und DUTTAGUPTA, S. P.: Transition Detection in Body Movement Activities for Wearable ECG. *IEEE Transactions on Biomedical Engineering* (2007), Bd. 54: S. 1149–1152
- [Paw07c] PAWAR, Tanmay; CHAUDHURI, Subhasis und DUTTAGUPTA, Siddhartha P.: Body Movement Activity Recognition for Ambulatory Cardiac Monitoring. *IEEE Transactions on Biomedical Engineering* (2007), Bd. 54(5): S. 874–882
- [Pez04] PEZAWAS, T. und SCHMIDINGER, H.: Effiziente Synkopenabklärung: Wann soll der implantierbare Loop-Rekorder verwendet werden? *Journal of Cardiology* (2004), Bd. 11: S. 353–358
- [Rap04] RAPHISAK, P.; SCHUCKERS, S.C. und DE JONGH CURRY, A.: An algorithm for EMG noise detection in large ECG data, in: *Computers in Cardiology, 2004*, S. 369–372
- [Ray02] RAYA, M.A.D. und SISON, L.G.: Adaptive noise cancelling of motion artifact in stress ECG signals using accelerometer, in: *[Engineering in Medicine and Biology, 2002. 24th Annual Conference and the Annual Fall Meeting of the Biomedical Engineering Society] EMBS/B-MES Conference, 2002. Proceedings of the Second Joint*, Bd. 2, S. 1756–1757
- [Red08] REDMOND, Stephen J.; LOVELL, Nigel H.; BASILAKIS, Jim und CELLER, Branko G.: ECG quality measures in telecare monitoring, in: *Engineering in Medicine and Biology Society, 2008. EMBS 2008. 30th Annual International Conference of the IEEE*, S. 2869 –2872
- [Rei11] REIN, Benjamin: *Früherkennung von Herz-Kreislauf-Erkrankungen durch 24/7 EKG-Monitoring*, Bachelorarbeit, Karlsruher Institut für Technologie (2011)
- [San95] SANDVIK, L.; ERIKSSON, J.; ELLESTAD, M.; ERIKSSON, G.; THAULOW, E.; MUNDAL, R. und RODAHL, K.: Heart rate increase and maximal heart rate during exercise as predictors of cardiovascular mortality: a 16-year follow-up study of 1960 healthy men. *Coron. Artery Dis.* (1995), Bd. 6: S. 667–679
- [Sch05] SCHUSTER, Hans-Peter und TRAPPE, Hans-Joachim: *EKG-Kurs für Isabel*, Georg Thieme Verlag, 4., überarb. und erw. Aufl. Aufl. (2005)
- [Sch08] SCHWAB, Jörg O.; MÜLLER, Axel; OEFF, Michael; NEUZNER, Jörg; SACK, Stefan; PFEIFFER, Dietrich und ZUGCK, Christian: Telemedizin in

- der Kardiologie – Relevanz für die Praxis?! *Herz* (2008), Bd. 33(6): S. 420–430
- [Sch09] Schiller AG, Switzerland: *The next generation – SCHILLER medilog Holter* (2009)
- [Sea00] SEARLE, A. und KIRKUP, L.: A direct comparison of wet, dry and insulating bioelectric recording electrodes. *Physiological Measurement* (2000), Bd. 21: S. 271–283
- [Sil03] SILBERNAGL, Stefan und DESPOPOULOS, Agamemnon: *Taschenatlas der Physiologie*, Georg Thieme Verlag, 6., korr. Aufl. Aufl. (2003)
- [Sör05] SÖRNMO, Leif und LAGUNA, Pablo: *Bioelectrical Signal Processing in Cardiac and Neurological Applications*, Elsevier Academic Press (2005)
- [Spi09] SPINDLER, Jutta und SCHELHASE, Torsten: Krankenhauslandschaft im Umbruch. *Wirtschaft und Statistik* (2009), Bd. 7: S. 641–659
- [Sta06] STATISTISCHES BUNDESAMT: Todesursachenstatistik, Jahr 2005: Pressemitteilung vom 15. September 2006 (2006), URL <http://www.destatis.de/presse/deutsch/pm2006/p3830092.htm>
- [Suc06] SUCH, Olaf und MUEHLSTEFF, Jens: The Challenge of Motion Artifact Suppression in Wearable Monitoring Solutions, in: *Proceedings of the 3rd IEEE-EMBS, International Summer School and Symposium on Medical Devices and Biosensors*, S. 49–52
- [Tam77] TAM, Hakw. und WEBSTER, John G.: Minimizing Electrode Motion Artifact by Skin Abrasion. *IEEE Transactions on Biomedical Engineering* (1977), Bd. 24(2): S. 134–139
- [Tat00] TATENO, K. und GLASS, L.: A Method for Detection of Atrial Fibrillation using RR Intervals, in: *IEEE Computers in Cardiology*, S. 391–294
- [Tha91] THAKOR, N.V. und ZHU, Y.-S.: Applications of adaptive filtering to ECG analysis: noise cancellation and arrhythmia detection. *IEEE Transactions on Biomedical Engineering* (1991), Bd. 38(8): S. 785–794
- [Ton02] TONG, D.A.; BARTELS, K.A. und HONEYAGER, K.S.: Adaptive reduction of motion artifact in the electrocardiogram, in: *[Engineering in Medicine and Biology, 2002. 24th Annual Conference and the Annual Fall Meeting of the Biomedical Engineering Society] EMBS/BMES Conference, 2002. Proceedings of the Second Joint*, Bd. 2, S. 1403–1404
- [vW05] VON WAGNER, G.; HAASE, D.; HAAS, M.; KIRST, M.; HEY, S.; STORK, W. und MÜLLER-GLASER, K.-D.: Reliable ECG Beat Detection with

- [vW06] Neuro-Fuzzy-Systems, in: 6. Würzburger Medizintechnik Kongress
VON WAGNER, Gero: *Entwicklung von Methoden zur Echtzeitanalyse von EKG-Signalen mit Neuro-Fuzzy-Systemen für Anwendungsszenarien der Telemedizin*, Dissertation, Universität Fridericiana Karlsruhe (2006)
- [Web84] WEBSTER, John G.: Reducing Motion Artifacts and Interference in Biopotential Recording. *IEEE Transactions on Biomedical Engineering* (1984), Bd. 31: S. 823–826
- [Web10] WEBSTER, John G.; JR., John W. Clark und ET. AL.: *Medical Instrumentation, Application and Design*, John Wiley & Sons, Inc., 4 Aufl. (2010)
- [Weh03] WEHRLI, Wilfried: *Enzyklopädie elektrophysiologischer Untersuchungen*, Urban und Fischer, 2., völlig bearb. und erw. Aufl. Aufl. (2003)
- [Wid75] WIDROW, B.; GLOVER, Jr., J.R.; MCCOOL, J.M.; KAUNITZ, J.; WILLIAMS, C.S.; HEARN, R.H.; ZEIDLER, J.R.; EUGENE DONG, Jr. und GOODLIN, R.C.: Adaptive noise cancelling: Principles and applications. *Proceedings of the IEEE* (1975), Bd. 63(12): S. 1692–1716
- [Win83] WINTER, Bruce B. und WEBSTER, John G.: Driven-Right-Leg Circuit Design. *IEEE Transactions on Biomedical Engineering* (1983), Bd. 30(1): S. 62–66
- [Wol91] WOLF, P.A.; ABBOTT, R.D. und KANNEL, W.B.: Atrial fibrillation as an independent risk factor for stroke: the Framingham Study. *Stroke* (1991), Bd. 22: S. 983–988
- [Yaz08] YAZAKI, Syunji und MATSUNAGA, T.: A proposal of abnormal condition detection system for elderly people using wireless wearable biosensor, in: *SICE Annual Conference, 2008*, Tokyo, S. 2234–2238
- [Yoo07a] YOON, Sung Won; MIN, Se Dong; YUN, Yong Hyeon; LEE, Seungpyo und LEE, MyoungHo: Adaptive Motion Artifacts Reduction Using 3-axis Accelerometer in E-textile ECG Measurement System. *J. Med. Syst.* (2007), Bd. 32(2): S. 101–106
- [Yoo07b] YOON, Sung Won; SHIN, Hang Sik; MIN, Se Dong und LEE, MyoungHo: Adaptive motion artifacts reduction algorithm for ECG signal in textile wearable sensor. *IEICE Electronics Express* (2007), Bd. 4(10): S. 312–318, URL http://www.jstage.jst.go.jp/article/elex/4/10/4_312/_article
- [Yu08] YU, Xinguo: Approaches and principles of fall detection for elderly and patient, in: *e-health Networking, Applications and Services*,

2008. *HealthCom 2008. 10th International Conference on*, Singapore, S. 42–47
- [Zau08] ZAUNSEDER, S.; FISCHER, W.-J.; POLL, R. und RABENAU, M.: Wavelet-based real-time ECG processing for a wearable monitoring system, in: *International Joint Conference on Biomedical Engineering Systems and Technologies (BIOSTEC)*
- [Zep10] Zephyr Technology: *BioHarness BT Data Sheet* (2010), URL <http://www.zephyr-technology.com>
- [Zha99] ZHANG, Xu-Sheng; ZHU, Yi-Sheng; THAKOR, N. V. und WANG, Zhi-Zhong: Detecting ventricular tachycardia and fibrillation by complexity measure. *IEEE Transactions on Biomedical Engineering* (1999), Bd. 46(5): S. 548–555
- [Zha00] ZHANG, H. X.; ZHU, Y. S. und WANG, Z. M.: Complexity measure and complexity rate information based detection of ventricular tachycardia and fibrillation. *Med Biol Eng Comput* (2000), Bd. 38: S. 553–557
- [Zip79] ZIPP, P. und AHRENS, H.: A model of bioelectrode motion artefact and reduction of artefact by amplifier input stage design. *J Biomed Eng* (1979), Bd. 1: S. 273–276
- [ZOLa] ZOLL LIFECOR CORPORATION: LifeVest, URL <http://www.lifecor.com/>
- [ZOLb] ZOLL LIFECOR CORPORATION: See-Thru CPR, URL <http://www.zoll.com/medical-technology/see-thru-cpr/>

Eigene Veröffentlichungen

- [1] FUHRHOP, Silvester ; LAMPARTH, Stefan ; SEEMANN, Tobias ; HEUER, Stephan ; KIRST, Malte ; STORK, Wilhelm:
Comparing Dry Electrode Materials for Long-Term ECG Monitoring.
In: *Biomedical Engineering Systems and Technologies, 4th International Joint Conference, BIOSTEC 2011*, 2011
- [2] HEUER, Stephan ; CHIRIAC, Sebastian ; KIRST, Malte ; GARBI, Adnene ; STORK, Wilhelm:
Signal Quality Assessment for Capacitively Coupled ECG Measurement Using Body-Sensor-Impedance.
In: *Biomedical Engineering Systems and Technologies, 4th International Joint Conference, BIOSTEC 2011*, 2011
- [3] SCHAAFF, Kristina ; MÜLLER, Lars ; KIRST, Malte ; HEUER, Stephan:
Improving Financial Decision Making Using Psychophysiological Sensor Data.
In: *51st annual meeting of the Society of Psychophysiological Research (SPR)*, 2011
- [4] SCHAAFF, Kristina ; KIRST, Malte ; MÜLLER, Lars:
Ein psychophysiologisches Monitoring-Framework zur Verbesserung der Entscheidungskompetenz an Finanzmärkten.
In: *7. Tagung der Fachgruppe Arbeits-, Organisations- und Wirtschaftspsychologie der Deutschen Gesellschaft für Psychologie*, 2011
- [5] KIRST, Malte ; GLAUNER, Bastian ; OTTENBACHER, Jörg:
Using DWT for ECG Motion Artifact Reduction with Noise-correlating Signals.
In: *33rd Annual International Conference of the IEEE EMBS, Boston, Massachusetts USA, August 30 - September 3, 2011*, S. 4804–4807
- [6] LAMPARTH, Stefan ; FUHRHOP, Silvester ; KIRST, Malte:
Kontinuierliches EKG-Monitoring mit integrierter Frühdefibrillation.
Medica Media Forum – Young Potential Nachwuchspreis, 2010
- [7] KAISER, Stefanie ; KIRST, Malte ; KUNZE, Christophe:

- Automatic Detection of Atrial Fibrillation for Mobile Devices.
Version: 2010.
http://dx.doi.org/10.1007/978-3-642-11721-3_20.
In: FRED, Ana (Hrsg.) ; FILIPE, Joaquim (Hrsg.) ; GAMBOA, Hugo (Hrsg.):
Biomedical Engineering Systems and Technologies Bd. 52.
Springer Berlin Heidelberg, 258-270. –
ISBN 978-3-642-11721-3. –
10.1007/978-3-642-11721-3_20
- [8] KIRST, Malte ; OTTENBACHER, Jörg ; FUHRHOP, Silvester ; LAMPARTH, Stefan ;
KUNZE, Christophe:
Kontextsignale zur Verbesserung der automatischen EKG-Analyse in Tele-
monitoringsystemen.
In: DUESBERG, Frank (Hrsg.): *e-Health 2011 : Informationstechnologien und
Telematik im Gesundheitswesen*.
Medical Future Verlag, 2010, S. 303–306
- [9] KIRST, Malte ; OTTENBACHER, Jörg ; LAMPARTH, Stefan ; FUHRHOP, Silvester ;
STORK, Wilhelm:
The Use of Body Acceleration and Electrode-skin Impedance Data for ECG
Analysis in Telemonitoring Systems.
In: GRUYTER, Walter de (Hrsg.): *Biomed Tech 2010* Bd. 55, 2010
- [10] FUHRHOP, Silvester ; LAMPARTH, Stefan ; KIRST, Malte ; WAGNER, Gero
von ; OTTENBACHER, Jörg:
Ambulant ECG Recording with Wet and Dry Electrodes: A Direct Compari-
son of two Systems.
In: DÖSSEL, O. (Hrsg.) ; SCHLEGEL, W. C. (Hrsg.): *IFMBE Proceedings* Bd. 25,
2009, S. 305–307
- [11] KAISER, Stefanie ; KIRST, Malte ; KUNZE, Christophe:
Automatic Detection of Atrial Fibrillation and Flutter.
In: *BIO SIGNALS 2009 : Second International Conference on Bio-inspired Sys-
tems and Signal Processing*.
Porto, January 2009
- [12] KIRST, Malte ; LAMPARTH, Stefan ; FUHRHOP, Silvester ; OTTENBACHER,
Jörg ; KUNZE, Christophe:
Transferring an Artifact Handling System into a Mobile Long-term ECG
Device with Dry Electrodes.
In: DÖSSEL, O. (Hrsg.) ; SCHLEGEL, W. C. (Hrsg.): *IFMBE Proceedings* Bd. 25,

- 2009, S. 942–945
- [13] KIRST, Malte ; OTTENBACHER, Jörg ; KUNZE, Christophe ; STORK, Wilhelm:
Improvement of Automatic ECG Analysis for Telemonitoring Systems Based
on Context Signals.
In: *BIOSTEC 2009 : Doctoral Consortium*.
Porto, January 2009, S. 3–8
- [14] LAMPARTH, Stefan ; FUHRHOP, Silvester ; KIRST, Malte ; WAGNER, Gero
von ; OTTENBACHER, Jörg:
A Mobile Device for Textile-integrated Long-term ECG Monitoring.
In: DÖSSEL, O. (Hrsg.) ; SCHLEGEL, W. C. (Hrsg.): *IFMBE Proceedings* Bd. 25,
2009, S. 278–281
- [15] KIRST, Malte ; OTTENBACHER, Jörg ; NEDKOV, Radoslav:
UNISENS – Ein universelles Datenformat für Multisensordaten.
In: *Tagungsband Biosignalverarbeitung*.
Universität Potsdam, Juli 2008. –
ISBN 978–3–9810021–7–1, S. 106–108
- [16] OTTENBACHER, Jörg ; KIRST, Malte ; JATOBÁ, Luciana ; GROßMANN, Ulrich ;
HUFLEJT, Michal:
Artefakterkennung für ambulante EKG-Monitoring-Systeme.
In: *Tagungsband Biosignalverarbeitung*.
Universität Potsdam, Juli 2008. –
ISBN 978–3–9810021–7–1, S. 52–54
- [17] OTTENBACHER, Jörg ; KIRST, Malte ; JATOBÁ, Luciana ; HUFLEJT, Michal ;
GROßMANN, Ulrich ; STORK, Wilhelm:
Reliable Motion Artifact Detection for ECG Monitoring Systems with Dry
Electrodes.
In: *Conf Proc IEEE Eng Med Biol Soc 2008 (2008)*, S. 1695–1698
- [18] KIRST, Malte ; OTTENBACHER, Jörg ; SCHÄFER, Dörte ; KUNZE, Christophe ;
STORK, W. ; MÜLLER-GLASER, K.:
Methode zur automatischen Artefakterkennung im EKG mit Hilfe eines
Beschleunigungssensors.
In: *Biomedizinische Technik* Bd. 52, 2007
- [19] OTTENBACHER, Jörg ; KIRST, Malte ; JATOBÁ, Luciana ; GROßMANN, Ulrich ;
STORK, Wilhelm:
An approach to reliable motion artifact detection for mobile long-term ECG
monitoring systems using dry electrodes.
In: *IV Latin American Congress on Biomedical Engineering, CLAIB 2007*, 2007

- [20] WAGNER, G. von ; HAASE, D. ; HAAS, M. ; KIRST, M. ; HEY, S. ; STORK, W. ;
MÜLLER-GLASER, K.-D.:
Reliable ECG Beat Detection with Neuro-Fuzzy-Systems.
In: 6. Würzburger Medizintechnik Kongress, 2005
- [21] WAGNER, Gero von ; KIRST, M. ; RAJEWICZ, M. ; KARL, F. ; STORK, Wilhelm ;
MÜLLER-GLASER, Klaus D.:
PATRES - A Mobile Patient simulator for Resuscitation Training.
In: KROLL, Michael (Hrsg.) ; LIPINSKI, Hans-Gerd (Hrsg.) ; MELZER, Kay
(Hrsg.): *MoCoMed* Bd. 27, Gl. –
ISBN 3–88579–356–3, 7-13
- [22] WAGNER, G. v. ; KIRST, M. ; RAJEWICZ, M. ; KARL, F. ; KIBROM, A. ; STORK,
W. ; MÜLLER-GLASER, K.:
New Approaches in Resuscitation Training with a Wireless, Automatic
Patient Simulator.
In: *Biomedizinische Technik* Bd. 48, 2003, S. 436–437
- [23] SCHLINDWEIN, M. ; WAGNER, G. von ; KIRST, M. ; RAJEWICZ, M. ; KARL, F. ;
SCHÖCHLIN, J. ; BOLZ, A.:
Mobile Patient Simulator for Resuscitation Training with Automatic Exter-
nal Defibrillators.
In: *Biomedizinische Technik* Bd. 47, 2002, S. 559–560

Betreute studentische Arbeiten

- [1] PHAM, Minh G.:
Framework zur Integration von Matlab-Funktionen in den UnisensViewer,
Karlsruher Institut für Technologie (KIT), Diplomarbeit, 2011
- [2] GLAUNER, Bastian:
Adaptive QRS-Erkennung mit Hilfe von Kontextsignalen, Karlsruher Institut
für Technologie (KIT), Diplomarbeit, 2010
- [3] BALTI, Hajer:
QRS-Detektion im gestörten Mehrkanal-EKG, Karlsruher Institut für Techno-
logie (KIT), Studienarbeit, 2010
- [4] JIBRI, Aymen:
*Optimierung von Algorithmen zur Erkennung und Kompensation von Arte-
fakten im EKG-Signal*, Universität Karlsruhe (TH), Studienarbeit, 2010
- [5] WARGA, Marcus:
Erstellung eines generischen Viewers für Unisens-Daten, Karlsruher Institut
für Technologie (KIT), Diplomarbeit, 2010
- [6] WARGA, Marcus:
Erweiterung eines Viewers für Unisens-Daten, Karlsruher Institut für Techno-
logie (KIT), Studienarbeit, 2010
- [7] TALEGHANI, Amin A.:
*Vergleich der Leistungsfähigkeit von Matlab/Simulink und Labview -
Embedded zur Codegenerierung für Mikrocontroller-Targets*, Karlsruher
Institut für Technologie (KIT), Diplomarbeit, 2009
- [8] JUNGKURTH, Henning:
*Aufbau eines Demonstrators für Algorithmen im Bereich der EKG-Online-
Analyse*, Universität Karlsruhe (TH), Studienarbeit, 2009
- [9] WANG, Bin:
*Implementation and Improvement of a Methodology for Identification of ECG
Rhythms that Require Instant Defibrillation*, Universität Karlsruhe (TH),
Diplomarbeit, 2009
- [10] AUBREVILLE, Marc:

- Umsetzung eines waveletbasierten EKG-Klassifikationsverfahrens auf einer mobilen Plattform*, Universität Karlsruhe (TH), Studienarbeit, 2008
- [11] GLOSE, Carsten:
Erstellung eines Werkzeugs zum Aufbau einer Test-Datenbank für EKG-Analysealgorithmen, Universität Karlsruhe (TH), Studienarbeit, 2008
- [12] KAISER, Stefanie:
Entwurf und Implementierung einer Methode zur automatischen Differenzierung von Vorhofflimmern und Extrasystolie anhand der Rhythmik, Universität Karlsruhe (TH), Diplomarbeit, 2008
- [13] NICKL, Stephanie:
Modellbildung des Elektrode-Haut-Systems zur Artefaktunterdrückung bei EKG-Messungen, Universität Karlsruhe (TH), Diplomarbeit, 2008
- [14] DHARMADJI, Arnold:
Entwicklung von Algorithmen zur Unterscheidung von aktiven und passiven Körperbewegungen, Universität Karlsruhe (TH), Studienarbeit, 2007

Abbildungsverzeichnis

1.1	Herz-Kreislauf-erkrankungen sind die häufigste Todesursache in Deutschland [Sta06]	2
1.2	Änderungen der Herzaktivität (blau) und des Aufnahmesystems (grau) beeinflussen die automatische EKG-Analyse	3
2.1	Erregungsleitungssystem des Herzens	8
2.2	Bezeichnungen der Wellen und Zacken im EKG	9
2.3	Beispiele für bradykarde Herzrhythmusstörungen	9
2.4	Beispiele für tachykarde Herzrhythmusstörungen	10
2.5	Aufbau der Haut und deren elektrisches Ersatzschaltbild	12
2.6	Möglichkeiten der Hautimpedanzbeeinflussung	14
2.7	EKG-Standardableitungen	15
2.8	Klinisches EKG mit seinen zwölf Standardableitungen, aufgenommen mit dem PC-EKG-System FlashLight	17
2.9	Verschiedene Elektrodentypen zur EKG-Ableitung	18
2.10	Ersatzschaltbild einer Elektrode	19
2.11	Übersicht möglicher Störquellen bei der EKG-Ableitung	20
2.12	Beispiele für verschiedene Artefakte im EKG	20
2.13	Impedanzmessung über zwei Elektroden nach [Web10]	26
2.14	Aufbau eines adaptiven Filters	27
2.15	Einsatz eines adaptiven Filters zur Störunterdrückung	29
3.1	Einsatz von Telemedizin zur Diagnostik symptomatischer Herzrhythmusstörungen [Sch08]	35
3.2	Holter-EKG-Geräte mit integriertem Beschleunigungssensor	54
3.3	Nicht-zugelassene EKG-Geräte unterscheiden sich oftmals in Form und Funktion von konventionellen EKG-Rekordern [mov, Zep10, cam]	56

4.1	Systemkonzept: Neben dem EKG werden weitere Signale aufgezeichnet und ausgewertet	57
4.2	Zusammenhang zwischen fehlerhaften QRS-Detektionen (OSEA) und körperlicher Bewegung	61
4.3	Unterschiedliche Sensorpositionen führen zu verschiedenen starker Korrelation zwischen EKG und Beschleunigungssignal	62
4.4	Kreuzkorrelationsfunktion zwischen EKG und dreiaxsigem Beschleunigungssensor bei verschiedenen Sensorpositionen während des Liegens	63
4.5	Zusammenhang zwischen Elektrode-Haut-Impedanz und Artefakten (Ersatzschaltbild nach [Zip79])	64
4.6	Korrelation zwischen dem EKG und der Elektrode-Haut-Impedanz bei einem 50-sekündigen artefaktbehafteten Segment (links) und einer artefaktfreien Sequenz (rechts)	65
4.7	Blockschaltbild zur Messung der Elektrode-Haut-Impedanz [Ott06]	65
4.8	Werkzeugkette zum Entwickeln, Testen und Evaluieren der Artefaktbehandlungsalgorithmen	67
4.9	Aufbau eines Unisens-Datensatzes	70
4.10	Repräsentation eines Unisens-Datensatzes im Dateisystem	71
4.11	EKG-Editor mit 5 min EKG in der Übersicht	75
4.12	UnisensViewer mit verschiedenen Messdaten und Annotationen	80
4.13	Virtuelle Speicherverwaltung durch Paging und Memory Mapped Files	81
4.14	Kommunikation zwischen UnisensViewer und Plug-ins	82
4.15	Möglichkeiten zur Integration von Matlab-Funktionen	84
4.16	Stuktur der Unisens-Datenbank (context.xml)	85
4.17	Stuktur der Unisens-Datenbank (unisens.xml)	86
4.18	Benutzeroberfläche für die Abfrage der Unisens-Datenbank	87
4.19	EKG-Aufnahme mit Brustgurt und Klebeelektroden	88
4.20	Textilintegriertes EKG-System mit integriertem Beschleunigungssensor (links) und zugehörige Aufnahmehardware (rechts)	89
4.21	careMon-Gurt für das 24/7-EKG-Monitoring	91
5.1	Bei unterschiedlichen Probanden kann trotz gleicher Aktivität (hier: Joggen) die EKG-Qualität erheblich abweichen	95
5.2	Die Artefaktbereiche werden auf Basis der QRS-Detektion bestimmt	96

5.3	Das Artefaktlevel wird aus Beschleunigungs- und EKG-Daten berechnet	98
5.4	Je nach Schwellwert kann der Algorithmus sensitiver oder spezifischer eingestellt werden	99
5.5	Mit dem Einsetzen der Bewegung (hier: Rennen) nehmen die Bewegungsartefakte zu, das EKG wird anschließend als artefaktbehaftet markiert (roter Balken)	100
5.6	Nach einer kurzen körperlichen Bewegung kann sich das EKG-Signal auf verschiedene Weise drastisch verändern	102
5.7	Artefakterkennung mit und ohne Berücksichtigung von Bewegungsinformationen bei den careMon-Daten	104
5.8	Die Deformation des gefilterten EKG-Signals ist minimal (Ausschnitt aus Abb. 5.9)	106
5.9	Morphologische Filter eignen sich zur Reduktion von Grundlinienschwankungen – ohne auf Kontextsignale angewiesen zu sein	107
5.10	In der Theorie wird neben dem EKG eine Störreferenz als zusätzlicher Eingang benötigt, um das EKG von den Artefakten zu befreien	108
5.11	In Einzelfällen führt die Artefaktreduktion mit einem adaptiven Filter zu Verbesserungen	110
5.12	Das normale EKG wird durch das Filter kaum beeinflusst (links), Artefakte werden hingegen stark reduziert (rechts)	110
5.13	Die See-Thru CPR der Firma Zoll reduziert CPR-Artefakte im Rohsignal (RAW) und visualisiert das gefilterte Signal (FIL) [ZOLb]	112
5.14	Der Algorithmus nutzt die DWT der Elektrode-Haut-Impedanz für die selektive Artefaktreduktion	114
5.15	Durch die selektive Artefaktreduktion ist die Deformation des gefilterten EKG minimal	115
5.16	Die integrierte Reduktion der Grundlinienschwankungen verbessert zwar die automatische QRS-Erkennung, deformiert das gefilterte Signal aber stark	116
5.17	Eine Veränderung des Schwellwerts im Parameter-Set I verschiebt die Anzahl der FN- und FP-Detektion	116
5.18	Die Validierung des Algorithmus erfolgt mit Hilfe des OSEA QRS-Erkenner und einem Beat-by-Beat-Vergleich (BxB)	117

5.19	Die Boxplots zeigen eine signifikante Verbesserung von Sensitivität und positiver Prädiktivität nach der Artefaktreduktion (Parameter-Set II)	119
6.1	Mit Matlab generierter Entscheidungsbaum für die automatische Ruheerkennung	125
6.2	Klassendiagramm der Ruheerkennung	126
6.3	Nutzen des Aktivitätsmonitorings für die EKG-Analyse	128
6.4	Aufbau eines Algorithmus zur vierstufigen Aktivitätsklassifikation auf Basis eines Beschleunigungssensors	129
6.5	Bei Sekunde 4 ist der Wechsel zwischen Sitzen und Liegen deutlich im Beschleunigungssignal zu erkennen	131
6.6	Beim Treppensteigen ändert sich die körperliche Aktivität mehrfach zwischen <i>mittel</i> und <i>hoch</i>	132
6.7	Aktivitätsdaten aus dem Alltag	134
6.8	Bei der Betrachtung der Aktivitätsdaten eines längeren Zeitraums ist die Mittelung über eine Minute sinnvoll	135
6.9	Benutzeroberfläche für die automatische Generierung der Referenz-Signatur für die Sturzerkennung	136
6.10	Kombiniert man die Sturzerkennung mit der Ruheerkennung, lässt sich die Erkennungsgüte steigern, hier werden ausschließlich die fünf Stürze zwischen 1,8 s und 2,8 s detektiert	137
6.11	Die Erkennung des Aufstehens basiert auf den Ergebnissen der Aktivitätserkennung der letzten Sekunden	138
6.12	Die magentafarbene Linie bei 3,1 s markiert das automatisch erkannte Aufstehen	139
6.13	Bedingungen für verlässliche Ergebnisse der EKG-Analyse	140
6.14	Das nach einem Artefakt auftretende Einschwingen des QRS-Detektors (rot) kann vermieden werden, wenn die gestörte Sequenz gezielt ausgeblendet wird (grün)	141
6.15	Bewegungsartefakte im EKG (oben) können einem Kammerflattern (unten), hier bei einem Schrittmacher-Patienten, ähneln	144
6.16	Körperliche Ruhe ist ein notwendiges Kriterium für die Erkennung von VT/VF	144
6.17	Der Algorithmus zur VT/VF-Erkennung berücksichtigt körperliche Ruhe	145

6.18	Herzrate und Aktivitätsprofil über einen Zeitraum von zwölf Stunden	147
6.19	Autoregulation der Herzfrequenz eines Patienten gemittelt über 295 Aufsteh-Ereignisse eines Tages	148
6.20	Zwei lange Pausen sind die Ursache für eine kurze Bewusstlosigkeit	151
6.21	Die Ruhephasen werden zur Bestimmung des Ruhepulses (rote Linie) genutzt	152
6.22	Rhythmus-Report	157
6.23	Frequenz-Report	158
6.24	Der EKG-Editor ermöglicht das gezielte Anspringen von Events, wie zum Beispiel zuvor detektierte Pausen	159
6.25	Der UnisensViewer kann alle im Datensatz enthaltene Informationen anzeigen, hier Beschleunigungssignal, verschiedene Ereignisse (Pausen, QRS-Trigger, Aufstehen), Körperlage und Bewegung sowie Tachogramm und Herzrate	161

Tabellenverzeichnis

2.1	Frequenz- und Dynamikumfang von Biosignalen	23
2.2	Wahrheitsmatrix für Klassifikatoren	30
3.1	Erkennungsgüte verschiedener QRS-Detektoren auf der MIT/BIH-Datenbank	37
3.2	Übersicht über die in der Literatur beschriebenen Verfahren zur Artefaktreduktion mit Hilfe eines Second Channel	48
3.3	Typische Applikationsdauer und notwendige Patienteninteraktion für verschiedene Gerätekonzepte	53
4.1	Alle von Unisens unterstützten Datentypen	72
4.2	EKG-Annotationen für QRS-Komplexe [Moo08]	76
4.3	Weitere EKG-Annotationen [Moo08]	77
5.1	Die Artefakterkennung verbessert das Ergebnis der QRS-Detektion	99
5.2	Die Artefakterkennung verbessert das Ergebnis der QRS-Detektion	103
5.3	Die Artefaktreduktion mit morphologischen Filtern führt zu einer signifikanten Verbesserung der positiven Prädiktivität . .	107
5.4	Verbesserung der automatischen QRS-Erkennung durch verschiedene Methoden zur Artefaktreduktion	117
5.5	Das gefilterte EKG führt zu einer Verringerung der Fehldetektionen bei der QRS-Erkennung	118
6.1	Ruheerkennung der 79 Testdatensätze, gemittelt über eine Minute	127
6.2	Ruheerkennung der 79 Testdatensätze	128
6.3	Aktivitätserkennung der 79 Testdatensätze	133
6.4	Aktivitätserkennung der 79 Testdatensätze, gemittelt über eine Minute	135

6.5	Fließen die Kenntnisse über artefaktbehaftete Bereiche in die QRS-Detektion mit ein, lässt sich das Ergebnis verbessern	143
6.6	In Tabellenform lassen sich belastungsinduzierte Herzrhythmusstörungen quantifizieren	149
6.7	Funktionen und Abhängigkeiten des DekomTex-Reportgenerators	153

Abkürzungsverzeichnis

+P	positive Prädiktivität
AED	automatischer externer Defibrillator
Ag/AgCl	Silber/Silberchlorid
AICF	Adaptive Impulse Correlated Filter
AMR	Anisotropic Magnetoresistance
ANFIS	Adaptive Network-based Fuzzy Inference System
AV-Knoten	Atrioventrikularknoten
AVSEP	Audio Visual Superimposed Electrocardiogram Presentation
BxB	Beat-by-Beat-Vergleich
CART	Classification and Regression Tree
CI	Chronotrope Inkompetenz
COM	Component Object Model
CSV	Character Separated Values
DLL	Dynamic Link Library
DWT	Diskrete Wavelet-Transformation
EDF	European Data Format
EDF+	European Data Format Plus
EEAC	Energy Equivalent Acceleration
EKG	Elektrokardiogramm
EMG	Elektromyogramm

FDA	U.S. Food and Drug Administration
FIR	Finite Impulse Response
FN	False Negative
FP	False Positive
GPL	General Public License
GUI	Graphical User Interface
HRV	Herzratenvariabilität
I ² C	Inter-Integrated Circuit
ICA	Independent Component Analysis
ICD	implantierbarer Kardioverter/Defibrillator
IEC	International Electrotechnical Commission
IIR	Infinite Impulse Response
ILR	Implantierbare Loop-Rekorder
JDBC	Java Database Connectivity
JNI	Java Native Interface
KHK	Koronare Herzkrankheit
kNN	k th Nearest Neighbor
LMS	Least Mean Squares
LSB	Least Significant Bit
MEMS	Micro-Electro-Mechanical Systems
MPG	Medizinproduktegesetz
MSP	Mixed Signal Processor
MySQL	siehe SQL
OSEA	Open Source ECG Analysis Algorithm
pP	positive Prädiktivität

PVC	Premature Ventricular Contraction (ventrikuläre Extrasystole)
RLS	Recursive Least Squares
SDK	Software Development Kit
Se	Sensitivität
SKG	Seismokardiogramm
SNR	Signal-to-noise Ratio
Sp	Spezifität
SPI	Serial Peripheral Interface
SQL	Structured Query Language
SVPB	Supraventricular Premature Beat (supraventrikuläre Extrasystole)
TN	True Negative
TP	True Positive
XML	Extensible Markup Language
XSD	XML Document Schema

A Unisens 2.0

A.1 Anforderungen

Freie Kennzeichnung von Inhalten (Art der Daten, Umgebung, Ursprung) in einem menschenlesbaren Format In den Datendateien werden nur die aufgezzeichneten Signaldaten gespeichert. Alle weiteren Informationen zur Aufnahme und zum Aufnahmesystem oder einfache Kommentare zum Signal werden in der Header-Datei im menschenlesbaren und -editierbaren XML-Format gespeichert.

Unterstützung von Signaldaten, Ereignisdaten und Bereichsdaten Das Datenformat kann kontinuierliche aufgezeichnete Sensordaten und einzeln aufgezeichnete Ereignisse in einem Datensatz vereinen. Daten unterschiedlichen Typs werden in getrennten Dateien gespeichert, der Zugriff erfolgt aber über das gleiche Interface.

Beliebige Anzahl von Datendateien pro Datensatz Die Anzahl der Datendateien (Signale, Ereignisse und Einzelwerte) pro Datensatz ist nicht begrenzt. In Bereichen wie z. B. der Polysomnographie ist es nötig, sehr viele unterschiedliche Signale und Ereignisse parallel aufzuzeichnen. Hier kann jeder der benutzen Sensoren seine Daten in einer eigenen Datendatei abspeichern. In der Header-Datei werden alle Datendateien aufgelistet und in einen gemeinsamen Kontext gebracht.

Klassenbildung für Daten gleichen Typs Daten des gleichen Typs (z. B. EKG, Beschleunigung, EKG-Trigger) werden zu einer Klasse zusammengefasst. Damit wird beispielsweise einem EKG-Darstellungswerkzeug ermöglicht, die EKG-Daten eines Datensatzes zu identifizieren. Die Klasse wird im Attribut `contentClass` gespeichert. Die Klassennamen können frei gewählt werden, es wird jedoch empfohlen, sich an die vorgeschlagenen Richtlinien zu halten.

Eine Datenklasse kann in einem Datensatz mehrfach vorhanden sein. Somit können in einem Datensatz bearbeitete und unbearbeitete Daten eines Signal enthalten sein (z. B. gefilterte EKG-Daten und EKG-Rohdaten oder automatisch erstellte Triggerliste und Referenztriggerliste)

Eindeutige Identifizierbarkeit einer Datendatei innerhalb eines Datensatzes
Über die `entryId` ist eine Datendatei eindeutig innerhalb des Datensatzes identifizierbar.

Unterstützung von Daten mit verschiedenen Abtastraten und Abtasttiefen
Innerhalb eines Datensatzes können Daten mit unterschiedlicher Abtastrate und Abtasttiefe gespeichert werden. Die Daten werden in getrennten Dateien abgelegt.

Mehrkanalige Aufnahmen möglich Signale und Einzelwerte können mehrere Kanäle besitzen, diese müssen jedoch in Abtastrate und Abtasttiefe übereinstimmen.

Keine Einschränkung der Größe der Daten durch die Spezifikation Die Größe der Daten ist lediglich durch das Filesystem und den Datenträger begrenzt. Übersteigt die Anzahl der gespeicherten Samples 2^{63} , kann die Referenzimplementierung die Datei nicht mehr vollständig lesen.

Möglichkeit der Beschreibung von Daten Alle Signal-, Ereignis- und Bereichsdaten sowie alle Kanäle können mit einem Kommentar versehen und damit verbal beschrieben werden.

Unterstützung verschiedener Dateiformate für Datendateien Für Datendateien können unterschiedliche Dateiformate verwendet werden (Binär, XML, CSV). Für jedes Dateiformat ist eine Referenzimplementierung in Java vorhanden, die Daten lesen und schreiben

Samplegenaue Angabe von Ereignissen und Bereichen Alle Zeitpunkte können samplegenau angegeben werden. Zu jeder Datendatei wird in `sampleRate` eine Samplerate angegeben, die als Zeitbasis für diese Datendatei gilt. Die einzelnen Datendateien innerhalb eines Datensatzes können unterschiedliche Sampleraten besitzen.

Samplegenaue Unterstützung von Signalen größer und kleiner 1 Hz Die Samplerate kann sowohl ganzzahlig oder als Dezimalzahl angegeben sein. Dezimaltrenner ist in jedem Fall ein Punkt.

Umgang mit proprietären Daten Innerhalb des Datensatzes können proprietäre Daten abgelegt und gekennzeichnet werden.

Gruppierungsfunktion Datendateien können zu inhaltlichen Gruppen zusammengefasst werden. So kann z. B. ein EKG mit der zugehörigen Annotation gruppiert werden.

Unterstützung von aufnahmespezifischen Kontextinformationen Aufnahme-spezifische Kontextinformationen wie z. B. Patientendaten bei der Aufzeichnung von Vitalsignalen können als XML-Datei im Datensatz abgelegt werden, inklusive der Information über das zugehörige XML-Schema. Das Interface unterstützt das Parsen dieser Kontext-Datei und das Laden der zugehörigen Schema-Datei.

A.2 Begriffe

Dateiformat (File Format) Datendateien können in unterschiedlichen Dateiformaten abgelegt werden. Definierte Dateiformate sind CSV (Character Separated Values), BIN (Binär-Format) und XML (Extensible Markup Language).

Datendatei (Data Entry) Überbegriff für eine Datei, die Signal-, Ereignis- oder Einzelmesswertdaten enthält.

Datensatz (Dataset) Zusammenhängende Einheit aus einer Header-Datei und einer beliebigen Anzahl von Datendateien und optional einer Kontextinformationsdatei. Ein Datensatz bezieht sich immer auf eine Messung.

Datentyp (Datatype) Unterstützt werden folgende Datentypen: uint8, int8, uint16, int16, uint32, int32, float, double.

Einzelwert (Value) Zeitdiskrete, nicht-äquidistant abgetastete Messwerte, die in mehreren Kanälen vorliegen können (z.B. Blutdruck). Jeder Einzelwert besteht aus einem Zeitpunkt und je einem Messwert pro Kanal.

Ereignis (Event) Zeitdiskretes Ereignis, bestehend aus einem Zeitstempel und einer Ereignisannotation (z.B. ein QRS-Trigger).

Gruppe (Group) Ereignisse, Signale und Messwerte können zu einer Gruppe zusammengefasst werden. Eine Gruppe spiegelt den semantischen Zusammenhang wider.

Header-Datei (Unisens-Datei) Die Header-Datei eines Datensatzes heißt immer unisens.xml. Sie ist eine XML-Datei, die Informationen über Inhalt und Format der Datendateien enthält.

Kanal (Channel) Untergruppierung eines Signals oder eines Messwerts. Alle Kanäle eines Signals bzw. eines Einzelwerts haben dieselbe Quantisierung und dieselbe Abtastrate.

Klasse (Content Class) Jede Datendatei wird genau einer Klasse zugeordnet. Die Klasse bezieht sich auf den Dateninhalt, die eigentliche Information.

Kontextinformation (Context) Anwendungsspezifische Zusatzinformationen zum Umfeld einer Messung (z.B. Personendaten).

Proprietäre Daten (Custom Data) Anwendungsspezifische Daten, die zu einer Messung gehören, aber in Unisens nicht durch Signale, Einzelwerte, Ereignisse oder Bereiche abgedeckt sind.

Signal (Signal) Kontinuierlich mit beliebiger, aber fester Samplerate aufgezeichnetes Messsignal (z.B. das EKG). Ein Signal kann mehrere Kanäle enthalten.