



TECHNISCHE
UNIVERSITÄT
WIEN

Vienna University of Technology

DIPLOMARBEIT

Automatische Klassifikation von Herzschlägen im Elektrokardiogramm durch die Support Vektor Maschine und Selbst Organisierte Karte

Ausgeführt am Institut für
Analysis and Scientific Computing
der Technischen Universität Wien

unter der Anleitung von
Ao.Univ.Prof. Dipl.-Ing. Dr.tech. Felix Breitenecker

durch
Natalie Gschaider
Joseph-Haydn-Straße 3/2/3
A-3300 Amstetten

Ort, Datum

Unterschrift

ERKLÄRUNG ZUR VERFASSUNG DER ARBEIT

Natalie Gschaider
Joseph-Haydn-Straße 3/2/3, A-3300 Amstetten

Hiermit erkläre ich, dass ich diese Arbeit selbstständig verfasst habe, dass ich die verwendeten Quellen und Hilfsmittel vollständig angegeben habe und dass ich die Stellen der Arbeit - einschließlich Tabellen, Karten und Abbildungen -, die anderen Werken oder dem Internet im Wortlaut oder dem Sinn nach entnommen sind, auf jeden Fall unter Angabe der Quelle als Entlehnung kenntlich gemacht habe.

Ort, Datum

Unterschrift

ABSTRACT

Cardiovascular diseases are the leading cause of premature death in Austria. This fact gives doctors and researchers a reason to improve existing early warning systems or develop new ones, some with the help of modeling.

Since arrhythmias are often an indicator for heart diseases, they are a good starting point for a detailed investigation of the patient's conductive system of the heart. The electrocardiogram (ECG) is a graphic representation of the function of the conductive system. Disorders are characterized by deviations of the regular heartbeat sequence or the usual shape of the ECG signal of the individual heartbeats. It can be evaluated using classification methods to identify types of heartbeats associated with disorders. The aim is to distinguish between cardiac arrhythmias and healthy heart rhythms.

The aim of this work is to develop an algorithm on the basis of medical annotated ECG data that analyzes and classifies the recordings from different cardiac patients. The development of software and the implementation of different classification methods are performed in the development environment MATLAB®. There are many different methods and models for this classification. In this work, Self Organizing Maps, Support Vector Machines, and a combination thereof are applied.

First, the corresponding data is preprocessed and prepared for classification - by using Higher Order Statistics (HOS) and Hermite Basis Functions Expansion (HER) for feature extraction. Cardiac signals are transformed into a feature matrix which represents the original ECG data.

A Support Vector Machine classifies annotated data by an optimal hyperplane that separates all data of one class from data of another class. It belongs to the group of methods of supervised learning. In contrast, a Self Organizing Map is applied as an example of unsupervised learning. It automatically assigns the data to cluster due to similarity. The evaluation of the results is performed by comparison with the annotations of the data.

The algorithms have to be designed with a high accuracy level, so that they show minimal error. Simulation of the classification using annotated data showed an accuracy of 74.7% for the Self Organizing Map. By using the two preprocessing methods HOS and HER, the Support Vector Machine showed an accuracy rate of 88.4% for HOS and 87% for HER. These are significantly improved by a method of combination (weighted voting principle) with an average value of 92.8%. In conclusion, this combination can serve as a basis for annotating ECG signals automatically.

KURZFASSUNG

Herz-Kreislauf-Erkrankungen sind in Österreich die häufigste Ursache für einen frühzeitigen Tod. Diese Tatsache gibt Medizinern und Forschern Anlass, bestehende Früherkennungssysteme zu verbessern oder mithilfe von Modellbildung neu zu entwickeln.

Da Herzrhythmusstörungen oft ein Indiz für Herzkrankheiten sind, stellen sie einen guten Ausgangspunkt dar, eine genauere Untersuchung des Patienten einzuleiten. Mittels Elektrokardiogramm (EKG) aufgezeichnete Daten können dafür so ausgewertet werden, dass diese Rhythmusstörungen klassifiziert werden können. Störungen sind durch Abweichungen der regelmäßigen Herzschlagfolge oder der üblichen Form des EKG-Signals der einzelnen Herzschläge gekennzeichnet. Dabei gilt es, Arten von Herzschlägen zu bestimmen und in weiterer Folge Herzrhythmusstörungen von gesunden Herzrhythmen zu unterscheiden. Die einzelnen Klassen stellen Anhaltspunkte für bestimmte Herzkrankheiten dar.

Das Ziel dieser Arbeit ist, auf Basis von von Medizinern annotierten EKG-Daten einen Algorithmus zu entwickeln, der EKG-Aufzeichnungen von verschiedenen Herzpatienten analysiert und klassifiziert. Die Entwicklung der Software und die Implementierung verschiedener Klassifizierungsmethoden erfolgen in der Entwicklungsumgebung MATLAB®. Es gibt verschiedenste Möglichkeiten und Modelle, diese Klassifikation vorzunehmen. In dieser Arbeit werden dafür Self Organizing Maps (SOM), Support Vector Machines (SVM) und eine Kombination daraus angewendet.

Zunächst werden die entsprechenden Daten vorverarbeitet und für die Klassifikation aufbereitet. Dafür werden Statistiken höherer Ordnung (HOS) und Hermitesche Basisfunktionen (HER) zur Merkmalsextraktion angewendet und die EKG-Signale in eine Matrix von Merkmalstupeln transformiert. Diese entspricht dann einer Repräsentation der originalen EKG-Daten.

Eine Support Vektor Maschine klassifiziert zuvor zugeordnete Daten, indem die optimale Hyperebene gefunden wird, die alle Daten einer Klasse von denen einer anderen trennt. Sie gehört zu den Verfahren des überwachten Lernens. Im Vergleich dazu wird die Selbst Organisierte Karte als Beispiel für ein Verfahren unüberwachten Lernens auf die Daten angewendet. Diese entscheidet automatisch nach Ähnlichkeit der Daten die Zugehörigkeit zu Clustern. Die Evaluierung der Resultate erfolgt durch einen Vergleich mit den Annotationen der Daten.

Die Algorithmen sollen diese entsprechende Klassifikation mit hohem Exaktheitsgrad, also minimalem Fehler, vornehmen. Simulation der Klassifikation mit annotierten Daten ergab eine Erkennungsrate von 74.7% für die Selbst Organisierte Karte. Die Support Vektor Maschine wies unter Verwendung der beiden vorverarbeitenden Methoden HOS und HER eine Erkennungsrate von 88.4% für HOS und 87% für HER auf. Diese werden durch ein Verfahren zur Kombination (gewichtetes Voting Prinzip) mit einem durchschnittlichem Wert von 92.8% deutlich verbessert. Abschließend kann diese Kombination damit als Basis für eine automatische EKG-Annotation dienen.

DANKSAGUNG

Zuerst möchte ich mich bei Prof. Felix Breitenecker für die Betreuung meiner Diplomarbeit und reichlichen Angebote an wissenschaftlichen Konferenzen und gemeinsamen Aktivitäten der ARGESIM Gruppe wie Summer Schools während der Studienzeit bedanken. Durch seine zahlreichen interessanten Lehrveranstaltungen kam ich zum ersten Mal mit Modellbildung und Simulation in Kontakt. So kam ich zum Austrian Institute of Technology, wo dann auch diese Diplomarbeit umgesetzt wurde.

Besonderer Dank gebührt meinen Betreuern Martin Bachler und Christopher Mayer sowie der Firma AIT und meinen lieben Kollegen, die mir die Zeit gaben und immer zur Seite standen. Ohne deren Unterstützung wäre ich um viele Erfahrungen ärmer und hätte diese Arbeit nicht in dieser Zeit geschafft.

Diese Diplomarbeit möchte ich meiner tollen Mutter Christina widmen, die leider während des Entstehens dieser Diplomarbeit plötzlich verstarb. Sie hat mich immer in allem unterstützt wo sie konnte, finanziell sowie mental. Sie stand mir immer zur Seite. Ich weiß, sie war immer sehr stolz, mich studieren lassen zu können. Sie wusste immer, dass ich alles schaffe. Danke Mama, dass es dich für mich gab. Ich bin stolz, deine Tochter zu sein. Danke für alles Mama.

Großen Dank möchte ich nun auch herzlichst meinem Freund Tom und meinen vielen lieben Freundinnen und Freunden aussprechen, die mich mit voller Tatkraft und zu jeder Zeit unterstützten, die mir auch die Motivation gaben, nachdem meine Mutter von mir gegangen ist, wieder weiter zu machen. Nun ist es geschafft.

Danke herzlichst, Natalie.

INHALTSVERZEICHNIS

1	EINLEITUNG	1
1.1	Ziel der Arbeit	1
1.2	Motivation	1
1.3	Überblick	2
2	GRUNDLAGEN	3
2.1	Herz	3
2.1.1	Aufbau und Funktion des Herzens	3
2.1.2	Zyklus des Herzens	4
2.1.3	Erregungsausbreitung im Herzen	5
2.2	Elektrokardiographie	6
2.2.1	Ableitung des EKG	6
2.2.2	Analyse des EKG	8
3	DATEN	11
3.1	Datensatz	11
3.2	Herzschläge	11
3.2.1	Normaler Herzschlag (N)	13
3.2.2	Linksschenkelblock (L), Rechtsschenkelblock (R)	14
3.2.3	Atrial premature beat (A), atrial escape beat (e)	15
3.2.4	Aberrated atrial premature beat (a)	16
3.2.5	Nodal (junctional) premature beat (J), nodal (junctional) escape beat (j)	17
3.2.6	Ventricular premature beat (V), ventricular escape beat (E)	18
3.2.7	Kammerflattern, Kammerflimmern (I)	19
3.2.8	Paced beat (P)	20
3.2.9	Vermischung von Herzschlägen	21
3.2.10	Unklassifizierbarer Herzschlag (Q)	22
4	VORVERARBEITUNG	23
4.1	Merkmalsextraktion	23
4.1.1	HOS - Higher Order Statistics	24
4.1.2	HER - Hermitesche Basisfunktionen	27
4.2	weitere Merkmale	30
4.3	Skalierung der Merkmale	31
4.4	Zusammenfassung aller gewählten Merkmale	32
4.5	Trainings- und Testdaten	33
4.5.1	Vorbereitung für SVM	33
4.5.2	Vorbereitung für SOM	33
5	METHODEN ZUR KLASSIFIZIERUNG	35
5.1	SVM - Support Vektor Maschine	37
5.1.1	Lineare Support Vektor Maschine für linear separierbare Daten	37
5.1.2	Lineare Support Vektor Maschine für nichtlinear separierbare Daten	38
5.1.3	Nichtlineare Support Vektor Maschine	39

5.1.4	Quadratic Programming	41
5.1.5	Implementierung in MATLAB®	43
5.2	Kombination der Klassifizierer	44
5.3	SOM - Selbst Organisierte Karte	47
5.3.1	Mathematische Beschreibung	48
5.3.2	Implementierung in MATLAB®	49
5.4	Performance eines Klassifikators	51
6	RESULTATE	53
6.1	Support Vektor Maschine	53
6.2	Selbst Organisierte Karte	57
7	DISKUSSION	61
7.1	SVM	61
7.2	SOM	63
7.3	Unterschiede SVM zu SOM	64
8	AUSBLICK UND FAZIT	65
9	ANHANG	67
9.1	HOS	67
9.2	HER	67
9.3	SVM	68
9.4	SOM	69
	ABKÜRZUNGSVERZEICHNIS	71
	ABBILDUNGSVERZEICHNIS	73
	TABELLENVERZEICHNIS	77
	LITERATURVERZEICHNIS	79

1

EINLEITUNG

Insgesamt 78.252 Personen sind im Jahr 2014 laut Statistik Austria in Österreich gestorben. 42,3 Prozent aller Todesfälle waren auf Herz-Kreislauf-Erkrankungen zurückzuführen - das entspricht insgesamt 33.137 Menschen [4].

Herz-Kreislauf-Erkrankungen sind somit die bei Weitem häufigste Ursache für einen frühzeitigen Tod in Österreich (siehe Abbildung 1). Zum einen bewirkt dies, dass Gesundheitszentren sowie Krankenkassen präventive Maßnahmen wie die Vorsorgeuntersuchung anbieten [9], da durch diese viele Todesfälle verhindert werden könnten. Zum anderen veranlasst diese Tatsache Mediziner und Forscher dazu, bestehende Früherkennungssysteme zu verbessern oder gar neu zu entwickeln. Um solche Systeme konzipieren und testen zu können, sind verlässliche und gut aufbereitete Datensätze von Herzpatienten erforderlich. Als Basis dienen dabei unter anderem die durch den Elektrokardiograph ermittelten Daten – diese werden im sogenannten Elektrokardiogramm (EKG) dargestellt.




Abbildung 1: Herz-Kreislauf-Erkrankungen als Todesursache Nummer 1 [4]

1.1 ZIEL DER ARBEIT

Das Ziel dieser Arbeit besteht darin, auf Basis von von Medizinern annotierten EKG-Daten einen Algorithmus zu entwickeln, der EKG-Aufzeichnungen von verschiedenen Herzpatienten analysiert und klassifiziert. Dabei gilt es die Herzschläge, Herzrhythmusstörungen bzw. Anomalitäten von gesunden Herzrhythmen zu unterscheiden. Der Algorithmus soll diese entsprechende Klassifikation mit hohem Exaktheitsgrad, also minimalem Fehler, vornehmen.

1.2 MOTIVATION

Ein solches Klassifikationssystem ist z.B. sehr hilfreich für die Annotationen von Langzeit-EKGs, die diagnostisch sehr wichtig, aber sehr mühsam von Hand

auszuwerten sind. Dieser Algorithmus soll ein Beitrag zum Entwurf der eingangs erwähnten Früherkennungs- und Monitoring-Systeme sein, die wiederum rechtzeitig Herz-Kreislauf-Erkrankungen erkennen sollen, um frühzeitige Tode zu verhindern.

1.3 ÜBERBLICK

Einen kurzen Überblick über den Aufbau und die Struktur dieser Arbeit:

Kapitel 2: Zu Beginn werden Grundlagen über die Physiologie des Herzens sowie die Funktion eines Elektrokardiogramms erläutert. Besonderes Augenmerk wird dabei auf den physiologische Zusammenhang zwischen Herz und Elektrokardiogramm gelegt.

Kapitel 3: Im 3. Kapitel wird der verwendete Datensatz näher beleuchtet, wobei auf die unterschiedlichen Herzschläge detailliert eingegangen wird.

Kapitel 4: Hier geht es um eine entsprechende Aufbereitung der vorhandenen Daten. Für die notwendige Vorverarbeitung der Daten gibt es mehrere Methoden. Das Kapitel behandelt Statistiken höherer Ordnung und Hermitesche Basisfunktionen.

Kapitel 5: Das 5. Kapitel umfasst den Hauptkern dieser Arbeit. Es werden zwei Methoden zur Klassifizierung der Daten vorgestellt und im Weiteren gegenübergestellt, nämlich die Support Vektor Maschine als Beispiel eines Klassifikationsverfahrens und die Selbst Organisierte Karte als Beispiel eines Clustering-Verfahrens.

Kapitel 6: Im 6. Kapitel werden die einzelnen Resultate sowie der Vergleich der Resultate beider Methoden zur Klassifizierung veranschaulicht und interpretiert.

Kapitel 7: Es wird in einer Diskussion Stellung zu den einzelnen Resultaten der Arbeit genommen sowie die Schwächen, Stärken und Limitationen angesprochen.

Kapitel 8: Der Ausblick umfasst Fragestellungen sowie Ideen zur weiteren Umsetzung, die über diese Arbeit hinausgehen. Das Fazit umschließt die Ziele, die in dieser Arbeit erreicht wurden.

Kapitel 9: Im Anhang befinden sich Beschreibungen zu den implementierten Funktionen der einzelnen Methoden.

2 | GRUNDLAGEN

Zu Beginn wird kurz auf die Physiologie und die Anatomie des Herzens sowie die Überleitung vom Herzzyklus auf das Elektrokardiogramm eingegangen.

Falls nicht anders angegeben, basiert dieses Kapitel auf der Literatur von Lippert [26], von Klinker und Silbernagl [21] sowie von Guyton & Hall [14].

2.1 HERZ

2.1.1 Aufbau und Funktion des Herzens




Abbildung 2: Das Herz als Pumpe bildet mit Lungen- und Körperkreislauf ein geschlossenes System [19].

Das Herz ist ein Hohlmuskel, der mit rhythmischen Kontraktionen 4 bis 6 Liter Blut pro Minute durch die Gefäße des Körpers presst. Bei extremer körperlicher Anstrengung kann es sogar das 4- bis 7-fache dieser Menge pumpen [14].

Das Herz wird in zwei Hälften unterteilt (siehe Abbildung 2), also in zwei separate Pumpen in einem geschlossenen Kreislaufsystem. Die rechte Herzhälfte pumpt das Blut durch die Lunge, das entspricht dem kleinen Kreislauf. Die linke Herzhälfte pumpt das Blut durch den (übrigen) Körper, das entspricht dem großen Kreislauf. Das „rechte Herz“ und das „linke Herz“ (jede dieser Hälften) bestehen wiederum aus zwei Teilen, aus einem Atrium (Vorhof) und einem Ventrikel (Kammer), die durch Herzklappen (Segelklappen: Trikuspidalklappe, Mitralklappe; Taschenklappen: Pulmonalklappe, Aortenklappe) miteinander verbunden sind ([14] S. 96 und 103, [26] S.46-47).

2.1.2 Zyklus des Herzens

Der Herzzyklus geht nun folgendermaßen vonstatten, siehe Abbildung 3:

Die obere und untere Hohlvene füllt den rechten Vorhof mit sauerstoffarmem Blut aus dem Körper, dieses gelangt über die Trikuspedalklappe in die rechte Kammer. Diese zieht sich zusammen und das Blut wird über die Pulmonalklappe durch die Lungenarterie in den Lungenkreislauf gepumpt. Das durch den kleinen Kreislauf und die Lungenvenen zirkulierende, nun sauerstoffreiche Blut wandert in den linken Vorhof und weiter über die Mitralklappe in die linke Kammer. Durch Kontraktion der linken Kammer wird das Blut über die Aortenklappe durch die Aorta dem Körperkreislauf zugeführt. Es ist erforderlich, dass beide Herzhälften dieselbe Blutmenge pro Zeiteinheit auswerfen, um eine Stauung zu verhindern. Das passiert durch gleichzeitige Kontraktion der linken und der rechten Kammer.

Der Körperkreislauf (große Kreislauf) ist der Weg des Blutes von der linken Herzkammer zum rechten Vorhof, während der Lungenkreislauf (kleiner Kreislauf) der Weg des Blutes von der rechten Herzkammer zum linken Vorhof ist. Der Weg des Blutes von der linken Herzkammer über die Aorta zu den Arterien des großen Kreislaufs stellt ein Hochdrucksystem dar. Der übrige Verlauf des Kreislaufs ist ein Niederdrucksystem ([26], S. 46-47). Aufgrund dieser Druckunterschiede öffnen und schließen die Klappen passiv. Sie bewirken, dass das Blut immer nur in eine Richtung durch den Körper transportiert wird. Die Trikuspidal- und Mitralklappe verhindern somit das Ausströmen des Blutes in die Venen (zuführende Gefäße) zurück, die Aorten- und Pulmonalklappe ein Ausströmen des Blutes aus den Arterien (abführende Gefäße) in das Herz zurück ([26], S. 209).

Der Blutfluss wird also durch abwechselnde Kontraktion und Entspannung des Herzmuskels gesteuert. Die Entspannungsphase der Kammern nennt man Diastole und die Anspannungsphase der Kammern Systole. Während der Diastole füllt sich das Herz mit Blut, während der Systole strömt das Blut aus. Der sich wiederholende Vorgang einer Diastole und der Systole wird als Herzzyklus bezeichnet ([14], S. 99 und [26], S. 210). Genauer kann man den Herzzyklus noch in 4 verschiedene Phasen unterteilen, wenn man den Druckverlauf im Vorhof miteinbezieht, das heißt die Anspannungs-, Austreibungs-, Entspannungs- und Füllungsphase ([26], S. 210).




Abbildung 3: Phasen des Herzzyklus für das linke Herz; Zusammenhang zwischen EKG und Herzzyklus; Druckverläufe; Verhalten der Klappen [43].

2.1.3 Erregungsausbreitung im Herzen

Das Erregungsleitungssystem im Herzen kann in 4 Bereiche gegliedert werden (siehe Abbildung 4): Sinusknoten, Atrioventrikularknoten (AV-Knoten), Atrioventrikulärbündel und Purkinje-Fasern ([26] S. 213-214, [21], S. 126).

Der Sinusknoten ist der primäre natürliche Taktgeber oder Herzschrittmacher und liegt an der Einmündungsstelle der oberen Hohlvene im rechten Vorhof. Dort entstehen die automatischen rhythmischen Erregungen des Herzens (Sinusrhythmus mit Herzfrequenz 60-80 Schläge/min), die sich dann über beide Vorhöfe mit einer Geschwindigkeit von 0.3-0.6 m/s bis zum AV-Knoten ausbreiten ([21], S. 126).

Der sogenannte Atrioventrikularknoten befindet sich an der Grenze zwischen dem Vorhof und der Kammer (Atrium-Ventrikel) und vollbringt nach Abschluss der Füllungsphase die verzögerte Überleitung der Erregung auf die Kammern. Der AV-Knoten bildet ebenso rhythmische Erregungen, aber mit niedrigerer Frequenz (40 Schläge/min) als die des Sinusknotens, weshalb er als sekundärer Taktgeber oder Herzschrittmacher bezeichnet wird. Die Sinuserregung ist im Normalfall durch die höhere Frequenz stärker, sodass die Eigenerregung des AV-Knotens untergeht. Fällt der Sinusknoten jedoch aus, werden die Kammern durch den Rhythmus des AV-Knotens erregt.

Der AV-Knoten - die einzige leitende Verbindung zwischen Vorhof und Kammer - ist der verdickte Anfang des Atrioventrikulärbündels, das sogenannte His-Bündel (nach Wilhelm His). Die Erregungsausbreitung in den Kammern erfolgt




Abbildung 4: Das Erregungsleitsystem im Herzen durch 1 den Sinusknoten, 2 den Atrioventrikularknoten (AV-Knoten), 3 die Atrioventrikulärbündel und 4 die Purkinje-Fasern [15].

dann mit einer Geschwindigkeit von 1 - 4 m/s über dieses Bündel, das sich in Richtung Herzspitze in einen rechten und linken Kammerschenkel spaltet. An den Enden zweigen sich Äste in die sogenannten Purkinje-Fasern oder -Fäden (nach Jan Evangelista Purkinje) auf, die in den Ventrikelmyokard eingebettet sind (Muskulatur der Herzkammern).

Die Erregungsleitung vom Sinusknoten bis zum Ventrikelmyokard dauert ca. 150 ms - nach ca. 210 ms ist das ganze Herz erregt.

Das Wissen über das System der Erregungsleitung ist Voraussetzung für das Verstehen eines Elektrokardiogramms ([26], S. 213-214 und [21], S.126-128).

2.2 ELEKTROKARDIOGRAPHIE

Ein Elektrokardiogramm (EKG) ist Ausdruck der elektrischen Herzerregung in Form von Spannungskurven mit Spitzen von ca. 1 mV. Es gibt Auskunft über Herzrhythmus, Herzfrequenz sowie über eventuelle Störungen in der Erregungsbildung, -leitung oder -ausbreitung. Daraus sind verschiedene mögliche Herzerkrankungen ablesbar ([21], S. 134).

2.2.1 Ableitung des EKG

Zwischen erregten und unerregten Herzmuskelzellen ergibt sich eine Potentialdifferenz - sie verhalten sich wie ein Dipol. Man kann diese Ladungsdifferenz durch einen Vektor darstellen, dessen Richtung und Länge für die Lage und Größe des Dipols stehen. Diese verändern sich im Laufe der Erregungsausbreitung. Vektorpfeile zeigen immer von erregten zu unerregten Herzmuskelzellen. Die Summe dieser einzelnen Vektoren bildet den Integralvektor. Die sogenannte Vektorschleife resultiert aus der Verbindung der Spitzen dieser Vektoren. Das elektrische Feld des Dipols breitet sich durch die wandernde Erregung im ganzen Körper aus. Durch Elektroden an der Körperoberfläche wird nun genau diese Größe der Po-

tenzialschwankungen innerhalb dieses Feldes gemessen. Sie hängt ab von Spannung des Dipols sowie Lage und Abstand der Ableitelektroden zum Dipol. Es gilt: Je mehr erregte Herzmuskelfasern, desto größer ist die Ladungsdifferenz und somit die Zacke im EKG. Außerdem ist die Potentialdifferenz bei paralleler Anordnung der Ableitelektroden zum Dipol am größten, bei senkrechter am kleinsten. Weiters sinkt die Höhe der Ausschläge mit dem Quadrat des Abstands vom Dipol. Die Vektorschleife wird nun auf Paare von Messelektroden, gegenüberliegend vertikal und horizontal auf Höhe des Herzens angebracht, projiziert und verursacht Potentialdifferenzen zwischen den Elektroden ([21], S. 129-134). An den Enden eines jeden Kanals gibt es zwei Elektroden zu unterscheiden: die Ableit- und die Bezugselektrode (differente und indifferente Elektrode). Elektroden mit entgegengesetzter Polarität stehen für bipolare Ableitungen, eine unipolare Ableitung stellt eine positive Ableitung mit einem Referenzpunkt dar. In einem Standard-Oberflächen-EKG sind die 6 Extremitätenableitungen I, II, III, aVR, aVL, aVF sowie die 6 Brustwandableitungen V_1 - V_6 enthalten (Extremitäten stehen für Arme und Beine). Die Höhe der einzelnen Zacken/des Signals im EKG ist also von der Ladungsdifferenz in der Vektorrichtung der jeweiligen Ableitung abhängig ([40], S. 4).




Abbildung 5: Brustwandableitungen nach Wilson. Elektroden sind verbunden mit Elektrokardiograph [20].

Ableitungen nach Einthoven

Die Standardableitungen nach Einthoven sind die bipolaren Extremitätenableitungen I, II, III. Willem Einthoven (1860 - 1927) stellte 1906 das erste menschliche EKG auf. Die Ableitung I misst die Potentialdifferenz zwischen rechtem und linkem Arm, die Ableitung II zwischen rechtem Arm und linkem Fuß und die Ableitung III zwischen linkem Arm und linkem Fuß. Die Übergänge zwischen den Extremitäten stellen die Kanten eines gleichseitigen Dreiecks dar - das sogenannte Einthoven-Dreieck ([26], S. 132). Die Summe der Spannungen in den Ableitungen I und III ist gleich der Spannung in der Ableitung II nach Einthoven - diese Gleichung wird das Gesetz von Einthoven genannt. Die Projektion der Vektorschleife findet nur in der Frontalebene statt.

Ableitungen nach Goldberger

Die mit der differentiellen Elektrode gemessenen Potenziale am rechten Arm (VR), am linken Arm (VL), am linken Fuß (VF) haben das Problem, dass sie zu klein sind. Emanuel Goldberger (1913 - 1994) hatte die Idee, die Amplituden von VR,

VL und VF zu verstärken, indem eine der Extremitäten(elektrode) als differente Elektrode gegen die Vereinigung der beiden anderen Extremitäten zu einer indifferenten Elektrode abgeleitet wird. Die dadurch entstehenden verstärkten Messsignale aVR, aVL, aVF sind die unipolaren Extremitätenableitungen nach Goldberger.

Ableitungen nach Wilson

Norman Wilson (1890 - 1952) determinierte 1934 die Positionen der unipolaren Brustwandableitungen $V_1 - V_6$, um eine horizontale Vektorprojektion der elektrischen Aktivitäten des Herzens zu erhalten. Werden die drei Extremitäten (VR rechter Arm, VL linker Arm, VF linker Fuß) über hochohmige Widerstände zu einer indifferenten Elektrode zusammengeschaltet, können gegen diese Elektrode verschiedene Positionen an der Körperoberfläche mit einer differenten Elektrode abgeleitet werden (siehe Abbildung 5).

2.2.2 Analyse des EKG

Hier wird der physiologische Zusammenhang zwischen der Erregungsausbreitung am Herzen und den Kurven in einem EKG untersucht. Siehe dazu die Abbildung 6.




Abbildung 6: Zur Analyse eines Oberflächen-EKG eine schematische Darstellung der EKG-Zacken in Relation zu den elektrischen Vorgängen im Herzen anhand eines normalen Herzschlags [2].

Bedeutung der einzelnen EKG-Zacken und ihre typischen Merkmale für einen gesunden Herzrhythmus:

Ein Herzschlag wird unterteilt in P-Welle, QRS-Komplex und T-Welle:

- P-Welle = Erregungsausbreitung in den Vorhöfen (Vorhofdepolarisation)
 - P = „halbrund“, glatt, konvexbogig, positiv, Dauer 0.05-0.1 sek
- PQ-Zeit = Überleitungszeit der Erregungsleitung vom Vorhof auf die Kammern (0.12-0.2 sek)
- QRS-Komplex = Erregungsausbreitung in den Kammern (Kammerdepolarisation), Dauer 0.06-0.1 sek

- Q = klein, spitz, negativ
- R = schlank, schmal, spitz, positiv
- S = schlank, schmal, spitz, negativ
- ST-Strecke und T-Welle = Erregungsrückbildung in den Kammern (Kammerrepolarisation)
 - ST-Strecke = geradlinig, isoelektrisch
 - T-Welle = halbrund, glatt, positiv
- QT-Zeit = Gesamte Erregungsdauer in den Kammern

Begriff der Herzrhythmusstörungen:

Herzrhythmusstörungen, Störungen in der Herzschlagfolge kann man im Allgemeinen in zwei Kategorien teilen: in Störungen der Erregungsbildung und in Störungen der Erregungsleitung.

- Störungen der Erregungsbildung:

Der Rhythmus des Herzschlages wird im Normalfall durch den Sinusknoten bestimmt.

Wird er zu schnell, beginnt das Herz zu rasen. Das nennt man allgemein *Tachykardie*. Gibt der Sinusknoten die Impulse zu langsam ab, schlägt das Herz langsamer (*Bradykardie*). Wird die Herzschlagfolge unregelmäßig, so ist das Herz aus dem Takt (*Arrhythmie*).

Das Erregungsleitungssystem (AV-Knoten, His-Bündel, Purkinje-Fasern) unterliegt dem Kommando des Sinusknotens. Ignoriert es diesen und schickt unabhängig von ihm Erregungen, so entstehen plötzlich zwei Erregungsbildungszentren, die miteinander konkurrieren. Es können zusätzliche Herzschläge (*Extrasystolen*), kammerbedingtes Herzrasen (sog. *Kammertachykardie*, *Kammerflattern*, *-flimmern*) oder Doppelrhythmen (*Frequenzdissoziation*) auftreten. Extrasystolen haben ihren Ursprung nicht im Sinusknoten. Erregungen außerhalb des Sinusknotens an einem abnormen Ort nennt man ektop. Man unterscheidet zwischen *ventrikulären Extrasystolen* (Herzkammern) und *supraventrikulären Extrasystolen* (Herzvorhöfe), je nach Ort der Entstehung im Herzen.

- Störungen der Erregungsleitung:

Die Erregungsleitung verläuft im Normalfall vom AV-Knoten über das His-Bündel, den Schenkeln und Purkinjefasern zu den Herzmuskelzellen. In diesem Verlauf können Störungen auftreten, z.B. zwischen Sinusknoten und Vorhof (*sinuatrialer Block* = SA-Block), zwischen Vorhof und AV-Knoten (*atrioventrikulärer Block* = AV-Block) oder innerhalb der linken und rechten Kammerschenkel (*linker, rechter Schenkelblock*).

Die verschiedenen Blöcke kann man noch unterteilen oder abstufen nach Schweregrad. *Schweregrad 1*: die Überleitung wird nur verzögert. *Schweregrad 2*: teilweise unterbrochen, es gibt zwei Möglichkeiten - entweder die Überleitung wird zunehmend verzögert bis sie ausfällt und beginnt dann wieder neu mit dieser Periodik, oder die Überleitung fällt zwischendurch unerwartet aus. *Schweregrad 3*: Die Überleitung ist vollkommen gestört (komplett unterbrochen = total) ([26], S. 215).

3 | DATEN

Die verwendeten Daten stammen aus der MIT-BIH Arrhythmien Datenbank, die vom Massachusetts Institute of Technology sowie vom Beth Israel Hospital, heute Israel Deaconess Medical Center, 1980 erstellt wurde [29]. Diese wird von PhysioNet online frei zur Verfügung gestellt und enthält eine große Sammlung von aufgezeichneten physiologischen Signalen [34]. PhysioNet garantiert die Anonymisierung der Daten, daher können sie ohne weitere Zustimmung einer Ethik-Kommission verwendet werden [13, 31].

3.1 DATENSATZ

Die MIT-BIH Arrhythmien Datenbank umfasst 48 halbstündige Ausschnitte von zweikanaligen ambulanten EKG-Aufzeichnungen. Diese stammen von 47 verschiedenen Personen (25 Männer im Alter von 32 bis 89 Jahren und 22 Frauen im Alter von 23 bis 89 Jahren) [34].

Die vom BIH gesammelten Daten bilden insgesamt eine Menge von 4000 ambulanten 24-stündigen EKG-Aufzeichnungen von stationär behandelten Patienten (60%) und ambulant behandelten Patienten (40%). 23 der 48 Aufnahmen wurden zufällig aus dieser großen Menge gewählt, die restlichen 25 wurden aus derselben Menge ausgewählt, um auch weniger häufige aber klinisch signifikante Arrhythmien mit in die Datenbank aufzunehmen, die ansonsten in einer kleinen zufälligen Stichprobe nicht gut repräsentiert werden würden [34].

Die Abtastrate der Aufzeichnungen ist 360 Hz (360 Samples pro Sekunde).

Jedes EKG-Signal aus der MIT-BIH Arrhythmien Datenbank wurde von Kardiologen annotiert. Es gibt ca. 110.000 Annotationen, also liegen ca. 110.000 Herzschläge vor. Davon sind ca. 70% nichtpathologisch und ca. 30% pathologisch [34].

3.2 HERZSCHLÄGE

Es werden nun 15 verschiedene Klassen von Herzrhythmen aus dieser Datenbank beispielhaft vorgestellt (vgl. EKG Kurs Isabel [40], Graphiken stammen aus der Datenbank [29, 34]). Neben dem normalen Herzrhythmus sind es 14 Arrhythmien, die im Zuge dieser Arbeit mit verschiedenen Methoden klassifiziert werden (siehe Abbildung 7). Dabei ist anzumerken, dass die Gruppe der supraventrikulären Extrasystolen aufgrund der geringen Anzahl von nur 2 Herzschlägen nicht abgehandelt wurde. Obwohl sie in der Datenbank vorkommt, wurde sie von Beginn an entfernt.

Es ist zu erwähnen, dass der Unterschied zwischen einem premature beat und einem escape beat durch ein vorzeitiges bzw. verzögertes Einsetzen/Auftreten vor bzw. nach einer langen Pause (meist zwischen zwei normalen Herzschlägen) bei gleichem Kurvenverlauf im EKG gekennzeichnet ist.




Abbildung 7: Häufigkeiten der einzelnen Gruppen im Datensatz. Man merkt, dass bestimmte Gruppen stark unterbesetzt sind (logarithmische Skala) und andere stark überwiegen. Für die Bedeutung der Buchstaben wird auf die Tabelle 1 verwiesen.

Tabelle 1: Auflistung der verschiedenen Typen von Herzschlägen oder Herzrhythmen in der MIT-BIH Datenbank [29, 34].

	Herzschläge	Abkürzung
1.	normaler Herzschlag, normal beat	N
2.	Linksschenkelblock, left bundle branch block beat	L
3.	Rechtsschenkelblock, right bundle branch block beat	R
4.	atrial premature beat	A
5.	aberrated atrial premature beat	a
6.	nodal (junctional) premature beat	J
7.	ventricular premature beat	V
8.	fusion of ventricular and normal beat	F
9.	Kammerflattern, ventricular flutter wave	I
10.	atrial escape beat	e
11.	nodal (junctional) escape beat	j
12.	ventricular escape beat	E
13.	paced beat	P
14.	fusion of paced and normal beat	f
15.	unklassifizierbarer Herzschlag, unclassifiable beat	Q

Allgemein haben beide ihren Ursprung in einem atrialen, junktionalen oder ventrikulären ektopen Fokus.

Die Typen mit Unterscheidung zwischen Premature und Escape Beats werden im Folgenden nur mit Graphiken von Premature Beats vorgestellt.

3.2.1 Normaler Herzschlag (N)




Abbildung 8: Normaler Herzschlag als Ausschnitt vom Record 115 aus der MIT-BIH Arrhythmien Datenbank mit dem zeitlichen Intervall von 2 s für jede der Ableitungen MLII und V1.

Der normale Herzrhythmus entspricht dem Sinusrhythmus (siehe Abbildung 8), der auf natürliche Weise mit einer Frequenz zwischen 60-100 Schläge/min durch den Sinusknoten hervorgerufen wird.

Regelmäßige Sinusrhythmen sind auch die Sinusbradykardie mit einer Frequenz von unter 60 Schläge/min und die Sinustachykardie mit einer Frequenz von über 100 Schläge/min, sie zählen aber zu den Herzrhythmusstörungen ([40], S.28-29, 126). Siehe auch zu Kapitel 2 (Analyse des EKGs, Herzrhythmusstörungen).

Merkmale oder Kennzeichen des normalen Herzschlages im EKG:

- PP-Intervalle (Intervall zwischen zwei aufeinanderfolgenden P-Wellen) konstant
- P-Welle regulär, „halbrund“, positiv
- Verhältnis P-Welle / QRS-Komplex konstant
- $Q < \frac{1}{4}R$, $P < 0.25 \text{ mV}$, $T = \frac{1}{6}R$ bis $\frac{2}{3}R$
- PQ-Zeit liegt zwischen 0.12-0.20 Sekunden, QRS-Zeit liegt zwischen 0.06-0.10 Sekunden

3.2.2 Linksschenkelblock (L), Rechtsschenkelblock (R)




Abbildung 9: Linksschenkelblock (a) und Rechtsschenkelblock (b) als Ausschnitte von den Records 111 und 212 aus der MIT-BIH Arrhythmien Datenbank mit dem zeitlichen Intervall von jeweils 2 s für jede der Ableitungen MLII und V1.

Schenkelblock steht für eine Störung im Bereich der Kammerleitungsschenkel (Tawara Schenkel, rechter und linker Schenkel). Die Ventrikel werden nicht gleichzeitig - wie im Normalfall - sondern hintereinander erregt.

Bei komplettem Linksschenkelblock (LSB) ist die Erregungsausbreitung im linken Schenkel vollständig unterbrochen, der linke Ventrikel wird also später erregt. Bei komplettem Rechtsschenkelblock (RSB) liegt eine entsprechende Leitungsstörung im rechten Schenkel vor. Intraventrikuläre Leitungsstörungen äußern sich in einer Verbreiterung und Deformierung des QRS-Komplexes ([40], S. 43-46), wie man in den Abbildungen 9 sieht.

Merkmale oder Kennzeichen des Links- und Rechtsschenkelblocks im EKG:

- Verlängerung des QRS-Komplexes ≥ 120 ms (Norm des QRS-Komplexes 0.06-0.10 s)
- absteigende ST-Strecke
- negative, abgeflachte T-Welle
- RSB:
 - „M-förmige“ Deformierung des QRS-Komplexes in den Ableitungen V_1, V_2
 - breite plumpe/unförmige tiefe S-Zacke in den Ableitungen I, aVL, V_6
- LSB:
 - „M-förmige“ Deformierung des QRS-Komplexes in den Ableitungen V_5, V_6, I, aVL
 - plumpe deformierte R-Zacke in V_5, V_6
 - breites plumpes Q in V_1 oder Q-Zacken fehlen

3.2.3 Atrial premature beat (A), atrial escape beat (e)




Abbildung 10: Atrial premature beat als Ausschnitt vom Record 232 aus der MIT-BIH Arrhythmien Datenbank mit dem zeitlichen Intervall von 3.3 s für jede der Ableitungen MLII und V1.

Atrial Premature Beats entstehen meist im rechten Vorhof weit entfernt vom Sinusknoten, in sogenannten ektopen Erregungszentren (ektopter Fokus) ([40], S. 8). Ein Fokus im unteren rechten Vorhof führt zu negativen P-Wellen in den Ableitungen aVF, III (und II). Eine negative P-Welle in I, aVL und V₆, V₅ kann entweder ektopen Ursprung im rechten oder linken Atrium haben. Das vorzeitige Eintreffen des Beats ist nicht konstant. Die Pause nach einem Atrial Premature Beat zeigt in der Regel nicht die volle Kompensation (siehe Abbildung 10). Wenn die P-Welle in die T-Welle des vorhergehenden Herzzyklus fällt, kann es schwierig sein, sie zu identifizieren. Eine Zacke an der T-Welle bedeutet eine überlagerte P-Welle ([12], S. 197).

Merkmale oder Kennzeichen eines atrial premature beat im EKG:

- deformierte P-Welle
- positive P-Welle in V₁
- negative P-Welle in den Ableitungen aVF, III (und II) und V₂ - V₆
- kurze PQ-Zeit ≥ 0.12 sek

3.2.4 Aberrated atrial premature beat (a)




Abbildung 11: Aberrated atrial premature beat als Ausschnitt vom Record 201 aus der MIT-BIH Arrhythmien Datenbank mit dem zeitlichen Intervall von 2 s für jede der Ableitungen MLII und V1.

Aberrated Atrial Premature Beats stellen eine Unterform der Atrial Premature Beats des vorigen Abschnitts dar. Abweichungen des Atrial Premature Beat bemerkt man am Auftreten eines Rechtsschenkelblocks (siehe R oben und vgl. mit der Abbildung 11).

Merkmale oder Kennzeichen eines atrial premature beat im EKG:

- schenkelblockartige, „M-förmige“ Deformierung der QRS-Komplexe

3.2.5 Nodal (junctional) premature beat (J), nodal (junctional) escape beat (j)




Abbildung 12: Nodal (junctional) premature beat als Ausschnitt vom Record 234 aus der MIT-BIH Arrhythmien Datenbank mit dem zeitlichen Intervall von 2 s für jede der Ableitungen MLII und V1.

Der AV-junktionale Herzrhythmus wird am Übergang vom Vorhof zur Kammer hervorgerufen, was der Region um den AV-Knoten entspricht. Ursachen sind Sinusknotenstillstand, d.h. wenn der erste natürliche Herzschrittmacher, der Sinusknoten, ausfällt und keine Erregung einleitet, oder sinuatriale Überleitungsstörungen (in diesem Fall komplette Unterbrechung im Übergang vom Sinusknoten zum Vorhof). Der AV-junktionale Herzrhythmus übernimmt dann die Funktion des primären Schrittmachers und wird AV-junktionaler Ersatzrhythmus genannt.

Der AV-junktionale Herzrhythmus kann aber auch entstehen, wenn die Erregung des Sinusknotens von einer Reizbildung in der Umgebung des AV-Knotens überholt wird. Da diese dann einen eigenen beschleunigten Rhythmus (höhere Erregungsfrequenzen) erzeugt als Antwort auf einen zu langsam aktiven Sinusknoten. Man nennt dies die AV-junktionale Tachykardie ([40], S. 38-40).

Merkmale oder Kennzeichen eines AV-junktionalen Rhythmus im EKG:

- schmale QRS-Komplexe (siehe Abbildung 12)
- keine P-Welle bei keiner retrograden Leitung auf die Vorhöfe
- P-Welle am Ende des QRS-Komplex oder nach dem QRS-Komplex, wenn eine retrograde Leitung schnell oder langsam auf die Vorhöfe erfolgt

3.2.6 Ventricular premature beat (V), ventricular escape beat (E)




Abbildung 13: Ventricular premature beat als Ausschnitt vom Record 200 aus der MIT-BIH Arrhythmien Datenbank mit dem zeitlichen Intervall von 2 s für jede der Ableitungen MLII und V1.

Ventrikuläre Extrasystolen (vgl. Abbildung 13) gehören zusammen mit ventrikulärer Tachykardie, Kammerflattern und -flimmern zu den ventrikulären Herzrhythmusstörungen. Entstehungsort dieser Extrasystolen ist im ganzen Ventrikelmyokard möglich. Man unterscheidet zwischen monomorphen und polymorphen Extrasystolen, je nachdem ob sie einen oder mehrere Entstehungsorte im Ventrikel haben. Monomorphe Extrasystolen sehen gleich aus, polymorphe weisen verschiedene Formen auf. Ein bedeutendes Merkmal ist die kompensatorische Pause: Die normale Folge von RR-Intervallen wird gestört durch eine ventrikuläre Extrasystole. Der RR-Abstand zwischen dem vorhergehenden und dem nachfolgenden normalen Herzschlag ist zweimal so lang wie ein normales RR-Intervall. Die Sinusknotenerregung trifft auf die Kammer, die durch Extrasystole bereits depolarisiert ist und erst durch den nächsten Sinusimpuls wieder gereizt werden kann ([40], S. 105-108).

Merkmale oder Kennzeichen von ventrikulären Extrasystolen im EKG:

- frühzeitiger Einfall eines verbreiterten QRS-Komplexes (≥ 120 ms)
- P-Welle fehlt
- kompensatorische Pause
- Ursprung im rechten Ventrikel: linksschenkelblockartiger QRS-Komplex
- Ursprung im linken Ventrikel: rechtsschenkelblockartiger QRS-Komplex

3.2.7 Kammerflattern, Kammerflimmern (I)




Abbildung 14: Kammerflattern, Kammerflimmern als Ausschnitt vom Record 207 aus der MIT-BIH Arrhythmien Datenbank mit dem zeitlichen Intervall von 2 s für jede der Ableitungen MLII und V1.

Beim Kammerflattern liegt eine extrem gesteigerte Herzfrequenz vor, die meist in Kammerflimmern ausartet.

Kammerflimmern entspricht der totalen chaotischen Erregung/Impulsgebung des Herzens, was eindeutig abgrenzbar von einem herkömmlichen EKG-Signal ist (siehe Abbildung 14).

Kammerflattern und -flimmern sind lebensgefährliche Herzrhythmusstörungen. Schnelle ärztliche Versorgung sowie Maßnahmen zur Wiederbelebung müssen ergriffen werden, denn von allein kann sich dieser Herzrhythmus nicht mehr normalisieren ([40], S. 107-109).

Merkmale oder Kennzeichen des Kammerflatterns und -flimmerns im EKG:

- Kammerflattern
 - Kammerfrequenz > 250 Schläge/min
 - Deformierung des QRS-Komplexes
 - Breite des QRS-Komplexes ≥ 120 ms $\Rightarrow$ Schenkelblockartige Verbreiterung
- Kammerflimmern
 - Keine erkennbare Struktur des Elektrokardiogramms
 - Chaotische Oszillationen elektrokardiographischer Signale

3.2.8 Paced beat (P)




Abbildung 15: Paced beat als Ausschnitt vom Record 107 aus [29] mit dem zeitlichen Intervall von 2 s für die zwei Ableitungen MLII und V1.

Das sind Herzschläge, die durch einen künstlichen Herzschrittmacher entstehen (siehe Abbildung 15). Man erkennt diese an den höheren, verstärkten Ausschlägen - sogenannte „Schrittmacher-Spikes“. Es gibt Einkammer- oder Zweikammerschrittmacher als sogenannte Bedarfsschrittmacher, die bei bradykarden Rhythmusstörungen eingesetzt werden. Bei dem Einkammerschrittmacher-System unterscheidet man die AAI-Stimulation (Stimulation im Atrium, Wahrnehmung im Atrium, Inhibierung bei Eigenrhythmus) und die VVI-Stimulation (Stimulation im Ventrikel, Wahrnehmung im Ventrikel, Inhibierung bei Eigenrhythmus). Die Schrittmacherelektrode befindet sich also entweder im rechten Vorhof oder in der rechten Kammer, je nachdem ob die AV-Überleitung vom Vorhof zur Kammer noch intakt ist. Ein Zweikammerschrittmacher-System versucht bei der DDD-Stimulation ($D=A+V=I+T$ steht für Double; Stimulation und Detektion im Atrium und Ventrikel, Inhibierung bei Eigenrhythmus und Triggern d.h. Auslösung bei Bedarf) eine Störung der AV-Überleitung durch zwei Elektroden durch Impulsgebung auszugleichen - eine Elektrode im rechten Vorhof und die andere in der rechten Kammer. Bei der VDD-Stimulation beschränkt man sich auf eine Elektrode im rechten Ventrikel, die Vorhofsignale durch atriale Ringelektroden erkennen kann und so den AV-Übergang stimuliert.

Merkmale oder Kennzeichen eines paced beat im EKG:

- Einkammerschrittmacher:
 - AAI-Stimulation: Vorhof-Spike, unauffälliger QRS-Komplex
 - VVI-Stimulation: Kammer-Spike, linksschenkelblockartige Deformierung des QRS-Komplexes (≥ 120 ms)
- Zweikammerschrittmacher:
 - DDD-Stimulation: Schrittmacher-Spikes im Atrium und Ventrikel, linksschenkelblockartige Deformation des QRS-Komplex (≥ 120 ms)
 - VDD-Stimulation: spontane P-Welle, AV-sequentielle Stimulation mit rechtsventrikulärer Impulsabgabe

3.2.9 Vermischung von Herzschlägen




Abbildung 16: Fusion of ventricular and normal beat als Ausschnitt vom Record 208 aus der MIT-BIH Arrhythmien Datenbank mit dem zeitlichen Intervall von 2 s für die zwei Ableitungen MLII und V1.

Ein Fusionsschlag ist die gleichzeitige Aktivierung der Ventrikel durch ein Erregungszentrum im Vorhof und durch eines in der Kammer. Die QRS-Dauer liegt zwischen der des supraventrikulären und der des ventrikulären QRS-Komplexes. In [Abbildung 16](#) sieht man in der Mitte einen resultierenden Fusionsschlag von ventrikulärem und normalem Herzschlag, in [Abbildung 17](#) in der Mitte von paced beat und normalem Herzschlag.




Abbildung 17: Fusion of paced and normal beat als Ausschnitt vom Record 217 aus der MIT-BIH Arrhythmien Datenbank mit dem zeitlichen Intervall von 2.8 s für die zwei Ableitungen MLII und V1.

3.2.10 Unklassifizierbarer Herzschlag (Q)




Abbildung 18: Unklassifizierbarer Herzschlag als Ausschnitt vom Record 104 aus der MIT-BIH Arrhythmien Datenbank mit dem zeitlichen Intervall von 2 s für die zwei Ableitungen V2 und V5.

Dieser Herzschlag in Abbildung 18 kann keinem Rhythmus zugeordnet werden, gleicht eher einem Rauschen. Das liegt möglicherweise darin, dass er weder einer Abfolge von regelmäßigen Zacken nachkommt noch den RR-Abstand mit einer bestimmten Frequenz einhält.

Sechs der 48 Datensätze enthalten insgesamt 33 Schläge, die nicht klassifiziert bleiben, weil die Kardiologen-Annotatoren nicht in der Lage waren, eine Einigung über die Schlagtypen zu erreichen. In diesen Fällen, passiert es gelegentlich, dass einige Schläge nicht mit Sicherheit zugeordnet werden können, entweder wegen technischer Defekte in der Aufnahme, oder weil es nicht genügend Informationen im Datensatz gibt [31].

Merkmale oder Kennzeichen:

- keiner der genannten Klassen zuweisbar

4

VORVERARBEITUNG

Im folgenden Kapitel wird die Vorverarbeitungs- und Aufbereitungsphase, die für die bessere Handhabung der Daten aus der MIT-BIH Arrhythmien Datenbank (siehe 3. Kapitel) erforderlich ist, um eine aussagekräftige Klassifikation der EKG-Daten in die verschiedenen Klassen im nächsten 5. Kapitel zu gewährleisten, erläutert.

Die Daten müssen gut aufbereitet werden, um sie später in der Klassifikation so verwenden zu können, dass auch gute Ergebnisse erzielt werden. Diese Phase ist eine sehr entscheidende, wenn nicht sogar die wichtigste, da ohne diese keine aussagekräftige Klassifikation vorgenommen werden kann.

Bei genauerer Betrachtung der EKG-Daten erkennt man nämlich sofort, dass selbst unter den Signalen derselben Gruppe von Herzschlägen eine hohe Variation besteht. Man könnte selbst diese nicht leicht einer gemeinsamen Klasse zuordnen, wenn nicht vorher eine entsprechende Vorverarbeitung erfolgt ist. Das liegt auch daran, dass viele Datensätze von verschiedenen Personen vorliegen, die sich schon alleine deshalb voneinander unterscheiden. Außerdem weisen alle Typen von Herzschlägen eine ähnliche Bandbreite von Amplituden und Frequenzen in einem EKG auf.

Es ist also schwierig, die verschiedenen Gruppen nur in Abhängigkeit von Zeit und Frequenz zu unterscheiden. Es braucht auch zusätzliche Informationen über formale Eigenschaften der Herzdaten, anhand dieser besser differenziert werden kann (vgl. [37], S. 583). Um diese Merkmale zu extrahieren, gibt es in der Literatur viele verschiedene Methoden. In dieser Arbeit werden zwei Methoden verwendet: die der Statistiken höherer Ordnung und die der Hermiteschen Basisfunktionen, die in den folgenden Unterkapiteln näher besprochen werden. Die Methoden basieren auf den Publikationen von S. Osowski et al. [37] und von M. Lagerholm et al. [27].

4.1 MERKMALSEXTRAKTION

Das EKG-Signal wird in die einzelnen Herzschläge zerlegt, wobei ein Herzschlag d Datenpunkte lang ist, sodass dann für n Herzschläge eine $n \times d$ - Matrix entsteht. Dazu wird jeder Herzschlag x an der annotierten R-Zacke detektiert und ein Intervall um R mit Intervalllänge d gewählt. Jeder i -te Herzschlag der Länge d wird dann zu einem Merkmalstupel y der Länge M (Feature vector) umgewandelt,

$$x^{(i)} = \left(x_1^{(i)}, x_2^{(i)}, \dots, x_d^{(i)} \right) \Rightarrow y^{(i)} = \left(y_1^{(i)}, y_2^{(i)}, \dots, y_M^{(i)} \right) \quad (4.1)$$

indem er durch seine Merkmale (Features) beschrieben wird. Diese stellen eine Annäherung an die Form der EKG-Daten, genauer der QRS-Verläufe der einzelnen Herzschläge dar. Dieser Merkmalstupel ist meist kürzer als die Länge eines Herzschlages, da oft schon wenige Merkmale ausreichen. Er entspricht somit den am meisten relevanten Aspekten eines jeden Herzschlages.

Dieses Kapitel beschreibt nun zwei Methoden zur Merkmalsextraktion - die Techniken, die verwendet wurden, um das Signal in eine Matrix von Merkmalstupeln zu transformieren.

4.1.1 HOS - Higher Order Statistics

Statistiken höherer Ordnung (Higher Order Statistics, HOS), wie Momente und Kumulanten, werden in der Signalverarbeitung zur Analyse von Signalen verwendet. Die Spektren höherer Ordnung oder auch Polyspektren genannt (Higher Order Spectra) sind multidimensionale Fouriertransformationen von den Statistiken höherer Ordnung. Beides, Statistiken und Spektren, enthalten Informationen über Amplituden und Phasen eines Signalprozesses (siehe [32], S. 15).

Allgemein: im Falle von stochastischen Signalen bringt die Verwendung von Kumulanten bestimmte Vorteile, während es für deterministische Signale besser ist, Momente zu gebrauchen ([32], S. 11). Bei den EKG-Daten handelt es sich um stochastische Signale, also sind im Weiteren nur die Kumulanten von Interesse. Diese werden aber über die Momente hergeleitet, wie man im folgenden Abschnitt sieht (vgl. [22], S. 3-18).

Das EKG-Signal $X(t)$ wird als stochastischer Prozess gesehen. Das ist eine Familie von Zufallsvariablen $\{X(t), t \in \mathbb{Z}\}$, d.h. $X(t)$ mit $t = 0, \pm 1, \pm 2, \pm 3, \dots$. Sei $X(t)$ außerdem ein reeller, zeit-diskreter, mittelwertfreier und stationärer Zufallsprozess.

Im Folgenden werden zunächst einige Grundbegriffe aus der Wahrscheinlichkeitstheorie und Statistik definiert:

Definition 4.1.1.1. Eine Zufallsvariable X ist eine Funktion, die den Ergebnisraum des Zufallsexperimentes Ω auf den Bereich der reellen Zahlen $\mathbb{R}$ abbildet $X : \Omega \rightarrow \mathbb{R}$.

Definition 4.1.1.2. Die Verteilungsfunktion $F_X(x)$ einer Zufallsvariablen X gibt die Wahrscheinlichkeit P an, mit der die Zufallsvariable X kleiner oder gleich dem konkreten Wert x ist: $F_X(x) = P(X \leq x)$.

Die Verteilungsdichtefunktion von X erhält man dann als Ableitung der Verteilungsfunktion: $f_X(x) = \frac{dF_X(x)}{dx}$.

Definition 4.1.1.3. Für eine kontinuierliche Zufallsvariable X ist der Erwartungswert definiert als $E[X] = \mu = \int_{-\infty}^{\infty} x f_X(x) dx$.

Definition 4.1.1.4. Stationäre stochastische Prozesse sind stochastische Prozesse bei denen sich die endlich-dimensionale Verteilungsfunktion bei einer Zeitverschiebung (näherungsweise) nicht ändert.

Definition 4.1.1.5. Ein stochastisches Signal X heißt mittelwertfrei, wenn sein Mittelwert für alle diskreten Zeitpunkte verschwindet, d.h. $E[X(t)] = 0 \quad \forall t$.

Zuerst wird eine Definition für die Momente eines Prozesses $\{X(t)\}$ formuliert, anhand dieser dann die dazugehörigen Kumulanten hergeleitet werden.

Definition 4.1.1.6. Die Momente einer Verteilungsdichtefunktion einer Zufallsvariablen X werden durch $m_{nx} := E[x^n] = \int_{-\infty}^{\infty} x^n f_X(x) dx$ als n -tes Moment definiert.

Durch konjugiert komplexe Fouriertransformation der Verteilungsdichtefunktion $f_X(x)$ einer Zufallsvariablen X erhält man die sogenannte momentenerzeugende Funktion (moment generating function, MGF; auch als charakteristische Funktion bekannt) M_X der Zufallsvariablen X :

$$M_X(\omega) = \int_{-\infty}^{\infty} e^{j\omega x} f_X(x) dx = E[e^{j\omega x}]. \quad (4.2)$$

Entwickelt man die momentenerzeugende Funktion um den Punkt $\omega = 0$ in eine Taylorreihe,

$$M_X(\omega) = E \left[\sum_{n=0}^{\infty} \frac{(j\omega x)^n}{n!} \right] = \sum_{n=0}^{\infty} \frac{(j\omega)^n}{n!} E[x^n] = \sum_{n=0}^k \frac{(j\omega)^n}{n!} E[x^n] + Rest,$$

bekommt man als Koeffizienten der Taylor-Reihenentwicklung die Momente der Verteilungsdichtefunktion laut Definition der Momente oben:

$$m_{nx} := E[x^n]. \quad (4.3)$$

Ähnlich wie die Momente werden die Kumulanten hergeleitet. Die kumulantenerzeugende Funktion (cumulant generating function, CGF) K_X entsteht durch Logarithmierung der momentenerzeugenden Funktion:

$$K_X(\omega) = \ln(M_X(\omega)) = \ln(E[e^{j\omega x}]). \quad (4.4)$$

Durch Logarithmierung bleiben die gleichen Informationen über die Eigenschaften der Verteilungsdichtefunktion erhalten, da die Logarithmusfunktion eine strenge Monotonie aufweist. Eine Taylor-Entwicklung der kumulantenerzeugenden Funktion um $\omega = 0$ ist daher gleich

$$K_X(\omega) = \sum_{n=0}^k \frac{(j\omega)^n}{n!} k_{nx} + Rest.$$

Man kann also gleich die Kumulanten k_{nx} in Form der Taylor-Koeffizienten ablesen. Da die Entwicklung in eine Taylorreihe diese Form besitzt,

$$K_X(\Delta\omega) = K_X(0) + \frac{(\Delta\omega)}{1!} K'_X(0) + \dots + \frac{(\Delta\omega)^k}{k!} K_X^k(0) + Rest,$$

können wir nun eine Definition der Kumulanten formulieren.

Definition 4.1.1.7. Die n -te Kumulante oder Kumulante der Ordnung n der Verteilung von X ist

$$k_{nx} := (-j)^n \frac{d^n K_X(\omega)}{d\omega^n} \Big|_{\omega=0}. \quad (4.5)$$

Kumulanten der 2., 3. und 4. Ordnung entsprechen den Koeffizienten der Taylor-Entwicklung der kumulantenerzeugenden Funktion.

Angenommen es existieren für das EKG-Signal $\{X(t), t \in \mathbb{Z}\}$ mit den eingangs eingeführten Eigenschaften dessen Momente bis zur Ordnung n (siehe [32], 15-16). Dann entspricht das n -te Moment nach Definition

$$m_{nx}(\tau_1, \tau_2, \dots, \tau_{n-1}) \triangleq E\{X(t) X(t + \tau_1) \dots X(t + \tau_{n-1})\},$$

welches aufgrund der Stationarität des Prozesses nur von den Zeitdifferenzen $\tau_1, \tau_2, \dots, \tau_{n-1}$ abhängt.

Für einen mittelwertfreien Prozess $\{X(t), t \in \mathbb{Z}\}$, d.h. mittelwertfreie Zufallsvariablen $X(t)$ gelten nun folgende Beziehungen:

Kumulanten 1. Ordnung (Mittelwert):

$$k_{1x}(\tau_1) = m_{1x}(\tau_1) = E\{X(t)\}. \quad (4.6)$$

Kumulanten 2. Ordnung (Varianz):

$$k_{2x}(\tau_1) = m_{2x}(\tau_1) = E\{X(t) X(t + \tau_1)\}. \quad (4.7)$$

Kumulanten 3. Ordnung (Schiefe):

$$k_{3x}(\tau_1, \tau_2) = m_{3x}(\tau_1, \tau_2) = E\{X(t) X(t + \tau_1) X(t + \tau_2)\}. \quad (4.8)$$

Kumulanten 4. Ordnung (Wölbung):

$$\begin{aligned} k_{4x}(\tau_1, \tau_2, \tau_3) &= m_{4x}(\tau_1, \tau_2, \tau_3) - m_{2x}(\tau_1)m_{2x}(\tau_3 - \tau_2) \\ &\quad - m_{2x}(\tau_2)m_{2x}(\tau_3 - \tau_1) - m_{2x}(\tau_3)m_{2x}(\tau_2 - \tau_1) \\ &= E\{X(t) X(t + \tau_1) X(t + \tau_2) X(t + \tau_3)\}. \end{aligned} \quad (4.9)$$

Für einen statistischen Prozess $\{X(t), t \in \mathbb{Z}\}$ sind die Kumulanten der 2. und 3. Ordnung gleich der entsprechenden Momente. Kumulanten der 4. Ordnung brauchen Informationen über die Momente der 2. und 4. Ordnung ([37] S. 583 und [32], 15-16).




Abbildung 19: Normaler Herzschlag und dessen entsprechende Repräsentationen durch Kumulanten der 2., 3. und 4. Ordnung

Die Verwendung der Higher-Order Spectral Analysis (HOSA) Toolbox in MATLAB® brachte gute Erfolge. Die Funktion *cumest* berechnet die Kumulanten mit den Funktionen *cum2est*, *cum3est* und *cum4est* für die 2., 3. und 4. Ordnung [39] (siehe Anhang, 9.1). Mit dieser Methode wurden für einen 91-elementigen Vektor, d.h. $d = 91$ aus Gleichung (4.1), der den QRS-Komplex eines Herzschlags repräsentiert, 91 Kumulanten berechnet. Nach dem Paper von S. Osowski ([37], S. 584) wurden insgesamt 15 Kumulanten, 5 pro Ordnung, jeweils zu den Zeitverschiebungen 15, 30, 45, 60 und 75, also gleichverteilt über

den QRS-Komplex, als features gewählt. Die Annäherung der Kumulanten 4. Ordnung an das EKG-Signal ist klarerweise am besten. Je höher die Ordnung, desto genauer ist die Annäherung (siehe Abbildung 19).

Wenn man die HOS Charakteristiken für verschiedene Herzrhythmen vergleicht, bemerkt man, dass die Unterschiede zwischen ihnen deutlicher wurden und somit die Herzrhythmen besser erkennbar und leichter zu unterscheiden sind ([37], S. 583).

4.1.2 HER - Hermitesche Basisfunktionen

Eine andere mögliche Repräsentation der Herzsignale können die Koeffizienten der Hermiteschen Basisfunktionen leisten (siehe dazu [37] S. 584-585 und [27] S. 840-841).

Zuerst wird das EKG-Signal aus einem um den Bezugspunkt (R-Zacke) zentrierten $t_0 = 200$ ms Zeitfenster extrahiert. Jeder QRS-Komplex wird dann durch einen $2t_0$ -dimensionalen Vektor $\vec{x} = x(t)$ repräsentiert - 200 ms QRS-Komplex mit einem 100 ms Signal von Nullen an jeder Seite. Dadurch wird sichergestellt, dass die Herzschläge außerhalb des QRS-Komplexes nahe genug an Null sind. Genauer besteht das QRS-Segment aus 91 Datenpunkten um die R-Zacke mit 45 Punkten vor und nach R, die Nullen sind zusätzliche 45 Datenpunkte links und rechts vom QRS-Komplex (also insgesamt 181 Datenpunkte).

Die EKG-Daten werden mithilfe der sogenannten Hermiteschen Basisfunktionen dargestellt. Das EKG-Signal $x(t)$ ist dann gleich der Entwicklung in Hermitesche Basisfunktionen der n -ten Ordnung ϕ_n mit Koeffizienten c_n für $n = 0, \dots, N-1$:

$$x(t) = \sum_{n=0}^{N-1} c_n(\sigma) \phi_n(t, \sigma), \quad (4.10)$$

wobei σ einen Parameter für die Weite darstellt, der proportional zur Breite des QRS-Komplexes steht.

Die Hermiteschen Basisfunktionen sind folgendermaßen definiert:

$$\phi_n(t, \sigma) = \frac{1}{\sqrt{\sigma 2^n n! \sqrt{\pi}}} e^{\frac{-t^2}{2\sigma^2}} H_n\left(\frac{t}{\sigma}\right), \quad (4.11)$$

wobei H_n die Hermiteschen Polynome bedeuten und rekursiv geschrieben werden als

$$H_n(x) = 2xH_{n-1}(x) - 2(n-1)H_{n-2}(x) \quad \text{für } n > 1 \in \mathbb{N}$$

mit $H_0(x) = 1$ und $H_1(x) = 2x$.

Je höher die Ordnung des Hermite-Polynoms ist, desto höher ist die Frequenz von Änderungen im Zeitbereich und desto besser ist die Fähigkeit, schnelle Änderungen des EKG-Verlaufs zu rekonstruieren (siehe Abbildung 20).

Man definiert ϕ_n außerhalb des Zeitfensters nahe genug bei Null mit folgenden Eigenschaften:

$$|\phi_n(-t_0, \sigma)| = |\phi_n(t_0, \sigma)| < \frac{1}{10} \max_{t \in [-t_0, t_0]} |\phi_n(t, \sigma)| \quad (4.12)$$




Abbildung 20: Hermitesche Basisfunktionen der ersten 6 Ordnungen für $\sigma = 30$

und

$$|\phi_n(t, \sigma)| \leq |\phi_n(t_0, \sigma)| \quad \text{für alle } |t| > t_0. \quad (4.13)$$

Die σ sind für jedes N durch eine obere Grenze σ_0 aufgrund des endlichen Zeitfensters begrenzt. Dann erhält man für $N = 3, 4, 5, 6$ ($n = 2, 3, 4, 5$) die maximalen Weiten $\sigma_0 = 62, 55, 51, 47$ ms, indem man die zwei Bedingungen 4.12 und 4.13 für ϕ_n berechnet. Diese Werte sind ausreichend groß für gute Repräsentationen der Herzschläge.

Als Merkmale der EKG-Kurven werden die Koeffizienten c_n der Hermiteschen Basisfunktionen gewählt, da durch diese die Annäherung an die originale Kurve erfolgt.

Die Herausforderung daran ist nur noch, die Koeffizienten zu bestimmen. Das geht durch Minimierung des Fehlers E , gebildet aus der Summe der quadrierten Fehler $e(t, \sigma)$ zwischen dem EKG-Signal und deren Approximation durch die Hermiteschen Basisfunktionen:

$$E = \sum_i \|e(t_i, \sigma)\|^2 = \sum_i \left\| x(t_i) - \sum_{n=0}^{N-1} c_n(\sigma) \phi_n(t_i, \sigma) \right\|^2. \quad (4.14)$$

Eine solche Problemstellung wird mit dem Verfahren der kleinsten Quadrate gelöst [10], einer Methode zur Lösung eines überbestimmten Systems von linearen Gleichungen $Ay = b$. Das bedeutet ein System, bei dem A eine $m \times n$ -Matrix mit $m > n$ ist. In unserem Fall entspricht die Matrix A den Hermiteschen Basisfunktionen $\phi_n(t, \sigma)$ mit m als Länge des Zeitintervalls und n als Ordnung der ϕ_n , y den Koeffizienten c_n und b dem EKG-Signal $x(t)$. Die Lösung dieses Problems, also von $\min(E)$ in 4.14, kann mathematisch durch die sogenannte Pseudoinverse, die sich aus der Singulärwertzerlegung (singular value decomposition, SVD) [25] ergibt, gefunden werden.

Definition 4.1.2.1. Sei $A \in \mathbb{R}^{m,n}$ mit $m \geq n$ gegeben. Die Singulärwertzerlegung (SVD) einer Matrix A ist eine Zerlegung der Form

$$A = UDV^T \quad (4.15)$$

in orthogonale Matrizen $U \in \mathbb{R}^{m,m}$ und $V \in \mathbb{R}^{n,n}$ mit

$$D = \begin{bmatrix} D_r & 0_{r,n-r} \\ 0_{m-r,r} & 0_{m-r,n-r} \end{bmatrix} \in \mathbb{R}^{m,n}, \quad D_r = \text{diag}(\lambda_1, \dots, \lambda_r),$$

wobei $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_r > 0$ und $r = \text{Rang}(A)$ sind.

Definition 4.1.2.2. Sei $A = UDV^T \in \mathbb{R}^{m,n}$ eine SVD von A mit $D = \text{diag}(\lambda_1, \dots, \lambda_r, 0, \dots, 0)$ und den oben genannten Eigenschaften, dann ist die Pseudoinverse oder Moore-Penrose-Inverse einer Matrix A definiert als

$$A^+ = VD^+U^T \quad \text{mit} \quad D^+ = \text{diag}\left(\frac{1}{\lambda_1}, \dots, \frac{1}{\lambda_r}, 0, \dots, 0\right) \in \mathbb{R}^{n,m}. \quad (4.16)$$

Die Kleinste-Quadrate-Lösung der kleinsten Norm des linearen Gleichungssystems $Ay = b$ mit A eine $m \times n$ - Matrix ist dann gegeben durch

$$y^+ = A^+b = VD^+U^Tb. \quad (4.17)$$

Es handelt sich hierbei sogar um ein eindeutiges Minimum, das $\|Ax - b\|^2$ minimiert [10]. Das Minimum von 4.14 ist also aufgrund der orthogonalen Eigenschaften der Hermiteschen Basisfunktionen (sie stellen eine Orthonormalbasis dar [27]) gegeben durch

$$c_n(\sigma) = \vec{x} \cdot \vec{\phi}_n(\sigma). \quad (4.18)$$

Durch gleichzeitige Maximierung von σ und Minimierung des Fehlers e erhält man die gewünschten Koeffizienten.

Die nun bestimmten Koeffizienten stellen also die gesuchten features eines Herzschlages dar. Im Bezug auf obig genanntes Paper [37] wurden Hermitesche Polynome bis zur 13. Ordnung berechnet und damit 14 Koeffizienten als features erhalten. Als 15. Merkmal wurde das maximale σ für jedes QRS-Segment gewählt (siehe Anhang, 9.2).




Abbildung 21: Normaler Herzschlag und dessen Hermitesche Repräsentationen der 3., 9. und 14. Ordnung

Hermitesche Basisfunktionen werden somit mit ziemlich genauen Ergebnissen an die originalen EKG-Daten approximiert (siehe Abbildung 21). Je höher die Ordnung der Hermiteschen Basisfunktionen, desto genauer wird die Approximation. Ab der 9. Ordnung ist die Approximation sehr nahe am Kurvenverlauf.

4.2 WEITERE MERKMALE

Zusätzlich zu den durch die Methoden HOS und HER extrahierten Merkmale (bezogen auf die Form), werden an den Feature Vektor noch zwei weitere Features angefügt. Diese Merkmale beziehen sich auf den lokalen Rhythmus der Herzschlagfolge, auf die RR-Intervalle. Sie stellen also zeitliche Informationen zur Verfügung, die am Anfang dieses Kapitels schon erwähnt wurden. Amplitude und Frequenz sollen nicht die einzigen Merkmale ist, um ein Signal zu beschreiben. Die Wahl der Merkmale bezieht sich auf die Publikationen von S. Osowski et al. [37] und M. Lagerholm et al. [27].

Diese Features sind wie folgt definiert:

Sei R_i die Zeit des Eintretens des i -ten Herzschlages.

Ein Feature entspricht dem aktuellen RR-Intervall (siehe Abbildung 22), also das Intervall der R-Zacke des vorigen Herzschlages zur R-Zacke des aktuellen Herzschlages (pre-instantaneous RR-interval):

$$R^- \equiv R_i^- = R_i - R_{i-1}. \quad (4.19)$$

Das andere Merkmal ist das durchschnittliche RR-Intervall der letzten 10 Herzschläge, wobei für die ersten neun Herzschläge die durchschnittlichen RR-Intervalle der vorigen Herzschläge berechnet werden (AR, average RR-intervals):

$$AR = \frac{R_i^- + R_{i-1}^- + \dots + R_{i-9}^-}{10}. \quad (4.20)$$




Abbildung 22: RR-Intervall zwischen zwei aufeinander folgenden Herzschlägen entspricht dem zeitlichen Abstand zweier R-Zacken. Variation dieser Intervalls entspricht der Herzratenvariabilität (HRV) [3].

Ein drittes Feature, das alternativ zum vorigen Merkmal verwendet wird, ist die Differenz des vorhergehenden und darauf folgenden RR-Intervalls für den aktuellen i -ten Herzschlag:

$$R^+ = \Psi \left[(R_{i+1}^- - R_i^-) - (R_i^- - R_{i-1}^-) \right], \quad (4.21)$$

mit

$$\Psi(x) = \begin{cases} x, & \text{falls } x > 0, \\ 0, & \text{sonst.} \end{cases}$$

R^+ hängt durch diese Definition nicht von der Herzfrequenz ab. Ist der i -te Herzschlag ein premature Typ, dann ist R^+ signifikant ungleich Null - eine wichtige Eigenschaft für z.B. atriale Herzschläge.

Andere Wahlmöglichkeiten der temporären Eigenschaften der Herzschläge bzw. deren Herzschlagfolge, die in dieser Arbeit nicht angewendet wurden, finden sich in [45].

4.3 SKALIERUNG DER MERKMALE

Als letzter Schritt müssen die einzelnen Merkmale der Herzschläge zur besseren Unterscheidung noch standardisiert werden, da dies in der Klassifikation deutlich bessere Resultate erzielte.

Dazu wurden (nach [37], S. 584) die Features in diesem Sinne normalisiert: Sei y das Merkmalstupel (Feature Vektor), $\bar{y}$ der Mittelwert aller Elemente des Merkmalstupels und σ die Standardabweichung der Elemente zum Mittelwert. Dann wird y gemittelt, der Mittelwert $\bar{y}$ von y abgezogen und dividiert durch die Standardabweichung σ . Wir erhalten den standardisierten Feature vector y_{sp} (sp steht für standardized points):

$$y_{sp} = \frac{y - \bar{y}}{\sigma}. \quad (4.22)$$

Damit wurde erreicht, dass alle Merkmale Mittelwert 0 und Standardabweichung 1 haben.

Weitere Methoden zur Normalisierung der einzelnen Merkmale findet man in der Literatur [45].

Die Wahl der Methode ist sehr abhängig von den Daten, aber auch von den einzelnen Eigenschaften. Das Wichtigste ist, überhaupt die Daten zu vereinheitlichen, da der Fehler in der Klassifikation nach der Skalierung kleiner ist [33].

4.4 ZUSAMMENFASSUNG ALLER GEWÄHLTEN MERKMALE

Die folgende Tabelle 2 fasst noch einmal alle Merkmale für jeden Herzschlag zusammen, die durch vorher besprochene Methoden und Überlegungen bestimmt und ausgewählt wurden. In den zwei Verfahren zur Klassifikation werden aber nur verschiedene Untergruppen dieser Features verwendet.

Tabelle 2: Ausgesuchte Merkmale y der Herzschläge x , die später als Inputs in der Klassifikation verwendet werden.

Merkmale der Herzschläge	Beschreibung
	<i>1. EKG-Ableitung nach Einthoven der Herzschläge</i>
$y(1, \dots, 15)$	HOS - Beschreibung durch jeweils 5 Kumulanten der 2., 3. und 4. Ordnung
$y(16, \dots, 29)$	HER - Beschreibung durch 14 Koeffizienten der Hermiteischen Basisfunktionen
$y(30)$	σ als Weite des QRS-Komplexes (abhängig von der Ordnung)
	<i>2. EKG-Ableitung nach Wilson der Herzschläge</i>
$y(31, \dots, 45)$	HOS - Beschreibung durch jeweils 5 Kumulanten der 2., 3. und 4. Ordnung
$y(46, \dots, 59)$	HER - Beschreibung durch 14 Koeffizienten der Hermiteischen Basisfunktionen
$y(60)$	σ als Weite des QRS-Komplexes (abhängig von der Ordnung)
$y(61)$	R^- - aktuelles vorhergehendes RR-Intervall
$y(62)$	AR - durchschnittliches RR-Intervall der letzten 10 Herzschläge
$y(63)$	R^+ - Differenz von drei vorhergehenden RR-Intervallen

4.5 TRAININGS- UND TESTDATEN

Die Klassifikation und die Bestimmung ihrer Qualität erfordert eine Aufteilung in Trainings- und Testdaten.

Ein Klassifikator nimmt in der Klassifikation die Zuordnung eines Merkmalstupels zu einer Klasse vor (siehe dazu Anfang des nächsten Kapitels 5).

Trainingsdaten sind die Eingangsvektoren, die einem Klassifikator annotiert oder ungekennzeichnet, abhängig von der Art des Klassifikators, zugeführt werden, um eine Lerneinheit zu absolvieren.

Testdaten sind Eingangsdaten, die einem Klassifikator nach der Trainingsphase zugeführt werden, um eine Evaluierung der Klassifikation vorzunehmen.

4.5.1 Vorbereitung für SVM

Es wird die Menge aller Daten von allen Personen nach ihren Annotationen in einzelne Untermengen aufgeteilt. In diesen Gruppen befinden sich dann alle Herzschläge einer Klasse zusammengefasst. Dies wird für die Support Vektor Maschine benötigt, da sie immer nur in zwei Gruppen klassifiziert. Des Weiteren werden diese Gruppen jeden Herzschlagtyps in Trainings- und Testdaten geteilt, denn diese dürfen für die Support Vektor Maschine nicht vermischt werden. Um einen subjektiven Einfluss auf die Klassifikation auszuschließen, werden Merkmalstupeln *zufällig* jeweils den Mengen der Trainings- und Testdaten einer Klasse zugeordnet. Es entsteht meist eine bessere Klassifikation, wenn mehr Trainingsdaten als Testdaten verwendet werden. Der Klassifikator kann durch eine höhere Anzahl an Trainingsdaten eine größere Variation von Herzschlägen unterscheiden. Die höher besetzten Klassen wurden daher im *Verhältnis 80 zu 20* und die schwach besetzten im *Verhältnis 90 zu 10* gewählt.

Basierend auf der Publikation von Osowski et al. [37] wurden die Merkmale der Herzschläge zu folgenden Merkmalstupeln zusammengestellt (siehe Tabelle 2):

$$\{y(1, \dots, 15)y(61)y(62)\} \quad (4.23)$$

$$\{y(16, \dots, 29)y(30)y(61)y(62)\}. \quad (4.24)$$

4.5.2 Vorbereitung für SOM

Für die Selbst Organisierte Karte ist der Schritt der strikten Trennung der annotierten Daten in Klassen nicht notwendig. Man nimmt einfach alle vorhandenen aufbereiteten Daten als Trainingsdaten, da der Klassifikator durch automatische Erkennung ähnlicher Mustern trainiert wird. Zum Testen werden dann dieselben Daten mit ihrer Annotation verwendet, um zu prüfen in welche Klasse sie eingeordnet wurden.

Basierend auf der Publikation von Lagerholm et al. [27] wurden diese Features für die SOM als Inputs ausgewählt und zu folgendem Merkmalstupel vereint (siehe Tabelle 2):

$$\{y(16, \dots, 20)y(30)y(46, \dots, 50)y(60)y(61)y(63)\}. \quad (4.25)$$

5

METHODEN ZUR KLASSIFIZIERUNG

Dieses Kapitel umfasst den Hauptkern dieser Arbeit, nämlich die Gegenüberstellung zweier Methoden zur Klassifizierung der unterschiedlichen Herzschräge. Genauer betrachtet werden einerseits die Methode der Support Vektor Maschine (support vector machine, SVM) und andererseits die der Selbst Organisierten Karte (self organizing map, SOM). In weiterer Folge wird deren Implementationen in MATLAB[®] besprochen.

Davor müssen Begriffe des sogenannten maschinellen Lernens (machine learning) und der Mustererkennung (pattern recognition) eingeführt werden, um besser zu verstehen, was eine Klassifikation bedeutet und wie eine solche genauer aussieht. Dazu werden Begriffe nach Voss und Süße verwendet [41].

Seien

K ... Anzahl der Klassen oder Gruppen

M ... Anzahl der Merkmale, entspricht der Größe des Raumes der Merkmale (*feature space*)

Je mehr Merkmale gewählt werden, desto größer ist die Dimension des Raumes.

n ... Anzahl der Merkmalstupel pro Stichprobe

Objekt: Das i -te Merkmalstupel $y^{(i)} = (y_1^{(i)}, y_2^{(i)}, \dots, y_M^{(i)})$ mit M Merkmalen wird als i -tes Objekt bezeichnet.

Klasse: Die Klasse ist die Menge von zusammengehörigen Objekten als Teilmenge der Menge aller Objekte.

Klassifikation: Die Klassifikation stellt allgemein den Prozess der Zuordnung eines Objektes zu einer Klasse durch einen Algorithmus dar.

Klassifikator: Der Algorithmus oder das Programm, mit dem ein Objekt einer Klasse zugeordnet wird, heißt Klassifikator.

Stichprobe: Eine Stichprobe ist eine endliche Menge von Merkmalstupeln und Teilmenge der Menge aller Objekte.

Klassifizierte Stichprobe: Den Objekten in der Stichprobe sind Klassenkennzeichen zugeordnet.

Unklassifizierte Stichprobe: Die Menge von Merkmalstupeln in der Stichprobe sind ohne Klassenkennzeichnung.

Lernen: Das maschinelle Lernen ist die Erarbeitung eines Klassifikators anhand einer klassifizierten oder unklassifizierten Stichprobe (Mustererkennung).

Überwachtes Lernen meint das Lernen mit klassifizierter Stichprobe (*supervised learning*),

Unüberwachtes Lernen ist das Lernen mit unklassifizierter Stichprobe (*unsupervised learning*).

Vergleich von überwachtem und unüberwachtem Lernen (siehe Tabelle 3):

Klassifikation: Die Zuordnung eines Objektes zu einer Klasse erfolgt anhand einer klassifizierten Stichprobe. Diese ist aber nicht zu verwechseln mit dem allgemeinen Begriff einer Klassifikation.

Klassifikationsmethoden ordnen Objekte in vorgegebene Klassen ein. In der Lern- oder Trainingsphase benötigen sie das Wissen über die Zugehörigkeit der Objekte zu Klassen im Vorhinein (siehe Abbildung 23).




Abbildung 23: Verlauf eines überwachten Lernverfahrens und der Klassifikation in zwei Phasen. In der Trainingsphase wird mithilfe annotierter Trainingsdaten das Klassifikationsmodell aufgestellt. In der Testphase werden Testobjekte klassifiziert [6].




Abbildung 24: Verlauf eines unüberwachten Lernverfahrens und der Clusterbildung in einer gemeinsamen Phase. In der Trainingsphase wird durch Ähnlichkeitsvergleiche der Trainingsdaten das Clustering Modell aufgestellt. Die Testphase dient nur zur Evaluierung der Ergebnisse, sie sind jedoch schon vorhin klassifiziert.

Clusterbildung: Die Zuordnung eines Objektes zu einer Klasse erfolgt anhand einer unklassifizierten Stichprobe. Die Objektmenge wird in Teilmengen, in die sogenannten Cluster, zerlegt.

Clusterbildungs- oder Clustering- Verfahren bilden automatisch Cluster nach gewissen Ähnlichkeitskriterien der einzelnen Objekte. Zur Evaluierung ist trotzdem das Wissen der Kennzeichnung der Objekte in zugehörige Klassen erforderlich, also im Nachhinein in der Testphase des Klassifikators (siehe Abbildung 24).

Tabelle 3: Supervised vs. Unsupervised learning in Form von Support Vektor Maschine vs. Selbst Organisierte Karte.

Support Vektor Maschine	Selbst Organisierten Karte
- überwachtes Lernen - Klassifikationsverfahren - Zuordnung eines Objektes zu einer vorgegebenen Klasse	- unüberwachtes Lernen - Clusterbildungsverfahren - automatische Einteilung der Objekte in Cluster

Nun wird konkret auf die verwendeten Klassifikationsmethoden Support Vektor Maschine und Selbst Organisierte Karte eingegangen.

5.1 SVM - SUPPORT VEKTOR MASCHINE

Die Grundidee einer Support Vektor Maschine ist die Konstruktion einer optimalen Hyperebene, der sogenannten Entscheidungsebene, die alle Daten einer Klasse von denen einer anderen mit dem größten Abstand (*maximum margin of separation*) voneinander trennt [24].




Abbildung 25: Support Vektor Maschine für linear separierbare Daten in einem 2-dimensionalen Raum. Optimale separierende Hyperebene mit maximalem Margin zu den nächsten Datenpunkten jeder Klasse [1], S. 23.

Die Wahl der optimalen Hyperebene unter den vielen möglichen Hyperebenen schließt also mit ein, dass der Generalisierungsfehler des Klassifikators klein gehalten bleibt. Dieser maximale Abstand ist die Summe der Abstände von der Hyperebene zu den nächsten Datenpunkten von jeder der beiden Klassen. Diese nächst gelegenen Datenpunkte werden Support-Vektoren (SVs) genannt, denn sie beschreiben („stützen“) die Hyperebene [24], siehe Abbildung 25.

Angenommen, die Merkmalsextraktion der Rohdaten wurde schon durchgeführt. Dann seien die annotierten Trainingsdaten gegeben durch $\mathbf{y}^{(i)} \in \mathbb{R}^M$ mit den Kennzeichnungen oder Labels $l_i \in \{-1, +1\}$ für $i = 1, \dots, n$ Herzschläge, wobei -1 die eine Klasse 1 und $+1$ die andere Klasse 2 meint.

5.1.1 Lineare Support Vektor Maschine für linear separierbare Daten

Sind die Daten zweier Klassen linear trennbar $\in \mathbb{R}^M$, dann sei die M -dimensionale Hyperebene oder Entscheidungsfunktion $D(\mathbf{y})$ gegeben durch

$$D(\mathbf{y}) = \mathbf{w} \cdot \mathbf{y} + b, \quad (5.1)$$

wobei $\mathbf{w}$ ein M -dimensionaler Vektor und b ein Verschiebeterm ist und für $i = 1, \dots, n$ gilt

$$\mathbf{w} \cdot \mathbf{y}^{(i)} + b = \begin{cases} > 0 & \text{für } l_i = 1, \\ < 0 & \text{für } l_i = -1. \end{cases} \quad (5.2)$$

Da die Trainingsdaten linear trennbar sind, erfüllen sie die Gleichung $\mathbf{w} \cdot \mathbf{y}^{(i)} + b = 0$ nicht (sonst würden sie alle auf dieser Ebene liegen). Um die Trennbarkeit zu überprüfen, betrachten wir folgende Ungleichungen:

$$\mathbf{w} \cdot \mathbf{y}^{(i)} + b = \begin{cases} \geq 1 & \text{für } l_i = 1, \\ \leq -1 & \text{für } l_i = -1. \end{cases} \quad (5.3)$$

Statt 1 und -1 an der rechten Seite der Ungleichungen kann auch $a(> 0)$ und $-a$ gesetzt werden. Die Gleichung 5.3 ist äquivalent zu

$$l_i \cdot (\mathbf{w} \cdot \mathbf{y}^{(i)} + b) \geq 1 \quad \text{für } i = 1, \dots, n. \quad (5.4)$$

Die Hyperebene kann auch geschrieben werden als

$$D(\mathbf{y}) = \mathbf{w} \cdot \mathbf{y} + b = c \quad \text{für } -1 < c < 1, \quad (5.5)$$

wobei c die Lage der Hyperebene bestimmt. Es gibt mehrere Entscheidungsfunktionen, die der Gleichung 5.5 genügen. Die gesuchte optimale separierende Hyperebene ist jedoch die mit dem größten Margin. Die Generalisierungsfähigkeit hängt somit von der Lage der Hyperebene ab.

Nun gilt es die optimale Hyperebene zu bestimmen. Der euklidische Abstand von einer Trainingsdatenprobe $\mathbf{y}$ zur Trennhyperebene ist gegeben durch (siehe [30], S. 39)

$$\frac{|D(\mathbf{y})|}{\|\mathbf{w}\|}. \quad (5.6)$$

Dann müssen alle Trainingsdaten die folgende Bedingung erfüllen

$$\frac{l_i \cdot D(\mathbf{y}^{(i)})}{\|\mathbf{w}\|} \geq \delta \quad \text{für } i = 1, \dots, n, \quad (5.7)$$

wobei δ für den Abstand steht. Nun ist mit $(\mathbf{w}, b)$ auch $(a\mathbf{w}, ab)$ mit a als Skalar eine Lösung von 5.5. Aus diesem Grund wird folgende Restriktion festgemacht:

$$\delta \|\mathbf{w}\| = 1. \quad (5.8)$$

Aus 5.7 und 5.8 folgt, dass für die optimale Trennhyperebene das $\mathbf{w}$ mit der minimalen euklidischen Norm gefunden werden muss, die 5.4 erfüllt.

Die optimale separierende Hyperebene kann durch folgendes Minimierungsproblem für $\mathbf{w}$ und b gelöst werden:

$$\text{Minimiere} \quad Q(\mathbf{w}, b) = \frac{\|\mathbf{w}\|^2}{2} \quad (5.9)$$

unter der Nebenbedingung (u.d.N.)

$$l_i (\mathbf{w} \cdot \mathbf{y}^{(i)} + b) \geq 1, \quad \text{für } i = 1, \dots, n.$$

Das Quadrat der euklidischen Norm $\|\mathbf{w}\|$ macht dieses Optimierungsproblem zu einem Problem der Quadratischen Programmierung (*Quadratic Programming*, QP) [1].

5.1.2 Lineare Support Vektor Maschine für nichtlinear separierbare Daten

Wenn die Daten nicht linear trennbar sind, muss obige Formulierung 5.4 erweitert werden. Um nicht vollständig trennbare Daten zu erlauben, führen wir nichtnegative Schlupfvariablen $\xi_i \geq 0$ in 5.4 ein:

$$l_i \cdot (\mathbf{w} \cdot \mathbf{y}^{(i)} + b) \geq 1 - \xi_i \quad \text{für } i = 1, \dots, n. \quad (5.10)$$




Abbildung 26: Support Vector Maschine für nicht linear separierbare Daten in einem 2-dimensionalen Raum. Optimal trennende Hyperebene mit noch richtig klassifiziertem ξ_i , schon falsch klassifiziertem ξ_j [1].

Durch die Schlupfvariablen ξ_i ist die Existenz von Lösungen sichergestellt. Für $0 < \xi_i < 1$ haben die Trainingsdaten $\mathbf{y}^{(i)}$ keinen maximalen Abstand zur Hyperebene, sind aber richtig klassifiziert. Falls $\xi_i \geq 1$, werden die Daten durch die optimale Hyperebene falsch klassifiziert. Für eine optimale Hyperebene muss die Anzahl der Trainingsdaten die kein maximales Margin haben klein sein, siehe Abbildung 26.

In diesem Fall ändert sich das Minimierungsproblem von 5.9 für die optimale Hyperebene zu

$$\begin{aligned} \text{Minimiere} \quad Q(\mathbf{w}, b, \xi) &= \frac{\|\mathbf{w}\|^2}{2} + C \sum_{i=1}^n \xi_i \\ \text{u.d.N.} \quad l_i(\mathbf{w} \cdot \mathbf{y}^{(i)} + b) &\geq 1 - \xi_i, \quad \xi_i \geq 0 \quad \text{für } i = 1, \dots, n, \end{aligned} \quad (5.11)$$

wobei $\xi = (\xi_1, \dots, \xi_n)^T$ und C der (benutzerdefinierte) Margin Parameter ist, der den Kompromiss zwischen der Maximierung des Margins und der Minimierung des Klassifizierungsfehlers steuert. Durch Lösen von 5.11 folgt die sogenannte verallgemeinerte optimale Trennhyperebene. Dieses Problem stellt wie in 5.9 ein QP-Problem dar [1, 24].

5.1.3 Nichtlineare Support Vektor Maschine

Wenn die Trainingsdaten nicht linear trennbar sind, wird zwar eine optimale Hyperebene gefunden, die Generalisierungsfähigkeit eines solchen Klassifikators ist jedoch nicht maximal [1].

Wenn die Entscheidungsfunktion keine lineare Funktion der Daten ist, werden die Daten aus dem Eingangsraum in einen höher-dimensionalen Merkmalsraum durch eine nichtlineare Transformation abgebildet. In diesem Merkmalsraum höherer Dimension wird die verallgemeinerte optimale Trennhyperebene konstruiert. Das Theorem von Cover besagt, dass, wenn die Transformation nicht linear ist und die Dimension des Merkmalsraumes hoch genug ist, dann kann der Eingangsraum in einen neuen Merkmalsraum umgewandelt werden, in dem dann die Daten mit hoher Wahrscheinlichkeit linear trennbar sind. Diese nichtlineare Transformation wird in impliziter Weise durch sogenannte Kernfunktionen (*kernel functions*) durchgeführt. Die Daten können im Merkmalsraum linear getrennt werden, obwohl sie im Eingangsraum nicht linear trennbar sind [24].




Abbildung 27: Support Vector Maschine muss die Eingangsdaten in einen höher-dimensionalen Raum transformieren um die Daten linear trennen zu können. Der Eingangsraum wird über die Abbildung ϕ in einen neuen Merkmalsraum umgewandelt [24], siehe Abbildung 27

Durch Verwendung der nichtlinearen Vektorfunktion

$$\phi(\mathbf{y}) = (\phi_1(\mathbf{y}) \dots, \phi_l(\mathbf{y}))^T, \quad (5.12)$$

die den M -dimensionalen Input-Vektor in den l -dimensionalen Skalarprodukt Merkmalsraum abbildet ($l \geq M$), ist die dadurch lineare Entscheidungsfunktion im Merkmalsraum gegeben durch

$$D(\mathbf{y}) = \mathbf{w}^T \phi(\mathbf{y}) + b, \quad (5.13)$$

wobei $\mathbf{w}$ ein l -dimensionaler Vektor und b ein Verschiebeterm ist.

Laut [1] existiert eine Abbildungsfunktion $\phi(\mathbf{y})$, die $\mathbf{y}$ in den Skalarprodukt-Merkmalsraum abbildet, und $\phi(\mathbf{y})$ erfüllt

$$K(\mathbf{y}, \mathbf{y}') = \phi^T(\mathbf{y}) \phi(\mathbf{y}'), \quad (5.14)$$

wenn eine symmetrische Funktion $K(\mathbf{y}, \mathbf{y}')$ die folgende Ungleichung erfüllt

$$\sum_{i,j=1}^n h_i h_j K(\mathbf{y}^{(i)}, \mathbf{y}^{(j)}) \geq 0, \quad (5.15)$$

für alle $n, \mathbf{y}^{(i)}, h_i$ mit $n \in \mathbb{N}$ und $h_i \in \mathbb{R}$.

Ist 5.14 erfüllt, dann folgt

$$\sum_{i,j=1}^n h_i h_j K(\mathbf{y}^{(i)}, \mathbf{y}^{(j)}) = \left(\sum_{i=1}^n h_i \phi^T(\mathbf{y}^{(i)}) \right) \left(\sum_{i=1}^n h_i \phi(\mathbf{y}^{(i)}) \right) \geq 0. \quad (5.16)$$

Mercers Theorem für positiv definite Funktionen erlaubt, $\phi(\mathbf{y}^{(i)}) \cdot \phi(\mathbf{y}^{(j)})$ durch eine positiv definite symmetrische Kernfunktion $K(\mathbf{y}^{(i)}, \mathbf{y}^{(j)})$ zu ersetzen. Diese Bedingung 5.16 heißt die Bedingung von Mercer (*Mercer's condition*) und die Funktion, die eine solche Bedingung erfüllt, wird positiv semidefiniter Kern oder Mercer-Kern (*Mercer kernel*) genannt. Die Technik des sogenannten Kernel Tricks (*kernel trick*) ist nun die, dass durch die Verwendung von Kernels der höher-dimensionale Merkmalsraum nicht explizit bekannt sein muss, denn er ist implizit über den Kernel definiert. Wir verwenden also $K(\mathbf{y}, \mathbf{y}')$ statt $\phi(\mathbf{y})$. Diese Methoden, die den Eingangsraum in den Merkmalsraum abbilden und die explizite Behandlung von Variablen im Merkmalsraum durch Kernel Tricks verhindern, sind die Kernel Methoden (*kernel methods*).

5.1.4 Quadratic Programming

Das QP-Problem ist ein Optimierungsproblem unter Nebenbedingungen und wird zur Berechnung in ein duales Problem unter Verwendung der Methode der Lagrange Multiplikatoren umgewandelt.

Da die Funktion Q in (5.9) quadratisch ist und die Nebenbedingungen linear sind, handelt es sich dabei um ein typisches QP-Problem. Es wird nun das duale Problem für linear separierbare Daten formuliert.

Zuerst wird das bedingte Problem (5.9) in ein uneingeschränktes Problem umgewandelt:

$$Q(\mathbf{w}, b, \boldsymbol{\alpha}) = \frac{1}{2} \mathbf{w}^T \mathbf{w} - C \sum_{i=1}^n \alpha_i \{l_i(\mathbf{w}^T \mathbf{y}^{(i)} + b) - 1\}, \quad (5.17)$$

wobei $\boldsymbol{\alpha} = (\alpha_1, \dots, \alpha_n)^T$ und α_i die nichtnegativen Lagrange Multiplikatoren sind. Die optimale Lösung von (5.17) ist durch den Sattelpunkt gegeben, wo (5.17) bezogen auf $\mathbf{w}$ minimal, auf α_i maximal und auf b abhängig vom Vorzeichen von $\sum_{i=1}^n \alpha_i y_i$ ist. Die Lösung erfüllt die folgenden Karush-Kuhn-Tucker (KKT) Bedingungen:

$$\frac{\partial Q(\mathbf{w}, b, \boldsymbol{\alpha})}{\partial \mathbf{w}} = \mathbf{0}, \quad (5.18)$$

$$\frac{\partial Q(\mathbf{w}, b, \boldsymbol{\alpha})}{\partial b} = 0, \quad (5.19)$$

$$\alpha_i \{l_i(\mathbf{w}^T \mathbf{y}^{(i)} + b) - 1\} = 0 \quad \text{für } i = 1, \dots, n, \quad (5.20)$$

$$\alpha_i \geq 0 \quad \text{für } i = 1, \dots, n. \quad (5.21)$$

In (5.17) müssen $\alpha_i = 0$, oder $\alpha_i \neq 0$ und $l_i(\mathbf{w}^T \mathbf{y}^{(i)} + b) = 1$ erfüllt sein. Die Trainingsdaten $\mathbf{x}_i$ mit $\alpha_i \neq 0$ werden *Support Vektoren* genannt.

Nun werden (5.18) und (5.19) unter Verwendung von (5.17) auf folgende Form gebracht:

$$\mathbf{w} = \sum_{i=1}^n \alpha_i l_i \mathbf{y}^{(i)} \quad (5.22)$$

und

$$\sum_{i=1}^n \alpha_i l_i = 0. \quad (5.23)$$

Setzt man diese zwei Gleichungen in (5.17) ein, erhalten wir das folgende duale Problem:

$$\text{Maximiere} \quad Q(\boldsymbol{\alpha}) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j l_i l_j \mathbf{y}^{(i)T} \mathbf{y}^{(j)} \quad (5.24)$$

$$\text{u.d.N.} \quad \sum_{i=1}^n \alpha_i l_i = 0, \quad (5.25)$$

$$\alpha_i \geq 0 \quad \text{für } i = 1, \dots, n. \quad (5.26)$$

Im Folgenden wird das duale Problem des QP-Problems für die nicht linear separierbaren Daten (5.11) formuliert, das eine ähnliche Herleitung besitzt wie

(5.24) und aus diesem Grund nicht noch einmal ausgeführt wird:

Gegeben seien die Trainingsdaten $\{\mathbf{y}^{(i)}, l_i\}_{i=1}^n$. Finde die Lagrange-Multiplikatoren $\{\alpha_i\}_{i=1}^n$, sodass die Funktion

$$Q(\boldsymbol{\alpha}) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j l_i l_j \mathbf{y}^{(i)T} \mathbf{y}^{(j)} \quad (5.27)$$

maximiert wird unter den linearen Bedingungen

$$\sum_{i=1}^n \alpha_i l_i = 0 \quad (5.28)$$

$$0 \leq \alpha_i \leq C \quad \text{für } i = 1, \dots, n \quad (5.29)$$

wobei C eine benutzerdefinierte positive Konstante ist. Die zu maximierende Zielfunktion $Q(\boldsymbol{\alpha})$ ist dieselbe wie für linear trennbare Daten mit einem wichtigen Unterschied: (5.26) wird durch eine strengere Nebenbedingung ersetzt - die α_i werden zusätzlich durch C beschränkt. Die Bedingungen (5.28) und (5.29) heißen Feldbedingungen (*box constraints*).

Für den nichtlinearen Fall wird $\mathbf{y}^{(i)T} \mathbf{y}^{(j)}$ einfach durch $K(\mathbf{y}^{(i)}, \mathbf{y}^{(j)})$ ersetzt: Unter der Verwendung des Kerns ist das duale Problem im Merkmalsraum gegeben durch

$$\begin{aligned} \text{Maximiere} \quad & Q(\boldsymbol{\alpha}) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j l_i l_j K(\mathbf{y}^{(i)}, \mathbf{y}^{(j)}) \\ \text{u.d.N.} \quad & \sum_{i=1}^n \alpha_i l_i = 0, \quad 0 \leq \alpha_i \leq C \quad \text{für } i = 1, \dots, n. \end{aligned} \quad (5.30)$$

Da $K(\mathbf{y}^{(i)}, \mathbf{y}^{(j)})$ positiv semidefinit ist, stellt das Optimierungsproblem ein konkaves QP-Problem dar. Da $\boldsymbol{\alpha} = 0$ eine Lösung ist, hat das Problem eine globale optimale Lösung. Die KKT Bedingungen sind dann gegeben durch

$$\alpha_i \left(l_i \left(\sum_{j=1}^n l_j \alpha_j K(\mathbf{x}_i, \mathbf{x}_j) + b \right) - 1 + \xi_i \right) = 0 \quad (5.31)$$

$$(C - \alpha_i) \xi_i = 0, \quad \alpha_i \geq 0, \quad \xi_i \geq 0 \quad \text{für } 0 \leq i \leq n. \quad (5.32)$$

Sei S die Menge der Indizes der Support Vektoren. Das Ausgangssignal der SVM, also die Entscheidungsfunktion $D(\mathbf{y})$ lautet

$$D(\mathbf{y}) = \sum_{i \in S} \alpha_i l_i K(\mathbf{y}^{(i)}, \mathbf{y}) + b. \quad (5.33)$$

Die unbekannten Daten $\mathbf{y}^{(i)}$ für $i = 1, \dots, n$ Herzschläge werden durch die Entscheidungsfunktion folgendermaßen klassifiziert:

$$\mathbf{y}^{(i)} \in \begin{cases} \text{Klasse 1} & \text{wenn } D(\mathbf{y}^{(i)}) > 0, \\ \text{Klasse 2} & \text{wenn } D(\mathbf{y}^{(i)}) < 0, \\ \text{unklassifizierbar} & \text{wenn } D(\mathbf{y}^{(i)}) = 0. \end{cases} \quad (5.34)$$

5.1.5 Implementierung in MATLAB®

Für die Implementierung der Support Vektor Maschine wurde in der Entwicklungsumgebung in MATLAB® gearbeitet. Die verwendeten functions und Befehle stammen aus der Statistics and Machine Learning Toolbox.

Die Support Vektor Maschine (SVM) ist für die binäre Klassifikation entwickelt, da sie Daten immer in zwei Kassen trennt [17]. Die Aufgabe besteht jedoch darin, die Herzschläge in 15 verschiedene Klassen zu unterteilen. Typischerweise wird ein Multi-Klassen-Klassifikator durch Kombination mehrerer binärer Klassifikatoren konstruiert [17]. In dieser Arbeit wurde die *one-against-one Methode* verwendet, nach der Publikation [37]. Laut der one-against-one Methode entstehen allgemein für K Klassen $K \cdot (K - 1)/2$ binäre Klassifikatoren [17]. Somit erhält man insgesamt 105 Klassifikatoren für 15 Klassen.

Die SVM hat gewählte 17-dimensionale Inputs und einen Output, nämlich das Ergebnis der zugeordneten Klasse. Insgesamt wurden 10043 Trainingsdaten für die Entwicklung der SVM und 2495 Testdaten verwendet. Sie wurden zufällig aus einer größeren Datenmenge von insgesamt 109813 ausgesucht (vgl. 4.5).

Die Entwicklung einer SVM wird in zwei Teile geteilt. Der erste Teil besteht aus dem Trainingsalgorithmus für den Klassifikator. Um diese Lerneinheit zu entwickeln, braucht es die Trainingsdaten (siehe Kapitel 4). In diesem wird die optimale separierende Hyperebene mit maximalem Abstand zu den nächsten Datenpunkten gefunden. Der zweite Teil entspricht der Klassifikationseinheit, indem er auf Testdaten angewendet wird.

In der Trainingsphase handelt es sich bei den EKG-Signalen um nichtlinear trennbare Daten, die über die Kernel Methoden in einen höher dimensionalen Merkmalsraum übergeführt werden müssen, um dort linear trennbar gemacht zu werden.

Numerisch kann das QP-Problem (siehe oben 5.1.4) durch verschiedene Algorithmen gelöst werden. Drei wichtige Algorithmen für das Trainieren von SVMs sind Chunking, Sequential Minimal Optimization (SMO) und SVM^{light} von Joachims ([24], S. 53). Da *Sequential Minimal Optimization* ein Algorithmus ist, der für das schnelle Training von SVMs verwendet werden kann ([24], S. 145), wurde dieser in dieser Arbeit ausgewählt (siehe Anhang, 9.3). Ein SVM Training erfordert die Lösung eines sehr großen Optimierungsproblems der quadratischen Programmierung. SMO bricht dieses große QP-Problem in eine Reihe von kleinst möglichen QP-Problemen. Diese kleinen QP-Probleme werden analytisch gelöst, was die übliche Verwendung von rechenintensiver numerischer quadratischer Programmierung als innere Schleife vermeidet [35].

Kernfunktionen können linear, polynomial oder radial sein. Diesem Trainingsalgorithmus wird als Kernfunktion die Gaussian oder *Radiale Basisfunktion* (RBF) mit einem Skalierungsfaktor von $\gamma = 2$ übergeben,

$$K(\mathbf{y}^{(i)}, \mathbf{y}) = e^{-\gamma|\mathbf{y}^{(i)} - \mathbf{y}|^2}. \quad (5.35)$$

Die benutzerdefinierte Konstante oder Feldbedingung C wurde nach [37] auf 100 gesetzt.

5.2 KOMBINATION DER KLASSIFIZIERER

Einzelne Klassifikatoren zu einem großen ganzen Gesamtklassifikator zu vereinen (siehe Abbildung 28, bringt zusätzlich bessere Ergebnisse und erfolgt durch das gewichtete Votieren (*weighted voting principle*). Das bedeutet, es wird für einen Herzschlag das Ergebnis mit dem größten Gewicht als Resultat der Gesamtklassifikation gewählt. Mit anderen Worten, das Ergebnis mit dem größten Gewicht entspricht der am häufigst vorkommenden Klasse unter den Einzelklassifizierern ([37], S. 585-586).




Abbildung 28: Schema einer Gesamtklassifikation

Seien die einzelnen Größen gegeben durch

K ... Anzahl der Klassen

M ... Anzahl der Merkmale

n ... Anzahl der Merkmalstupel (der Herzschläge)

d ... Anzahl der Datenpunkte eines Herzschlages

N ... Anzahl der Klassifikatoren

Für den i -ten Herzschlag ($i = 1, \dots, n$) gilt:

$\mathbf{x}^{(i)} = (x_1^{(i)}, x_2^{(i)}, \dots, x_d^{(i)})$... Rohdaten

$P_1, \dots, P_N$ = Aufbereitungsblöcke (preprocessing blocks)

$\mathbf{y}^{(i)} = (y_1^{(i)}, y_2^{(i)}, \dots, y_M^{(i)})$... i -tes Merkmalstupel

$C_1, \dots, C_N$ = neuronale Klassifikatoren (classifier)

$\mathbf{v}^{(i)} = (v_1^{(i)}, v_2^{(i)}, \dots, v_N^{(i)})$... Output des Klassifikators, klassifizierter Merkmalstupel

W ... Integrationsmatrix, Kombination der Resultate der Einzelklassifikatoren

$\mathbf{z}^{(i)} = (z_1^{(i)}, z_2^{(i)}, \dots, z_N^{(i)})$... klassifizierter Herzschlag nach der Gesamtklassifikation

Der Zielvektor (*target vector*) $\mathbf{t}^{(i)}$ für $i = 1, \dots, n$ repräsentiert die Zugehörigkeit des i -ten Herzschlages zur entsprechenden Klasse. Er hat als Länge die Anzahl der Klassen und ist gefüllt mit Nullen und nur einem Einser, dessen Position die entsprechende Klasse angibt. Die Targetvektoren für n Herzschläge werden zusammengefasst in einer $(n \times K)$ - Matrix $\mathbf{T}$

$$\mathbf{T} = \begin{bmatrix} \mathbf{t}^{(1)} \\ \mathbf{t}^{(2)} \\ \dots \\ \mathbf{t}^{(n)} \end{bmatrix} = \begin{bmatrix} t_1^{(1)} & t_2^{(1)} & \dots & t_K^{(1)} \\ t_1^{(2)} & t_2^{(2)} & \dots & t_K^{(2)} \\ \dots & \dots & \dots & \dots \\ t_1^{(n)} & t_2^{(n)} & \dots & t_K^{(n)} \end{bmatrix} \quad (5.36)$$

mit $\mathbf{t}^{(i)} = [t_1^{(i)}, t_2^{(i)}, \dots, t_K^{(i)}]$ für $i = 1, \dots, n$.

Die einzelnen Klassifizierer haben alle Outputs, die ähnlich wie die Zielvektoren eine bestimmte Klasse als Resultat anzeigen (durch einen einzigen entsprechenden Einser neben Nullen). Die Outputs $\mathbf{v}_j^{(i)}$ von j Klassifikatoren für den i -ten Herzschlag bilden eine Matrix $\mathbf{V} \subset \mathbb{R}^{n \times NK}$

$$\mathbf{V} = \begin{bmatrix} \mathbf{v}_1^{(1)} & \mathbf{v}_2^{(1)} & \dots & \mathbf{v}_N^{(1)} \\ \mathbf{v}_1^{(2)} & \mathbf{v}_2^{(2)} & \dots & \mathbf{v}_N^{(2)} \\ \dots & \dots & \dots & \dots \\ \mathbf{v}_1^{(n)} & \mathbf{v}_2^{(n)} & \dots & \mathbf{v}_N^{(n)} \end{bmatrix}, \quad (5.37)$$

wobei $\mathbf{v}_j^{(i)} = [v_{j1}^{(i)}, v_{j2}^{(i)}, \dots, v_{jK}^{(i)}]$ für $i = 1, \dots, n$ und $j = 1, \dots, N$.

Sei $\mathbf{W} \subset \mathbb{R}^{NK \times K}$ die sogenannte Integrationsmatrix der anfangs unbekannten Gewichtsvektoren $\mathbf{w}_j^{(k)}$ des j -ten Klassifizierers für Herzschläge die zur k -ten Klasse gehören:

$$\mathbf{W} = \begin{bmatrix} \mathbf{w}_1^{(1)} & \mathbf{w}_2^{(1)} & \dots & \mathbf{w}_N^{(1)} \\ \mathbf{w}_1^{(2)} & \mathbf{w}_2^{(2)} & \dots & \mathbf{w}_N^{(2)} \\ \dots & \dots & \dots & \dots \\ \mathbf{w}_1^{(K)} & \mathbf{w}_2^{(K)} & \dots & \mathbf{w}_N^{(K)} \end{bmatrix}^T, \quad (5.38)$$

wobei $\mathbf{w}_j^{(k)} = [w_{j1}^{(k)}, w_{j2}^{(k)}, \dots, w_{jK}^{(k)}]$ für $k = 1, \dots, K$ und $j = 1, \dots, N$.

Alle Gewichtsvektoren dieser Matrix $\mathbf{W}$ werden durch das Verfahren der kleinsten Quadrate gefunden (siehe 4). Das bedeutet, sie werden durch Minimierung der durchschnittlichen quadratischen Fehler über alle Trainingsdaten berechnet:

$$\min_{\mathbf{W}} \|\mathbf{VW} - \mathbf{T}\|^2. \quad (5.39)$$

Durch die Bestimmung der Singulärwertzerlegung von $\mathbf{V}$ und damit der Pseudoinversen $\mathbf{V}^+$ folgt (siehe 4.16 in Definition 4.1.2.2):

$$\mathbf{W} = \mathbf{V}^+ \mathbf{T}. \quad (5.40)$$

Nun wird die Matrix $\mathbf{W}$ auf die Output-Matrix $\mathbf{V}$ der Klassifikatoren angewendet und man erhält das Resultat des gesamten Klassifikationssystems in Form von $\mathbf{Z}$:

$$\mathbf{Z} = \mathbf{VW} = \begin{bmatrix} z_1^{(1)} & z_2^{(1)} & \dots & z_K^{(1)} \\ z_1^{(2)} & z_2^{(2)} & \dots & z_K^{(2)} \\ \dots & \dots & \dots & \dots \\ z_1^{(n)} & z_2^{(n)} & \dots & z_K^{(n)} \end{bmatrix}, \quad (5.41)$$

wobei $\mathbf{z}^{(i)} = [z_1^{(i)}, z_2^{(i)}, \dots, z_K^{(i)}]$ für $i = 1, \dots, n$.

Für den i -ten Herzschlag gilt: Die Position des Elements mit dem größten Wert von $\mathbf{z}^{(i)}$ zeigt auf die entsprechende Klasse.

Eine Kombination der Klassifizierer zu einem ganzen Klassifikationssystem ist wie sich zeigt erfolgreich, bei der Klassifikation zusätzlich bessere Ergebnisse zu erzielen (siehe Resultate im 6. Kapitel). Es können entweder verschiedene Netzwerke von Klassifikatoren oder nur verschiedene Methoden zur Vorverarbeitung der Daten in einem Klassifikator zusammen geschaltet werden [37].

5.3 SOM - SELBST ORGANISIERTE KARTE

Eine Selbstorganisierte Karte (Self Organizing Maps, Kohonen-Netze, SOM), erfunden von Teuvo Kohonen, gehört zu den neuronalen Netzen als unüberwachte Lernmethode. Diese neuronalen Netze haben den Namen durch Nachbildung von biologischen Prozessen, genauer von Vernetzung der Nervenzellen (Neuronen) im Gehirn [38].




Abbildung 29: Schema eines zweischichtigen Neuronalen Netzes mit 2-dimensionalem Gitter der Größe $X \times Y$ bestehend aus zusammenhängenden Knoten und den Gewichtsverbindungen w zu den einzelnen Merkmalen des Eingangsvektors $\mathbf{y}^i$ [7].

Bei der Modellierung neuronaler Netze sind die Neuronen und deren Verbindungen im Netz die Hauptbestandteile. Mathematisch werden Grundbegriffe aus der Graphentheorie verwendet. Neuronen sind dann die Knoten im Graphen, die miteinander verbunden sind, sodass ein Gitter entsteht. Ihnen wird ein Zustand (Aktivierung) und Transformationsfunktionen - Propagierungs-, Aktivierungs- und Outputfunktion - zugewiesen. Dazu kommt die Gewichtsmatrix (Adjazenzmatrix), sie gibt die Stärke der Verbindung zwischen den Neuronen an [38]. Für Kohonennetze basiert ihre Netzstruktur auf zwei Schichten, der Eingabeschicht und einer Ausgabeschicht. Die Anzahl der Neuronen der Eingabeschicht und die Dimension des Eingabevektors sind gleich. Die Neuronen der Ausgabeschicht erzeugen das zweidimensionale Gitter. Jeder Knoten der Ausgabeschicht ist mit allen Knoten der Eingabeschicht verbunden [38], siehe Abbildung 29.

Unüberwachtes Lernen in Neuronalen Netzen bedeutet selbstorganisiertes Lernen [38], d.h. SOMs müssen sich selbst nach der Struktur der eingegebenen Daten organisieren [27]. Kohonen-Karten lernen unüberwacht nach der Technik des kompetitiven Lernens. Die Neuronen der Ausgabeschicht konkurrieren untereinander um die stärkste Aktivierung in Richtung Eingangsdaten. Nur genau ein Neuron - das Gewinner-Neuron (*winner*) - wird durch einen Reiz (Eingangssignal) erregt. Das entspricht dem „*winner takes all*“-Prinzip ([38], S. 196). „Die Lage der am stärksten erregten Neuronen korreliert daher mit bestimmten, ähnlichen Merkmalen der Eingangsreize. Man spricht deshalb von einer topologischen Merkmals-Kartierung“, folgern J. Schmidt et al. [38], S. 195.

Selbst Organisierte Karten unterscheiden sich von herkömmlichen konkurrierenden Lernmethoden in einer bedeutenden Eigenschaft. Es wird nicht nur das Gewicht des Gewinner-Neurons, sondern zusätzlich auch die Gewichte der Nachbarknoten des Gewinner-Neurons aktualisiert. Das Ergebnis ist, dass die Nach-

barneuronen zu ähnlichen Gewichtsvektoren neigen und auf ähnliche Eingangsvektoren ansprechen [8].

5.3.1 Mathematische Beschreibung

Eine Selbst Organisierte Karte weist topologische Strukturen auf, die man mathematisch beschreiben kann. Der folgende mathematisch theoretische Abschnitt basiert auf der Publikation von Lagerholm et al. [27].




Abbildung 30: Die SOM Abbildung von einem höher dimensional Raum zu einem diskreten 2-D-Raum [27].

Die Idee der Selbst Organisierten Karte ist die Abbildung einer Menge von M -dimensionalen Inputvektoren $\mathbf{y}^{(i)}$ für $i = 1, \dots, n$ auf einen diskreten 2-dimensionalen Raum mit K Positionen (siehe Abbildung 30). Jede Position im Ausgangsraum wird repräsentiert durch einen Ausgangsknoten, h_j für $j = 1, \dots, K$. Jedem h_j wird eine Position ω_j im Eingangsraum zugeordnet. Der Abstand zwischen h_j und einem Eingangsvektor $\mathbf{y}^{(i)}$ ist gegeben durch

$$d_j = \sum_{k=1}^M (\omega_{jk} - y_k^{(i)})^2. \quad (5.42)$$

Für jedes Merkmalstupel $\mathbf{y}^{(i)}$ wird das h_j gewählt, das ihm am nächsten ist. Für das gewinnende Neuron h_{i^*} gilt dann

$$d_{i^*} = \min_j d_j. \quad (5.43)$$

Die Eingangsvektoren mit h_{i^*} als Gewinner werden dem Cluster (Ausgangsknoten) i^* zugeordnet. Die Positionen ω_j von h_j im Eingangsraum können als die Gewichte im Zuordnungsprozess gesehen werden. Die Gewichte werden nach jedem Schritt aktualisiert, sodass h_j auf die vorliegenden Muster eingehen kann. Das erfolgt durch

$$\omega_{jk} \longrightarrow \omega_{jk} + \Delta\omega_{jk} \quad (5.44)$$

$$\Delta\omega_{jk} = \begin{cases} \eta(y_k^{(i)} - \omega_{jk}) & \text{wenn } j = i^* \\ 0 & \text{wenn } j \neq i^* \end{cases} \quad (5.45)$$

wobei η die Schrittgröße in Richtung des Merkmalstupels darstellt, die sich im Laufe des Trainings ändert.

Es ist oft wünschenswert, eine topologische Ordnung unter den Ausgabeneinheiten so zu haben, dass benachbarte Einheiten im Ausgangsraum auf benachbarte Punkte im Eingangsraum antworten. Eine solche topologische Karte zu

erhalten entspricht der schon angedeuteten Technik, die Einheiten in der Nähe vom Gewinner-Knoten in der gleichen Weise zu aktualisieren wie den Gewinner-Knoten selbst. Umgesetzt wird dies mit einem Schritt, der zusätzlich zu η auch von der Distanz r zum Gewinner Neuron im Ausgangsraum abhängt. Auf diese Weise enden benachbarte Einheiten mit ähnlichen Gewichtsvektoren. Dies wird mit sogenannten Potts Neuronen vollzogen, unter diesen der Gewinner-Knoten seinen Schritt mit seinen Nachbarn „teilt“. Die Gleichung 5.45 ändert sich zu

$$\Delta\omega_{jk} = \eta(y_k^{(i)} - \omega_{jk})v_{i^*m} \quad \text{für alle } m, \quad (5.46)$$

mit

$$v_{i^*m} = \frac{e^{-r_{i^*m}^2/T}}{\sum_k e^{r_{i^*k}^2/T}}, \quad (5.47)$$

wobei r_{ij} die Distanz zwischen den Ausgabeeinheiten in der Ausgabeschicht und somit die Topologie des Netzwerkes definiert. Die Weite T verringert sich während der Trainingsphase. Für $T \rightarrow 0$ wird Gleichung 5.46 zu 5.45 ([27], S. 841).

5.3.2 Implementierung in MATLAB®

Die Implementierung wurde mit Hilfe der Neural Network Toolbox von MATLAB® und der Clustering-Methode erzeugt [8].

Mit Hilfe der topologischen Struktur eines Kohonen-Netzes wurde eine QRS-Karte für die Herzsignale als Inputvektoren erstellt. Die Abbildung dieser erfolgte durch Verwendung von 5.42 und 5.43 auf eine Karte der Größe 5×5 . Da für die SOM 14 Merkmale ausgesucht wurden (siehe 4.5), bildet die Karte den 14-dimensionalen Merkmalsraum auf den 2-dimensionalen 5×5 Ausgangsraum ab [27].

Der Trainingsalgorithmus der Selbst Organisierten Karte ist ein iteratives Verfahren. Iteriert wird nach vorgegebenen Lernschritten (*Epochen*) ([38], S. 196). Zuerst werden die Gewichte initialisiert und die Nachbarschaft (T) groß gewählt [27]. Die Nachbarn liegen in einer durch einen geeigneten Radius definierten Umgebung des Gewinner-Knotens [38]. Während der Epochen gelangen die Merkmalstupel nacheinander – meist in zufälliger Reihenfolge – in die Eingabeschicht des Netzes (vgl. [38], S. 196). Das Training dieser Methode wird in zwei Phasen unterteilt, die Ordering Phase und die Tuning Phase [8]. In jedem Trainingsschritt wird zuerst der Gewinner-Knoten berechnet, also das Neuron, dessen Gewichtsvektor dem Merkmalstupel am nächsten ist. In anderen Worten: Das Netzwerk identifiziert das gewinnende Neuron für jeden Eingangsvektor [8]. Im Folgenden werden die Gewichte des Gewinners und der benachbarten Neuronen angepasst, d.h. die Gewichte werden dem Eingabevektor angenähert oder zu ihm hin gezogen (vgl. [38], S. 196). Jeder Gewichtsvektor bewegt sich dann auf die Eingangsvektoren zu, für die oder für deren Nachbarschaft er ein Gewinner ist [8]. Der Abstand, der die Größe der Nachbarschaft definiert, wird während des Trainings durch diese zwei Phasen verändert [8].

Ordering Phase:

Der Abstand zur Nachbarschaft hat einen festgelegten Anfangswert. Der Abstand zur Nachbarschaft nimmt während dieser Phase ab [8]. Die Dauer dieser Phase wird durch die Anzahl der Schritte vorgegeben. Die *Lernrate* η der Ordnungsphase verringert sich entsprechend dem Gesetz

$$\eta_{t+1} = k\eta_t \quad (5.48)$$

mit $\eta_0 = 1$ und $k = 0.96$.

Die Lernrate der Tuning Phase ist η_{min} [27].

Tuning Phase:

Diese Phase ist die letzte des Trainings [8].

Die *Nachbarschaft* verhält sich dann in dieser Phase nach der Formel

$$T_{t+1} = cT_t \quad (5.49)$$

mit t Iterationszahl, $c = 0.95$ und $T_t = -\frac{d^2}{\ln(2)}$. d beschreibt dabei den diagonalen Abstand der Karte [27]. T steht mit der Nachbarschaft insofern in Beziehung, als dass die Größe der Nachbarschaft mit der Größe von T wächst, d.h. T ist die Weite der Nachbarschaft.

Folgende Parameter wurden in der Implementierung gesetzt [8]:

Schritte der Ordering Phase = 200.

Initiale Nachbarschaftsgröße = 3, die Distanz von einem Knoten zu dem nächsten Knoten.

Das *Gitter* des Ausgangsraumes kann verschiedene Formen aufweisen: hexagonal, quadratisch oder rechteckig. Gewählt wurde die hexagonale topologische Struktur zur Veranschaulichung des Cluster-Netzes. Die Entfernungen zwischen den Neuronen werden mit der euklidischen Norm als *Abstandsfunktion* berechnet.

In MATLAB® wurde dafür der Batch-Algorithmus verwendet. Eine Beschreibung der Implementierung zu dieser Methode SOM findet man im Anhang siehe 9.4.

5.4 PERFORMANCE EINES KLASSIFIKATORS

In diesem Abschnitt werden die verwendeten Messinstrumente zur Bewertung der Performance eines Klassifikators vorgestellt (siehe [1], S. 13-15). Die Auswertung eines Klassifikators gibt an, wie gut und genau er funktioniert.

Ein Klassifizierer wird getestet, indem man ihn auf Testdaten anwendet. Um ihn für einen Testdatensatz optimal nach seinen Eigenschaften zu bewerten, gibt es bestimmte Kriterien und Vorgaben, wie folgt.

Angenommen, es gibt K Klassen und n Herzschläge in der Stichprobe, die zu klassifizieren sind.

Um einen Klassifikator zu überprüfen wird zunächst eine $K \times K$ - Konfusionsmatrix A (*confusion matrix*) generiert, deren Element a_{ij} die Anzahl der Daten angibt, die der Klasse i angehören und durch die Klassifikation der Klasse j zugeordnet wurden. Das bedeutet, dass alle Diagonalelemente a_{ii} dieser Matrix die richtig und alle anderen die falsch klassifizierten Elemente umfassen (siehe Tabelle 4).

Dann ist die Erkennungsrate R oder die Erkennungsgenauigkeit (*recognition rate*, *recognition accuracy*) in % definiert durch

$$R = \frac{\sum_{i=1}^K a_{ii}}{\sum_{i,j=1}^n a_{ij}} \times 100. \quad (5.50)$$

Umgekehrt bezeichnet E die Fehlerrate (*error rate*) und ist in % gegeben durch

$$E = \frac{\sum_{i \neq j, i,j=1}^K a_{ij}}{\sum_{i,j=1}^n a_{ij}} \times 100, \quad (5.51)$$

wobei $R + E = 100\%$, vorausgesetzt alle Daten sind klassifiziert.

Die Erkennungsrate (oder Fehlerrate) gibt die Gesamtleistung eines Klassifikators an und wird verwendet, um verschiedene Klassifikatoren zu vergleichen.

Für den Fall mehrerer unterschiedlicher Klassifikationsprobleme ist unzureichend nur die durchschnittlichen Erkennungsraten der Klassifikatoren zu vergleichen.

Tabelle 4: Konfusionsmatrix A mit $K = 2$ Klassen, z.B. für ein Diagnoseproblem. TP (true positive), FP (false positive) korrekt und falsch klassifizierte positive Daten; TN (true negative), FN (false negative) korrekt und falsch klassifizierte negative Daten.

	Assigned positive	Assigned negative
Actual positive	TP	FN
Actual negative	FP	TN

Weitere gängige Parameter zur Evaluierung der Erkennungsleistung eines Klassifikators sind daher:

Der positive Vorhersagewert (*precision*, *positive predictive value*) definiert durch

$$Precision = \frac{TP}{TP + FP} \quad (5.52)$$

und die Sensitivität (*sensitivity*, *recall*, *True-positive rate*) gegeben durch

$$Recall = \frac{TP}{TP + FN}. \quad (5.53)$$

Ein Klassifikator mit Erkennungsrate, Precision- und Recall-Werten nahe bei 1 ist daher zu bevorzugen.

6

RESULTATE

In diesem Kapitel werden die Ergebnisse der besprochenen implementierten Klassifizierungsmethoden, der Support Vektor Maschine und der Selbst Organisierten Karte, anhand von Graphiken und Tabellen vorgestellt.

6.1 SUPPORT VEKTOR MASCHINE

Das Ergebnis einer Support Vektor Maschine kann für 2 Merkmale der Merkmalstupel im 2-dimensionalen Merkmalsraum abgebildet werden, siehe Abbildung 31.




Abbildung 31: Zur Veranschaulichung eines Outputs im 2-dimensionalen Raum der implementierten Support Vektor Maschine unter der Methode HOS sind von dem für die HOS-Methode vorbereiteten Merkmalstupel $\{y(1), \dots, y(15)y(61)y(62)\}$ die folgenden Elemente $\{y(15)y(61)\}$ gewählt (siehe 4.5). Die Positionen der roten und grünen Kreuze stehen für die Trainingsdaten von Klasse 1 und Klasse 2. Die rosa und blauen 2-dimensionalen Merkmalsvektoren sind die klassifizierten Testdaten, rosa für Klasse 1 und blau für Klasse 2. Die eingekreisten Datenpunkte stellen die Support Vektoren der Hyperebene dar, sie befinden sich entlang der Hyperebene. Die Hyperebene selbst ist als schwarze Linie dargestellt.

Bei diesem Resultat sieht man eine klare Trennung der Datenpunkte durch die Hyperebene zwischen den zwei Klassen. Durch die Transformation des Merkmalsraumes in einen höher dimensional Merkmalsraum wurden die optimale Hyperebene bestimmt und die eigentlich nicht linear trennbaren Daten linear trennbar. Bei der Rücktransformation in den Eingangsraum sieht man, dass die Hyperbene im Eingangsraum nichtlinear, in diesem Fall sogar nicht zusammenhängend ist. Streng genommen handelt es sich dabei somit um eine Hyperfläche. Außerdem erkennt man, dass die Support Vektor Maschine ziemlich robust gegenüber Outlier ist, denn auch diese werden erkannt.

SVM und Methode HOS

Tabelle 5: Die Ergebnisse der Mustererkennung von verschiedenen Typen von Herzschlägen durch die SVM mit HOS als Merkmale. Genauer, die relativen und absoluten Testfehler der Klassifikation anhand von Testdaten jedes Typen.

Typen der Herzschläge	Anzahl der Trainingsdaten	Anzahl der Testdaten	Absolute Testfehler	Relative Testfehler (%)
N	3200	800	52	6.5%
L	960	240	28	11.67%
R	800	200	14	7%
A	722	180	26	14.44%
a	96	24	12	50%
J	68	7	2	28.57%
V	2007	502	15	2.99%
F	514	128	33	25.78%
I	302	76	26	34.21%
e	13	1	1	100%
j	146	37	18	48.65%
E	68	17	3	17.65%
P	800	200	12	6%
f	320	80	36	45%
Q	27	3	3	100%
Total	10043	2495	281	11.26%

Tabelle 6: Konfusionsmatrix der SVM mit HOS als Merkmale. Die Daten gehören zu den Klassen in der vertikalen Achse, während sie in die Klassen auf der horizontalen Achse klassifiziert werden. Die Anzahl der richtig klassifizierten Herzsignale befindet sich in den Diagonaleinträgen.

HOS	N	L	R	A	a	J	V	F	I	e	j	E	P	f	Q	rel. Fehler [%]
N	748	1	0	4	1	0	25	15	0	2	2	0	0	2	0	6,50
L	7	212	0	0	0	0	21	0	0	0	0	0	0	0	0	11,67
R	8	0	186	0	0	1	5	0	0	0	0	0	0	0	0	7,00
A	13	0	2	154	0	0	11	0	0	0	0	0	0	0	0	14,44
a	0	0	0	0	12	0	12	0	0	0	0	0	0	0	0	50,00
J	1	0	1	0	0	5	0	0	0	0	0	0	0	0	0	28,57
V	2	1	2	0	0	0	487	7	3	0	0	0	0	0	0	2,99
F	16	0	1	0	0	0	16	95	0	0	0	0	0	0	0	25,78
I	0	0	0	0	0	0	26	0	50	0	0	0	0	0	0	34,21
e	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100,00
j	15	0	0	0	0	0	3	0	0	0	19	0	0	0	0	48,65
E	0	0	0	0	0	0	3	0	0	0	0	14	0	0	0	17,65
P	0	0	0	0	0	0	11	0	0	0	0	0	188	1	0	6,00
f	9	0	0	0	0	0	22	0	0	0	0	0	5	44	0	45,00
Q	0	0	0	0	0	0	3	0	0	0	0	0	0	0	0	100,00
rel. Fehler [%]	8,78	0,93	3,13	2,53	7,69	16,67	24,50	18,80	5,66	100,00	9,52	0,00	2,59	6,38	---	-----

Aus den Tabellen 5 und 6 geht für die SVM mit HOS als Merkmale eine Streuung der relativen Testfehler von 2.99% bis zu 100% hervor. Lässt man die Ausreißer e und Q außer Acht, reicht sie von 2.99% bis 50% mit dem Bestwert von 2.99% für V. Die Tabelle 5 zeigt die Anzahl der Daten, die zum Trainieren und Testen verwendet worden sind. Die Konfusionsmatrix aus Tabelle 6 dient der Darstellung, in welche Klassen die Daten zugeordnet wurden. Viele der Daten werden als N oder V klassifiziert. Der Unterschied von 5 zu 6 ist, dass in 5

die Anzahl der Trainings- und Testdaten und die absoluten Testfehler zusätzlich ersichtlich sind. Dasselbe gilt für die Tabellen 7 zu 8 und 9 zu 10.

SVM und Methode HER

Tabelle 7: Die Ergebnisse der Mustererkennung von verschiedenen Typen von Herzschlägen durch die SVM mit HER als Merkmale. Es sind die Anzahl der gewählten Testdaten sowie deren Testfehler durch die Klassifikation für jeden Herzschlag Typ aufgelistet.

Typen der Herzschläge	Anzahl der Trainingsdaten	Anzahl der Testdaten	Absolute Testfehler	Relative Testfehler (%)
N	3200	800	10	1.25%
L	960	240	21	8.75%
R	800	200	19	9.5%
A	722	180	40	22.22%
a	96	24	15	62.5%
J	68	7	5	71.43%
V	2007	502	53	10.56%
F	514	128	24	18.75%
I	302	76	34	44.74%
e	13	1	1	100%
j	146	37	25	67.57%
E	68	17	2	11.77%
P	800	200	18	9%
f	320	80	25	31.25%
Q	27	3	3	100%
Total	10043	2495	295	11.82%

Tabelle 8: Konfusionsmatrix der SVM mit HER als Merkmale. Die vertikale Achse entspricht den Herzschlägen die zu den jeweiligen Klassen gehören, wohingegen die horizontale Achse sich als Ergebnis deren Klassifikation liest. Die Anzahl der richtig klassifizierten Daten befinden sich in den Diagonaleinträgen.

HER	N	L	R	A	a	J	V	F	I	e	j	E	P	f	Q	rel. Fehler [%]
N	790	1	0	4	0	0	1	2	0	1	1	0	0	0	0	1,25
L	17	219	0	0	0	0	4	0	0	0	0	0	0	0	0	8,75
R	18	0	181	0	0	1	0	0	0	0	0	0	0	0	0	9,50
A	36	0	0	140	1	0	3	0	0	0	0	0	0	0	0	22,22
a	11	0	0	0	9	0	4	0	0	0	0	0	0	0	0	62,50
J	4	0	1	0	0	2	0	0	0	0	0	0	0	0	0	71,43
V	47	0	0	0	0	0	449	5	1	0	0	0	0	0	0	10,56
F	18	0	0	0	0	0	6	104	0	0	0	0	0	0	0	18,75
I	26	0	0	0	0	0	8	0	42	0	0	0	0	0	0	44,74
e	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100,00
j	25	0	0	0	0	0	0	0	0	0	12	0	0	0	0	67,57
E	2	0	0	0	0	0	0	0	0	0	0	15	0	0	0	11,76
P	18	0	0	0	0	0	0	0	0	0	0	0	182	0	0	9,00
f	22	1	0	0	0	0	1	0	0	0	0	0	1	55	0	31,25
Q	3	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100,00
rel. Fehler [%]	23,89	0,90	0,55	2,78	10,00	33,33	5,67	6,31	2,33	100,00	7,69	0,00	0,55	0,00	---	-----

Die relativen Testfehler streuen für die SVM mit HER als Merkmale von 1.25% bis 100% wie man aus den Tabellen 7 und 8 erkennen kann. Wenn man

über die groben Ausreißer e und Q hinwegsieht, folgt eine Streuung von 1.25% für N bis 71.43% für J. Aus der Tabelle 8 geht hervor, dass fast alle falsch klassifizierte Daten in die Gruppe N eingehen.

Kombination HOS und HER

Tabelle 9: Die Ergebnisse der Mustererkennung von verschiedenen Typen von Herzschlägen durch die Kombination der HOS und HER Merkmale in zwei SVMs. Die gewählten Testdaten sowie deren Fehlklassifikation für jeden Herzschlag Typ sind aufgelistet.

Typen der Herzschläge	Anzahl der Trainingsdaten	Anzahl der Testdaten	Absolute Testfehler	Relative Testfehler (%)
N	3200	800	38	4.75%
L	960	240	12	5.26%
R	800	200	9	4.50%
A	722	180	22	12.22%
a	96	24	5	20.83%
J	68	7	2	28.57%
V	2007	502	10	1.99%
F	514	128	24	18.75%
I	302	76	14	18.42%
e	13	1	1	100%
j	146	37	11	29.73%
E	68	17	0	0.00%
P	800	200	0	0.00%
f	320	80	17	21.25%
Q	27	3	3	100%
Total	10043	2495	168	6.73%

Tabelle 10: Die Konfusionsmatrix der Gesamtklassifikation der Merkmale HOS und HER. Genauer: Das Resultat der Kombination der Ergebnisse der HOS und HER Methoden in der SVM durch gewichtetes Voting Prinzip.

HOS & HER	N	L	R	A	a	J	V	F	I	e	j	E	P	f	Q	rel. Fehler [%]
N	762	1	0	4	1	0	25	2	0	0	3	0	0	2	0	4,75
L	7	228	0	0	0	0	5	0	0	0	0	0	0	0	0	5,00
R	8	0	191	0	0	1	0	0	0	0	0	0	0	0	0	4,50
A	13	0	2	158	1	0	6	0	0	0	0	0	0	0	0	12,22
a	0	0	0	0	19	0	5	0	0	0	0	0	0	0	0	20,83
J	1	0	1	0	0	5	0	0	0	0	0	0	0	0	0	28,57
V	3	0	0	0	0	0	492	5	2	0	0	0	0	0	0	1,99
F	19	0	0	0	0	0	5	104	0	0	0	0	0	0	0	18,75
I	0	0	0	0	0	0	14	0	62	0	0	0	0	0	0	18,42
e	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100,00
j	10	0	0	0	0	0	1	0	0	0	26	0	0	0	0	29,73
E	0	0	0	0	0	0	0	0	0	0	0	17	0	0	0	0,00
P	0	0	0	0	0	0	0	0	0	0	0	0	200	0	0	0,00
f	3	1	0	0	0	0	10	0	0	0	0	3	63	0	0	21,25
Q	0	0	0	0	0	0	3	0	0	0	0	0	0	0	0	100,00
rel. Fehler [%]	7,86	0,87	1,55	2,47	9,52	16,67	13,07	6,31	3,13	---	10,34	0,00	1,48	3,08	---	-----

Die Tabelle 9 zeigt, wenn man von den Ausreißern e und Q absieht, dass sich die relativen Testfehler für die Kombination von den Merkmalen HOS und HER

von 1.99% bis 29.73% erstrecken, mit dem Bestwert für V. Aus der Konfusionsmatrix 10 ist ersichtlich, dass nur mehr wenige Datensätze falsch in N und V klassifiziert werden.

Ein Vergleich der Erkennungsraten (accuracy rates) der beiden Methoden HOS und HER mit deren Integration in ein Gesamtklassifizierungskonzept ergibt 88.4% für die HOS Merkmale, 87% für die HER Merkmale und 92.8% für die Integration.

Tabelle 11: Vergleich der positiven Vorhersage Werte (Precision) sowie der Sensitivität (Recall) der Merkmale HOS und HER und deren Kombination zu einem Gesamtklassifizierungskonzept für jeden Typ von Herzschlag.

	Precision			Recall		
	HOS	HER	Kombination	HOS	HER	Kombination
N	0.9122	0.7611	0.9214	0.9350	0.9875	0.9525
L	0.9907	0.9910	0.9913	0.8833	0.9125	0.9500
R	0.9688	0.9945	0.9845	0.9300	0.9050	0.9550
A	0.9747	0.9722	0.9753	0.8556	0.7778	0.8778
a	0.9231	0.9000	0.9048	0.5000	0.3750	0.7917
J	0.8333	0.6667	0.8333	0.7143	0.2857	0.7143
V	0.7550	0.9433	0.8693	0.9701	0.8944	0.9801
F	0.8120	0.9369	0.9369	0.7422	0.8125	0.8125
I	0.9434	0.9767	0.9688	0.6579	0.5526	0.8158
e	0.0000	0.0000	NaN	0.0000	0.0000	0.0000
j	0.9048	0.9231	0.8966	0.5135	0.3243	0.7027
E	1.0000	1.0000	1.0000	0.8235	0.8824	1.0000
P	0.9741	0.9945	0.9852	0.9400	0.9100	1.0000
f	0.9362	1.0000	0.9692	0.5500	0.6875	0.7875
Q	NaN	NaN	NaN	0.0000	0.0000	0.0000

Die Precision- und Recall- Werte geben an, wie stark die Herzschläge einer Gruppe nach der Klassifikation unter allen Gruppen gestreut sind (siehe Tabelle 11). Die Werte für e und Q sind 0 oder undefiniert (NaN). Die besten Werte wurden in Gruppe E mit dem positiven Vorhersagewert 1 und Werten nahe 1 für die Sensitivität für alle drei Methoden erzielt.

6.2 SELBST ORGANISIERTE KARTE

Die folgenden Resultate beziehen sich auf den für die SOM gewählten Merkmalstupel $\{y(16, \dots, 20)y(30)y(46, \dots, 50)y(60)y(61)y(63)\}$ (siehe 4.5). Die Graphiken sind in der Neural Network Toolbox in MATLAB[®] entstanden [8]. Die einzelnen Herzschläge werden durch die SOM durch Verwendung von 5 Hermite-sche Basisfunktionen aus zwei EKG-Ableitungen, der Breite der QRS-Komplexe und den lokalen RR-Intervallen geclustert. Das verwendete Netz ist ein 2-dimensionales 5×5 Felder großes hexagonales Gitter bestehend aus 25 Knoten.

Bei Abbildung 32 ist in Folge herauszufinden, mit welchem Klassentyp die jeweiligen Cluster versehen sind. Die Cluster erhalten den Typ, von dem die meisten Herzschläge in einem Cluster vorhanden sind. Diese wiegen somit am schwersten pro Cluster und Knoten.




Abbildung 32: Dieser Plot zeigt, wie viele der Trainingsdaten in jedes Cluster klassifiziert und somit als ähnlich erachtet werden. Ein leeres Cluster würde eine Trennung zwischen benachbarten Clustern bedeuten, d.h. es gibt keine ähnlichen Herzschläge zwischen ihnen.

Die Abbildung 33 umfasst 25 Neuronen in Form von blauen Hexagons, zwischen ihnen sind die Distanzen zu den benachbarten Neuronen durch Striche und Farben gekennzeichnet. Eine große dunkle Region indiziert, dass sich wenige oder keine Herzschläge zwischen den Clustern befinden, d.h. sie haben fast nur unterschiedliche Eigenschaften.

Wenn man die Graphik 32 mit der Abbildung 33 vergleicht, bemerkt man, dass das Cluster, in dem sich am wenigsten Trainingsdaten, 616 an der Zahl, befinden, genau dem Cluster entspricht, welches zu seinen Nachbarn den größten Abstand hat (Distanzen am dunkelsten gefärbt). Das Cluster mit den meisten Trainingsdaten, 11076 an der Zahl, hat den geringsten Abstand (Distanzen am hellsten gefärbt), d.h. es befinden sich zwischen ihm und seinen Nachbarn viele ähnliche Herzschläge. Die Neuronen mit den Positionen (0,3.5), (0,0) und (2,0) am Rand sind entferntere Gruppen zu den anderen. Das Cluster mit der Position (4,3.5) enthält zu seinen anliegenden Nachbarn hingegen sehr ähnliche Herzschläge.

Die Abbildung 34 entspricht einer Abbildung der Input Features auf die einzelnen Cluster. Sie ist nicht linear und zeigt eine Gewichtsebene für jede der 14 Eingabefunktionen. Sie sind Visualisierungen der Gewichtungen, die jeden Input mit jedem der 25 Neuronen im 5×5 hexagonalen Gitter verbinden. Dunklere Farben repräsentieren größere Gewichte. Wenn zwei Inputs ähnliche Gewichtsebenen haben (ihre Farbverläufe können gleich oder umgekehrt sein), zeigt es, dass sie stark korrelieren [8].

Input 14 z.B. entspricht dem zeitlichen Merkmal $\{y(63)\}$ (siehe 4.5), dessen Gewicht in (0,4) dem Gewicht in (0,4) von Input 13 $\{y(61)\}$ ähnlich ist und somit deren Abhängigkeit verdeutlicht. Es handelt sich auch bei Input 13 um ein temporäres Merkmal.

In der Tabelle 12 ist klar erkennbar, dass N und V am stärksten ausgeprägt und durch die meisten Trainingsdaten vertreten sind. Alle schwach besetzten Gruppen werden in erster Linie als N oder V, in zweiter Linie als L, R oder P klassifiziert, d.h. diese werden zu 100% nicht in die eigene Gruppe eingeordnet.




Abbildung 33: Die Abstände zwischen den benachbarten Neuronen sind repräsentiert durch dunkle und helle Farben. Dunkle Regionen zwischen Clustern geben an, dass diese weit auseinander liegen. Das bedeutet wenig oder keine Ähnlichkeit der Herzschläge zwischen diesen Clustern. Helle Farben sind zwischen den Neuronen, deren Cluster ähnlich sind. Ein großer heller Bereich zeigt eine glatte Verteilung der Merkmale der Herzschläge.

Tabelle 12: Die annotierten Herzschläge sind auf der vertikalen Achse dargestellt, während die durch die verschiedenen Typen dominierten Cluster horizontal angezeigt sind. Beispielsweise werden 1526 der Gruppe N zu Clustern zugewiesen, in denen V dominiert.

SOM	N	L	R	A	a	J	V	F	I	e	j	E	P	f	Q	rel. Fehler [%]
N	72559	361	438	0	0	0	1526	0	0	0	0	0	64	0	0	3,19
L	6471	1441	0	0	0	0	154	0	0	0	0	0	0	0	0	82,13
R	2913	1	4319	0	0	0	11	0	0	0	0	0	0	0	0	40,38
A	2365	98	16	0	0	0	64	0	0	0	0	0	1	0	0	100,00
a	44	0	3	0	0	0	103	0	0	0	0	0	0	0	0	100,00
J	81	0	0	0	0	0	2	0	0	0	0	0	0	0	0	100,00
V	1893	309	108	0	0	0	4762	0	0	0	0	0	50	0	0	33,14
F	688	16	1	0	0	0	96	0	0	0	0	0	1	0	0	100,00
I	175	3	4	0	0	0	284	0	0	0	0	0	6	0	0	100,00
e	16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100,00
j	228	0	0	0	0	0	1	0	0	0	0	0	0	0	0	100,00
E	105	1	0	0	0	0	0	0	0	0	0	0	0	0	0	100,00
P	5535	2	0	0	0	0	3	0	0	0	0	0	1476	0	0	78,96
f	968	2	0	0	0	0	1	0	0	0	0	0	11	0	0	100,00
Q	25	0	0	0	0	0	7	0	0	0	0	0	1	0	0	100,00
rel. Fehler [%]	22,86	35,50	11,66	---	---	---	32,11	---	---	---	---	---	8,32	---	---	-----

Die relativen Fehlerraten der Typen von Klassen reichen von 3.19% bis 82.13% unter Nichtbeachtung der Klassen mit relativer Fehlerrate von 100%.

Die Berechnung der Erkennungsrate (accuracy rate) für die SOM ergibt durchschnittlich 75% nach 10 ganzen Durchläufen von 200 Iterationen. Für die Precision- und Recall-Werte dieser SOM liegen nur aussagekräftige Werte für die höherbesetzten Klassen vor (siehe Tabelle 13). Die Werte für die Sensitivität liegen zwischen 0.1749 für L und 0.9407 für N. Die positiven Verhersagewerte sind zwischen 0.5486 für P und 0.8688 für L.




Abbildung 34: Man sieht die Gewichtung jedes einzelnen Merkmals des Merkmalstups auf die einzelnen Cluster aufgeteilt. Ähnlich gefärbte Cluster zwischen den Gewichten zweier Inputs indizieren abhängige Merkmale und unähnliche Cluster unabhängige Merkmale.

Tabelle 13: Vergleich der positiven Vorhersage Werte (Precision) sowie der Sensitivität (Recall) der SOM für jeden Typ von Herzschlag.

	Precision	Recall
N	0.7654	0.9407
L	0.8688	0.1749
R	0.8037	0.6578
A	NaN	0.0000
a	NaN	0.0000
J	NaN	0.0000
V	0.6051	0.6345
F	NaN	0.0000
I	NaN	0.0000
e	NaN	0.0000
j	NaN	0.0000
E	NaN	0.0000
P	0.5486	0.2091
f	NaN	0.0000
Q	NaN	0.0000

7 | DISKUSSION

In diesem Kapitel werden die Schwächen und Stärken der Implementierung bezogen auf die Resultate besprochen. Die Stärken zeigen sich hauptsächlich bei der Klassifikation durch die Support Vektor Maschine und vor allem bei der Kombination von den Vorverarbeitungsmethoden HOS und HER. Die Schwächen zeigen sich in der Klassifikation durch die SOM.

7.1 SVM

Die relativen Testfehlerraten der SVM in Bezug auf die HOS Verarbeitung für die einzelnen Typen von Herzschlägen reichen von 2.99% für die Klasse V bis 100% für die Gruppen e, Q. Die Ergebnisse der SVM bezüglich der HER Methode sind gestreut von 1.25% für N bis 100% für e, Q. Diese Streuung ist so breit gefächert, da eine unterschiedliche Anzahl von Herzschlägen in den Gruppen vorliegt. Die HOS Methode erreichte eine totale relative Testfehlerrate von 11.26%. Diese ist im Vergleich zur HER Methode (11.82%) minimal besser ausgefallen. Gründe dafür könnten sein, dass die Implementierung der HER Methode durch Lösen des Verfahrens der kleinsten Quadrate eher fehlerbehaftet ist als die der HOS Methode.

Im Gegensatz dazu ist in der Veröffentlichung von Osowski et al. [37] die Testfehlerrate für beide Methoden deutlich geringer ausgefallen. Weiters zeigte die HER Methode hier bessere Resultate als die HOS Methode. Im Gegensatz zu der Publikation von Osowski et al. [37] werden in dieser Arbeit 15 Typen von Herzschlägen verwendet, um einen gleichzeitigen Vergleich und einen weitest möglichen Vergleich von dieser und der Veröffentlichung von Lagerholm et al. [27] zu erreichen. Die erstere untersuchte 13 Klassen, das sind alle bis auf e, P und Q und zusätzlich Gruppe S (supraventrikuläre Extrasystolen). Die zweite Publikation untersuchte dieselben Klassen wie diese Arbeit bearbeitet. Während in dieser Arbeit die Gruppe S gleich von Anfang an ausgeschlossen wird aufgrund der geringen Anzahl (nur 2), verzichten beide Publikationen nicht darauf. Lagerholm et al. [27] konnte aber auch keine Klassifikation dieser erreichen. Weiters standen Osowski et al. [37] zur Gruppe S 512 Beispiele zur Verfügung. Diese Samplegröße konnte leider nicht reproduziert werden. Weiters ist unklar, ob überhaupt von den gleichen Daten ausgegangen wird, da die MIT-BIH Arrhythmien Datenbank laut [29, 34] ständig weiter entwickelt und erweitert wurde.

In dieser Arbeit wurden die von Osowski et al. nicht behandelten Klassen e und Q zu 100% mit jeder Methode falsch klassifiziert. Einerseits verschlechtert dies die Gesamtergebnisse, andererseits haben diese Gruppen aufgrund ihrer geringen Anzahl wenig Einfluss auf die gesamte Testfehlerrate jeder Methode. Die Gruppe P, die auch nicht in [37] abgehandelt wird, ist des Weiteren gut klassifiziert, bei HOS mit 6%, bei HER mit 9% und bei der Kombination beider Methoden sogar mit 0% Fehlerrate. Diese Werte tragen zur Verbesserung der Klassifikation bei und gehen somit nicht in den Gesamtfehler ein.

Da die Testdaten besonders für die kleineren Datengruppen wie e und Q in dieser Arbeit nicht richtig klassifiziert wurden, wurde mit 90 zu 10 ein weiteres Verhältnis zwischen Trainings- und Testdaten gewählt. Dies brachte keine Veränderung für e und Q, aber eine minimale Besserung in der Klassifikation von anderen kleineren Datengruppen wie A und J mit geringer Anzahl von Daten. Der Versuch analog zu Osowski et al. in diesen Gruppen ein Verhältnis von 50 zu 50 zu wählen, erzielte keine Erfolge.

Einige tendenzielle Übereinstimmungen mit der Publikation von Osowski et al. [37] finden sich hingegen bei einzelnen Methoden und der besseren oder schlechteren Klassifikation von den einzelnen Typen. Zum Beispiel wurden mit der Methode HOS die Gruppen a und j mit einer Fehlerrate von 50% und 48.65% sehr schlecht klassifiziert (siehe Tabelle 5). Im Vergleich dazu wurden diese beiden bei Osowski et al. sogar am schlechtesten bewertet, wobei die Klassen e und Q aber ausgeschlossen sind. Außerdem geht aus der Tabelle 7 noch hervor, dass J als drittkleinste Klasse mit der Methode HER nach e und Q mit einem Wert von 71.43% am schlechtesten abschneidet, ebenso wie bei Osowski et al. [37]. Im Weiteren fallen die Fehlerraten für J und j, 28.57% und 29.73%, mit der Kombination der Methoden HOS und HER ebenfalls schlecht aus.

Es ist außerdem klar ersichtlich, dass große Gruppen wie N oder auch V, für die viele Datensätze aus der Datenbank zur Verfügung stehen, im Verhältnis um einiges besser klassifiziert werden, z.B. V mit 1.99% Fehlerrate bei kombinierter Auswertung, N mit 1.25% bei HER und V mit 2.99% bei HOS (siehe Tabellen 9, 7 und 5). Die Ursache dafür ist, dass durch eine hohe Anzahl an Daten die Support Vektor Maschine für ein breiteres Spektrum einer Gruppe besser trainiert ist. Eine ähnliche Tendenz zeigte sich auch bei Osowski et al. [37].

Obwohl die Trends in dieser Arbeit mit jenen bei Osowski et al. vergleichbar sind, weisen die relativen Fehlerraten trotz gleicher Methodik Unterschiede auf. Im Folgenden wird auf mögliche Ursachen eingegangen.

Zunächst ist unklar, wie Trainings- und Testdaten gewählt wurden. Es wird nur angegeben, dass versucht wurde, die minimale Balance für die Anzahl der Schläge unter allen Klassen hergestellt werden sollte, indem die Anzahl von einigen Klassen beschränkt wurde (vgl. [37], S. 586). Weiteres ist anzunehmen, dass die Outlier aus den einzelnen Gruppen, doch es wird nicht klar beschrieben welche. In dieser Arbeit wurden daher die Daten der 15 Klassen genommen, die zur Verfügung standen, ausgenommen non-beat annotated Beats aus der Arrhythmien Datenbank. Die Gesamtfehlerrate pro Methode hängt also sehr stark von der verschiedenen Anzahl und der Wahl der Daten in den Gruppen ab.

Außerdem wurde im Paper der Algorithmus der Lagrangian Support Vektor Maschine (LSVM) [28] als Trainingsalgorithmus, der das QP-Problem löst, verwendet. Der Test- Klassifikationsalgorithmus wurde jedoch nicht näher beschrieben. Diese Methoden wurden daher in dieser Arbeit durch von MATLAB® zur Verfügung gestellte Funktionen ersetzt und unmodelliert. Das Training der LSVM mit dem Testalgorithmus von MATLAB® zu kombinieren, wäre aufgrund der unterschiedlichen Struktur nicht zielführend gewesen.

Diese Kombination erzielt sogar eine Spitzen- Klassifikation in den Gruppen P und E mit jeweils 0.00% relativem Testfehler, d.h. einer 100% richtigen Klassifikation.

Die Hälfte der Precision und Recall Werte, ergaben mit 0.9 und 1.0 ein sehr gutes Ergebnis. Die Ausreißer e und Q spiegeln sich auch in diesen Werten mit 0 und undefiniertem Ergebnis für alle Methoden wieder. Nach diesen kommen J,

j und a mit Recall-Werten von 0.2857, 0.3243 und 0.3750 für die HER Methode. Die Best-Werte ergeben sich für die Gruppe E mit Precision-Werten 1 für alle Methoden und Recall-Wert 1 für die Kombination der Methoden HOS und HER. Auch diese Ergebnisse werden somit durch Kombination deutlich verbessert.

Abschließend geht aus der Tabelle 9 im Vergleich zu den anderen Tabellen eindeutig hervor, dass die Kombination der beiden Methoden HOS und HER für die Support Vektor Maschine die besten Ergebnisse erzielte, analog zu [37]. Das Resultat war 6.73% für die relative Gesamttestfehlerrate sowie die besten Ergebnisse bei Precision und Recall bei der Kombination beider Methoden. Dieser Erfolg ist insbesondere auf das einfach zu implementierende Modell des gewichteten Votings zurückzuführen.

7.2 SOM

Die SOM ist in der Klassifikation nur mit einer Erkennungsrate um 75% erfolgreich. Nur in höherbesetzten Klassen wie N, L, R, V und P wurden überhaupt verwertbare Ergebnisse erzielt, wie z.B. der Bestwert für die Klasse N mit einer Fehlerrate von 3.19%, erzielt. Im Gegensatz dazu zeigten die niedrigbesetzten Klassen eine Fehlerrate von 100%, es werden also alle Datensätze falsch klassifiziert. Alle Gruppen mit weniger als 2546 Datensätzen sind anscheinend zu klein oder zu inhomogen, um erkannt zu werden. Lagerholm et al. [27] konnte im Vergleich ebenfalls keine Klassifikation der Klasse e (und S, hier nicht miteinbezogen) und nur eine sehr schlechte der Gruppe Q erzielen. Es konnten jedoch 84557 von insgesamt 109813 gewählten Datensätzen von der SOM richtig klassifiziert werden. Den Großteil macht jedoch die Gruppe der normalen Herzschläge N aus, die ca. 70% der ganzen Datenmenge einnehmen.

Ein Vergleich von Abbildung 32 und Tabelle 12 zeigt, dass die meisten Cluster als N klassifiziert wurden und daher in die Gruppe N eingehen.

Es konnte zwar festgestellt werden, dass bei Verwendung weniger Klassen als Inputs in die SOM weitaus bessere Ergebnisse zustande kommen. Jedoch ist eine anschließende Kombination der Ergebnisse zur Erweiterung auf 15 Klassen, analog zur SVM, nicht direkt möglich und wurde daher nicht weiter verfolgt.

Der große Unterschied, der im Vergleich zu der Publikation von Lagerholm et al. [27] entstanden ist, ist möglicherweise darin begründet, dass verschiedene Implementierungen verwendet wurden. In dieser Arbeit wurde nicht die Toolbox von T. Kohonen [23] selbst verwendet, wie sie im Paper beschrieben wird, sondern die Neural Network Toolbox in MATLAB® [8], die sich nur auf die Toolbox von Kohonen stützt. Der Grund dafür ist die unzureichende Beschreibung der Verwendung der Toolbox in der Publikation von Lagerholm et al.. Daher mussten die Parameter angepasst und somit unterschiedlich zu der Publikation von Lagerholm et al. [27] gewählt werden. Sie beeinflussen die Genauigkeit, mit der Selbst Organisierte Karten arbeiten, und umfassen die Zahl der Referenzvektoren für jede Klasse, die Lernrate, den Lernalgorithmus, aber auch die Initialwerte und die Terminierung([38], S. 194).

Schmidt et al. ([38], S. 159) fasste dieses Problem wie folgt zusammen: „Es ist eine generelle Eigenschaft von Netzen, dass es Klassen von Inputs gibt, die prinzipiell vom Netz nicht gelernt bzw. erkannt werden können. Man sagt, das Netz kann gewisse Inputs nicht repräsentieren, folglich auch nicht lernen. Davon zu unterscheiden ist die Frage der Konvergenz: Auch bei einem Input, der von einem Netz repräsentiert wird, kann es sein, dass der Lernalgorithmus nicht konvergiert; es muss dann ein anderer Algorithmus gesucht werden“.

7.3 UNTERSCHIEDE SVM ZU SOM

Ein Vorteil der SVM ist die Robustheit gegenüber Ausreißern. Normalerweise sind neuronale Netzwerke sehr anfällig für Ausreißer. Um die Wirkung von solchen Extremen zu verhindern, müssen diese noch vor dem Training unterdrückt werden. Dies steuert der Margin Parameter C . Bei hohem Wert von C bleibt die Fehlklassifikation gering. D.h. durch passendes Setzen eines Wertes für C , können Outlier unterdrückt werden [1].

Ein Nachteil der SVM ist jedoch die lange Trainingszeit und der damit verbundene Speicherbedarf. Das Training einer SVM geschieht durch Lösen des zugehörigen dualen Problems. Die Anzahl der Variablen ist gleich der Anzahl der Trainingsdaten. Somit ist für eine große Anzahl an Trainingsdaten das duale Problem schwierig zu lösen [1].

Vorteile einer SOM sind die Verarbeitung von unscharfem und unvollständigem Wissen und daher das flexible Lernen anhand von Beispielen. Ebenso wie die SVM weist die SOM Robustheit auf, was Ausreißer betrifft. Sie schafft die Kompensation von Störungen [36].

Sehr zum Nachteil einer SOM kann der sogenannte *Border Effekt* sein. Das bedeutet, dass die Einheiten am Rand vermehrt als Best Match Unit - gleichbedeutend mit dem Gewinner Neuron, der minimalen Abstand zum Trainingsvektor hat - gewählt werden, was eine Konzentration der Eingangs-Datenpunkte in diesen Bereichen führt [36].

LIMITATIONEN

Das Ergebnis dieser Arbeit unterliegt mehreren Einschränkungen. Zuerst wurden die Klassifikatoren nur auf die Daten aus der MIT-BIH Arrhythmien Datenbank angewendet und in vorgegebene annotierte Klassen aufgeteilt. Das Ungleichgewicht zwischen pathologischen und nicht pathologischen Daten verursachte eine Tendenz in den Resultaten.

Des Weiteren wurde eine Klasse von Anfang an weggelassen aufgrund der geringen Anzahl der Datenpunkte. Die Klasse S mit 2 Datensätzen ist schwierig in Trainings- und Testdaten zu einem Verhältnis von 90 zu 10 aufzuteilen.

Außerdem hatten einige Klassen offenbar zu wenig Daten, um ein sinnvolles Training durchzuführen. Das führte zu einem größeren Gesamtfehler der einzelnen Methoden.

Zuletzt können nur sehr wenige der möglichen Implementierungen, Parameterkombinationen, Featurekombinationen und Skalierungsmöglichkeiten aufgrund des enormen Umfangs und langer Trainingszeiten getestet werden.

8

AUSBLICK UND FAZIT

Der Ausblick soll noch einige Ideen zur weiteren Umsetzung auf Basis der Entwicklungen und Ergebnisse dieser Arbeit aufzeigen.

Es wäre von großem Interesse, den Einfluss von Filterung der Daten in der Eingangsphase (vor der Merkmalsextraktion) auf die Resultate dieser Arbeit zu untersuchen, da diese Methode in den meisten referenzierten Publikationen angewendet wurde, wie [27] und [45] (außer [37]). Eine Filterung geschieht durch Verwendung eines Hochpass- und eines Tiefpass- Filters und bedeutet, dass die Signale von gewissem Rauschen, das bei jeder Aufnahme entsteht, oder unbedeutenden Abweichungen in der Aufnahme befreit werden und dadurch noch besser voneinander unterscheidbar gemacht werden. Somit könnten dadurch bessere Ergebnisse in der Klassifikation erzielt werden.

Ein weiterer Punkt besteht darin, dass die Annotationen der Daten aus der MIT-BIH Arrhythmien Datenbank manuell annotiert wurden. Daher befindet sich die R-Zacke nicht immer dort, wo sie vermutet wird. Was würde es für einen Unterschied machen, R-Zacken automatisch zu detektieren?

Ein weiterer Ansatz für Weiterentwicklungen ist die Verwendung von anderen oder mehreren Merkmalen. In der Literatur werden des Öfteren viel mehr Features verwendet, um die Daten noch besser zu repräsentieren [45]. Aufgrund der enormen Auswahl und Kombinationsmöglichkeiten bezog sich die Wahl in dieser Arbeit auf die Publikationen von [27] und [37]. Ebenso gibt es viele andere Skaliermöglichkeiten der Features. Es wäre interessant, ihren Einfluss auf die Resultate zu untersuchen [45].

Zuletzt könnte noch ein weiterer Ansatz sein, die SVM mit SOM in ein Gesamtklassifizierungskonzept zu kombinieren, um daraus noch bessere Resultate für eine Gesamtklassifikation zu gewinnen. Die Voraussetzung dafür ist allerdings eine Adaption der SOM, um ihre Resultate in ein gewichtetes Voting einbringen zu können.

FAZIT

Im Zuge dieser Arbeit wurden mehrere Algorithmen zur automatischen Klassifikation von Herzschlägen in EKG-Daten entwickelt und miteinander verglichen. Dabei wurde gezeigt, dass für reale EKG Messungen, welche naturgemäß Störungen, Artefakte und Outlier enthalten, eindeutig die SVM mit einer Kombination aus HOS und HER zur Featureextraktion die geeignetere Wahl ist.

9 | ANHANG

In diesem Abschnitt werden die in MATLAB[®] geschriebenen Funktionen der in Kapitel 4 und Kapitel 5 vorgestellten Methoden beschrieben.

9.1 HOS

Eingabewerte

n	int. Länge eines jeden QRS-Segments.
m	int. Anzahl der R-Zacken oder QRS-Segmente einer Person.
ECG_data	double[]. QRS-Segmente einer Ableitung einer Person.

Rückgabewerte

cum2ndorder_5points	double[]. 5 Werte eines QRS-Segments repräsentiert durch 5 Kumulanten der 2-ten Ordnung.
cum3rdorder_5points	double[]. 5 Werte eines QRS-Segments repräsentiert durch 5 Kumulanten der 3-ten Ordnung.
cum4thorder_5points	double[]. 5 Werte eines QRS-Segments repräsentiert durch 5 Kumulanten der 4-ten Ordnung.

Funktionsweise

Diese Funktion entspricht der HOS Beschreibung der EKG-Daten durch die Statistiken höherer Ordnung, genauer durch die Kumulanten der 2., 3. und 4. Ordnung, die wiederum durch ihre Momente ausgedrückt sind. Für jede Ordnung werden äquidistant über das Segment insgesamt 5 Punkte als Merkmale der Extraktion des QRS-Komplexes gewählt.

9.2 HER

Eingabewerte

m	int. Anzahl der R-Zacken oder QRS-Segmente einer Person.
ECG_data	double[]. QRS-Segmente einer Ableitung einer Person.
N	int. Maximale Ordnung der Hermiteschen Basisfunktionen.
sigma_all	int[]. Alle maximalen sigma für jede Ordnung N.
A_matrix	double[][], Hermiteschen Basisfunktionen für jede Ordnung N und für jedes sigma.

Rückgabewerte

B	double[]. Transformierte ECG_data durch Hinzufügen von Nullen links und rechts.
x	double[[]]. Entwicklung in Hermitesche Basisfunktionen mit Koeffizienten c für jedes sigma.
c_sp	double[[]]. Standardisierte Koeffizienten der Entwicklung in Hermitesche Basisfunktionen für jedes sigma.
sigma_max	int. Maximales sigma sodass der Fehler zwischen originalem Herzschlag und dessen Approximation minimal ist.
sigma_max_sp	int. Standardisiertes maximales sigma für minimalen Fehler.

Funktionsweise

Diese Funktion entspricht der HER Beschreibung der EKG-Daten durch die Hermiteschen Koeffizienten der Entwicklung in Hermitesche Basisfunktionen. Dabei kann die Ordnung N der Hermiteschen Basisfunktionen gewählt werden. Es werden transformierte QRS-Komplexe durch Hinzufügen von Nullen links und rechts benötigt. Zur Berechnung wird das maximale sigma (die maximale Weite) genommen, das den Fehler zwischen originalem Herzschlag und dessen Approximation minimiert.

9.3 SVM

Eingabewerte

Group	int. Anzahl der zu klassifizierenden Gruppen.
TrainingData	double[[]]. Trainingsdaten zweier Gruppen für eine Ableitung.
Testing_data	double[[]]. Testdaten zweier Gruppen.
Testing_label	int[]. Annotierte Testdaten.
lead	int. EKG-Ableitung.

Rückgabewerte

outputclassifier	int[]. Resultat der Klassifizierung als Vektor gefüllt mit 0 und einem 1.
targetvectors	int[]. Annotation als Vektor gefüllt mit 0 und einem 1.
C	double[]. Konfusionsmatrix des Klassifikators.
R	double. Erkennungsrate des Klassifikators.
E	double. Fehlerrate des Klassifikators.
Precision	double[]. Positiver Vorhersagewert pro Klasse.
Recall	double[]. Sensitivitätswerte für jede Klasse.
AverageRelative_TestingError	double[]. Relativer Testfehler für jede Klasse.

Funktionsweise

Die annotierten Trainingsdaten einer Ableitung zweier Gruppen werden dem binären Trainingsteil zugeführt. Anschließend werden die Testdaten dieser zwei Gruppen in einem Klassifikationsteil klassifiziert. Die Ergebnisse werden mit dem Testlabel verglichen und ausgewertet. Dieser Vorgang wird solange wiederholt bis jede Gruppe klassifiziert wurde. Anschließend wird die Leistung des Klassifikators gemessen anhand der Konfusionsmatrix, der Accuracy Rate oder Fehlerrate, den Precision- und Recall-Werten und den relativen Testfehlern.

9.4 SOM

Eingabewerte

Training_data_HER_SOM	double[[]]. Trainingsdaten.
dimension1	int. Höhe des Gitters.
dimension2	int. Breite des Gitters.
Training_label_SOM	int[[]]. Annotierten Testdaten.
it	int. Anzahl der Iterationen.

Rückgabewerte

outputclassifier	int[[]]. Resultat der Klassifizierung als Vektor gefüllt mit 0 und einem 1.
C	double[[]]. Konfusionsmatrix des Klassifikators.
R	double. Erkennungsrate des Klassifikators.
E	double. Fehlerrate des Klassifikators.
Precision	double[[]]. Positiver Vorhersagewert pro Klasse.
Recall	double[[]]. Sensitivitätswerte pro Klasse.

Funktionsweise

Alle für die SOM vorbereiteten Daten werden zusammen mit der Größe des gewählten Gitters in die Trainingseinheit übergeführt. Nach Durchlauf mehrerer Iterationen ist die SOM trainiert. Dann werden die Ergebnisse anhand der Labels dieser Daten verifiziert. Anschließend wird die Leistung des Klassifikators gemessen anhand der Konfusionsmatrix, der Accuracy Rate oder Fehlerrate, den Precision- und Recall-Werten und den relativen Testfehlern.

ABKÜRZUNGSVERZEICHNIS

N	Normaler Herzschlag, normal beat
L	Linksschenkelblock, left bundle branch block beat
R	Rechtsschenkelblock, right bundle branch block beat
A	Atrial premature beat
a	Aberrated atrial premature beat
J	Nodal (junctional) premature beat
V	Ventricular premature beat
F	Fusion of ventricular and normal beat
I	Kammerflattern, ventricular flutter wave
e	Atrial escape beat
j	Nodal (junctional) escape beat
E	Ventricular escape beat
P	Paced beat
f	Fusion of paced and normal beat
Q	Unklassifizierbarer Herzschlag, unclassifiable beat
SVM	Support Vektor Maschine
SOM	Selbst Organisierte Karte
HOS	Higher Order Statistics, Statistiken höherer Ordnung
HER	Hermiteische Basisfunktionen

ABBILDUNGSVERZEICHNIS

Abbildung 1	Herz-Kreislauf-Erkrankungen als Todesursache Nummer 1 [4]	1
Abbildung 2	Das Herz als Pumpe bildet mit Lungen- und Körperkreislauf ein geschlossenes System [19].	3
Abbildung 3	Phasen des Herzzyklus für das linke Herz; Zusammenhang zwischen EKG und Herzzyklus; Druckverläufe; Verhalten der Klappen [43].	5
Abbildung 4	Das Erregungsleitsystem im Herzen durch 1 den Sinusknoten, 2 den Atrioventrikularknoten (AV-Knoten), 3 die Atrioventrikulärbündel und 4 die Purkinje-Fasern [15].	6
Abbildung 5	Brustwandableitungen nach Wilson. Elektroden sind verbunden mit Elektrokardiograph [20].	7
Abbildung 6	Zur Analyse eines Oberflächen-EKG eine schematische Darstellung der EKG-Zacken in Relation zu den elektrischen Vorgängen im Herzen anhand eines normalen Herzschlags [2].	8
Abbildung 7	Häufigkeiten der einzelnen Gruppen im Datensatz. Man merkt, dass bestimmte Gruppen stark unterbesetzt sind (logarithmische Skala) und andere stark überwiegen. Für die Bedeutung der Buchstaben wird auf die Tabelle 1 verwiesen.	12
Abbildung 8	Normaler Herzschlag als Ausschnitt vom Record 115 aus der MIT-BIH Arrhythmien Datenbank mit dem zeitlichen Intervall von 2 s für jede der Ableitungen MLII und V1.	13
Abbildung 9	Linksschenkelblock (a) und Rechtsschenkelblock (b) als Ausschnitte von den Records 111 und 212 aus der MIT-BIH Arrhythmien Datenbank mit dem zeitlichen Intervall von jeweils 2 s für jede der Ableitungen MLII und V1.	14
Abbildung 10	Atrial premature beat als Ausschnitt vom Record 232 aus der MIT-BIH Arrhythmien Datenbank mit dem zeitlichen Intervall von 3.3 s für jede der Ableitungen MLII und V1.	15
Abbildung 11	Aberrated atrial premature beat als Ausschnitt vom Record 201 aus der MIT-BIH Arrhythmien Datenbank mit dem zeitlichen Intervall von 2 s für jede der Ableitungen MLII und V1.	16
Abbildung 12	Nodal (junctional) premature beat als Ausschnitt vom Record 234 aus der MIT-BIH Arrhythmien Datenbank mit dem zeitlichen Intervall von 2 s für jede der Ableitungen MLII und V1.	17
Abbildung 13	Ventricular premature beat als Ausschnitt vom Record 200 aus der MIT-BIH Arrhythmien Datenbank mit dem zeitlichen Intervall von 2 s für jede der Ableitungen MLII und V1.	18

Abbildung 14	Kammerflattern, Kammerflimmern als Ausschnitt vom Record 207 aus der MIT-BIH Arrhythmien Datenbank mit dem zeitlichen Intervall von 2 s für jede der Ableitungen MLII und V1.	19
Abbildung 15	Paced beat als Ausschnitt vom Record 107 aus [29] mit dem zeitlichen Intervall von 2 s für die zwei Ableitungen MLII und V1.	20
Abbildung 16	Fusion of ventricular and normal beat als Ausschnitt vom Record 208 aus der MIT-BIH Arrhythmien Datenbank mit dem zeitlichen Intervall von 2 s für die zwei Ableitungen MLII und V1.	21
Abbildung 17	Fusion of paced and normal beat als Ausschnitt vom Record 217 aus der MIT-BIH Arrhythmien Datenbank mit dem zeitlichen Intervall von 2.8 s für die zwei Ableitungen MLII und V1.	21
Abbildung 18	Unklassifizierbarer Herzschlag als Ausschnitt vom Record 104 aus der MIT-BIH Arrhythmien Datenbank mit dem zeitlichen Intervall von 2 s für die zwei Ableitungen V2 und V5.	22
Abbildung 19	Normaler Herzschlag und dessen entsprechende Repräsentationen durch Kumulanten der 2., 3. und 4. Ordnung	26
Abbildung 20	Hermiteische Basisfunktionen der ersten 6 Ordnungen für $\sigma = 30$	28
Abbildung 21	Normaler Herzschlag und dessen Hermiteische Repräsentationen der 3., 9. und 14. Ordnung	30
Abbildung 22	RR-Intervall zwischen zwei aufeinander folgenden Herzschlägen entspricht dem zeitlichen Abstand zweier R-Zacken. Variation dieser Intervalls entspricht der Herzratenvariabilität (HRV) [3].	31
Abbildung 23	Verlauf eines überwachten Lernverfahrens und der Klassifikation in zwei Phasen. In der Trainingsphase wird mithilfe annotierter Trainingsdaten das Klassifikationsmodell aufgestellt. In der Testphase werden Testobjekte klassifiziert [6].	36
Abbildung 24	Verlauf eines unüberwachten Lernverfahrens und der Clusterbildung in einer gemeinsamen Phase. In der Trainingsphase wird durch Ähnlichkeitsvergleiche der Trainingsdaten das Clustering Modell aufgestellt. Die Testphase dient nur zur Evaluierung der Ergebnisse, sie sind jedoch schon vorhin klassifiziert.	36
Abbildung 25	Support Vektor Maschine für linear separierbare Daten in einem 2-dimensionalen Raum. Optimale separierende Hyperebene mit maximalem Margin zu den nächsten Datenpunkten jeder Klasse [1], S. 23.	37
Abbildung 26	Support Vector Maschine für nicht linear separierbare Daten in einem 2-dimensionalen Raum. Optimal trennende Hyperebene mit noch richtig klassifiziertem ξ_i , schon falsch klassifiziertem ξ_j [1].	39

Abbildung 27	Support Vektor Maschine muss die Eingangsdaten in einen höher-dimensionalen Raum transformieren um die Daten linear trennen zu können. Der Eingangsraum wird über die Abbildung ϕ in einen neuen Merkmalsraum umgewandelt [24], siehe Abbildung 27	40
Abbildung 28	Schema einer Gesamtklassifikation	44
Abbildung 29	Schema eines zweischichtigen Neuronalen Netzes mit 2-dimensionalem Gitter der Größe $X \times Y$ bestehend aus zusammenhängenden Knoten und den Gewichtsverbindungen w zu den einzelnen Merkmalen des Eingangsvektors $\mathbf{y}^i$ [7].	47
Abbildung 30	Die SOM Abbildung von einem höher dimensionalen Raum zu einem diskreten 2-D-Raum [27].	48
Abbildung 31	Zur Veranschaulichung eines Outputs im 2-dimensionalen Raum der implementierten Support Vektor Maschine unter der Methode HOS sind von dem für die HOS-Methode vorbereiteten Merkmalstupel $\{y(1, \dots, 15)y(61)y(62)\}$ die folgenden Elemente $\{y(15)y(61)\}$ gewählt (siehe 4.5). Die Positionen der roten und grünen Kreuze stehen für die Trainingsdaten von Klasse 1 und Klasse 2. Die rosa und blauen 2-dimensionalen Merkmalsvektoren sind die klassifizierten Testdaten, rosa für Klasse 1 und blau für Klasse 2. Die eingekreisten Datenpunkte stellen die Support Vektoren der Hyperebene dar, sie befinden sich entlang der Hyperebene. Die Hyperebene selbst ist als schwarze Linie dargestellt.	53
Abbildung 32	Dieser Plot zeigt, wie viele der Trainingsdaten in jedes Cluster klassifiziert und somit als ähnlich erachtet werden. Ein leeres Cluster würde eine Trennung zwischen benachbarten Clustern bedeuten, d.h. es gibt keine ähnlichen Herzschläge zwischen ihnen.	58
Abbildung 33	Die Abstände zwischen den benachbarten Neuronen sind repräsentiert durch dunkle und helle Farben. Dunkle Regionen zwischen Clustern geben an, dass diese weit auseinander liegen. Das bedeutet wenig oder keine Ähnlichkeit der Herzschläge zwischen diesen Clustern. Helle Farben sind zwischen den Neuronen, deren Cluster ähnlich sind. Ein großer heller Bereich zeigt eine glatte Verteilung der Merkmale der Herzschläge.	59
Abbildung 34	Man sieht die Gewichtung jedes einzelnen Merkmals des Merkmalstupels auf die einzelnen Cluster aufgeteilt. Ähnlich gefärbte Cluster zwischen den Gewichten zweier Inputs indizieren abhängige Merkmale und unähnliche Cluster unabhängige Merkmale.	60

TABELLENVERZEICHNIS

Tabelle 1	Auflistung der verschiedenen Typen von Herzschlägen oder Herzrhythmen in der MIT-BIH Datenbank [29, 34].	12
Tabelle 2	Ausgesuchte Merkmale y der Herzschläge x , die später als Inputs in der Klassifikation verwendet werden.	32
Tabelle 3	Supervised vs. Unsupervised learning in Form von Support Vektor Maschine vs. Selbst Organisierte Karte. . . .	36
Tabelle 4	Konfusionsmatrix A mit $K = 2$ Klassen, z.B. für ein Diagnoseproblem. TP (true positive), FP (false positive) korrekt und falsch klassifizierte positive Daten; TN (true negative), FN (false negative) korrekt und falsch klassifizierte negative Daten.	51
Tabelle 5	Die Ergebnisse der Mustererkennung von verschiedenen Typen von Herzschlägen durch die SVM mit HOS als Merkmale. Genauer, die relativen und absoluten Testfehler der Klassifikation anhand von Testdaten jedes Typen.	54
Tabelle 6	Konfusionsmatrix der SVM mit HOS als Merkmale. Die Daten gehören zu den Klassen in der vertikalen Achse, während sie in die Klassen auf der horizontalen Achse klassifiziert werden. Die Anzahl der richtig klassifizierten Herzsignale befindet sich in den Diagonaleinträgen. . . .	54
Tabelle 7	Die Ergebnisse der Mustererkennung von verschiedenen Typen von Herzschlägen durch die SVM mit HER als Merkmale. Es sind die Anzahl der gewählten Testdaten sowie deren Testfehler durch die Klassifikation für jeden Herzschlag Typ aufgelistet.	55
Tabelle 8	Konfusionsmatrix der SVM mit HER als Merkmale. Die vertikale Achse entspricht den Herzschlägen die zu den jeweiligen Klassen gehören, wohingegen die horizontale Achse sich als Ergebnis deren Klassifikation liest. Die Anzahl der richtig klassifizierten Daten befinden sich in den Diagonaleinträgen.	55
Tabelle 9	Die Ergebnisse der Mustererkennung von verschiedenen Typen von Herzschlägen durch die Kombination der HOS und HER Merkmale in zwei SVMs. Die gewählten Testdaten sowie deren Fehlklassifikation für jeden Herzschlag Typ sind aufgelistet.	56
Tabelle 10	Die Konfusionsmatrix der Gesamtklassifikation der Merkmale HOS und HER. Genauer: Das Resultat der Kombination der Ergebnisse der HOS und HER Methoden in der SVM durch gewichtetes Voting Prinzip.	56
Tabelle 11	Vergleich der positiven Vorhersage Werte (Precision) sowie der Sensitivität (Recall) der Merkmale HOS und HER und deren Kombination zu einem Gesamtklassifizierungskonzept für jeden Typ von Herzschlag.	57

Tabelle 12	Die annotierten Herzschläge sind auf der vertikalen Achse dargestellt, während die durch die verschiedenen Typen dominierten Cluster horizontal angezeigt sind. Beispielsweise werden 1526 der Gruppe N zu Clustern zugewiesen, in denen V dominiert.	59
Tabelle 13	Vergleich der positiven Vorhersage Werte (Precision) sowie der Sensitivität (Recall) der SOM für jeden Typ von Herzschlag.	60

LITERATURVERZEICHNIS

- [1] Shigeo Abe. *Support vector machines for pattern classification*, volume 2. Springer, 2005.
- [2] Anthony Atkielski. File:sinusrhythmlabels. <https://en.wikipedia.org/wiki/File:SinusRhythmLabels.svg>, 2007. [Online; Zugriffen am 16. März 2016].
- [3] Anthony Atkielski. File:ecg-rrinterval. <http://commons.wikimedia.org/wiki/File:ECG-RRinterval.svg>, 2009. [Online; Zugriffen am 03. Mai 2016].
- [4] Statistik Austria. Todesursachen. http://www.statistik.at/web_de/statistiken/menschen_und_gesellschaft/gesundheit/todesursachen/todesursachen_ausgewaehlte/index.html. [Online; Zugriffen am 12. Juni 2015].
- [5] Martin Bachler, Christopher Mayer, Bernhard Hametner, Siegfried Wassertheurer, and Andreas Holzinger. *Pervasive Computing and the Networked World: Joint International Conference, ICPCA/SWS 2012, Istanbul, Turkey, November 28-30, 2012, Revised Selected Papers*, chapter Online and Offline Determination of QT and PR Interval and QRS Duration in Electrocardiography, pages 1–15. Springer Berlin Heidelberg, Berlin, Heidelberg, 2013.
- [6] Martin Behnisch. *Urban data mining*, chapter Aufbau eines kanonischen Klassifikators zur nachträglichen Klassenidentifikation, page 237. Universitätsverlag, Karlsruhe, 2009. Graphik.
- [7] Sachin Joglekar’s blog. Self organizing map. <https://codesachin.files.wordpress.com/2015/11/kohonen1.gif>, November 2015. [Online; Zugriffen am 02. Mai 2016].
- [8] Howard Demuth and Mark Beale. *Neural network toolbox for use with matlab®*. 1993.
- [9] Bundesministerium für Gesundheit. Vorsorgeuntersuchung. http://www.gesundheit.gv.at/Portal.Node/ghp/public/content/Die_Vorsorgeuntersuchung_LN.html. [Online; Zugriffen am 05. Februar 2016].
- [10] Guido Gerig. Least squares, pseudo-inverses, pca & svd. <http://www.sci.utah.edu/~gerig/CS6640-F2012/Materials/pseudoinverse-cis61009sl10.pdf>. [Online; Zugriffen am 18. November 2015].
- [11] M. Gertsch. *Das EKG: Auf einen Blick und im Detail*, 2. Auflage, chapter Ventrikuläre Extrasystolen, page 456. Springer-Verlag, 2008.
- [12] M. Gertsch. *The ECG Manual: An Evidence-Based Approach*, chapter Atrial Premature Beats, pages 197–200. Springer London, London, 2009.

- [13] Glass L Hausdorff JM Ivanov PCh Mark RG Mietus JE Moody GB Peng C-K Stanley HE Goldberger AL, Amaral LAN. Physiobank, physiotoolkit, and physionet: Components of a new research resource for complex physiologic signals. *Circulation*, (101(23)):e215–e220, 2000 (June 13). [Circulation Electronic Pages; <http://circ.ahajournals.org/cgi/content/full/101/23/e215>].
- [14] A.C. Guyton & J.E. Hall. *Textbook of Medical Physiology, Tenth Edition*. W. B. Saunders Company, 2000.
- [15] J. Heuser. File:reizleitungssystem 1. https://commons.wikimedia.org/wiki/File:Reizleitungssystem_1.png, 2007. [Online; Zugriffen am 09. Mai 2016].
- [16] Tran Hoai Linh, Stanislaw Osowski, and Maciej Stodolski. On-line heart beat recognition using hermite polynomials and neuro-fuzzy network. In *Instrumentation and Measurement Technology Conference, 2002. IMTC/2002. Proceedings of the 19th IEEE*, volume 1, pages 165–170. IEEE, 2002.
- [17] Chih-Wei Hsu and Chih-Jen Lin. A comparison of methods for multiclass support vector machines. *Neural Networks, IEEE Transactions on*, 13(2):415–425, 2002.
- [18] Yu Hen Hu, Surekha Palreddy, and Willis J Tompkins. A patient-adaptable ecg beat classifier using a mixture of experts approach. *Biomedical Engineering, IEEE Transactions on*, 44(9):891–900, 1997.
- [19] Jakov. Diagram of the human heart (cropped) de. https://commons.wikimedia.org/wiki/File:Diagram_of_the_human_heart_%28cropped%29_de.svg, 2016. [Online; Zugriffen am 19. April 2016].
- [20] Jmarchn. File:precordial leads 2. https://commons.wikimedia.org/wiki/File:Precordial_Leads_2.svg, 2010. [Online; Zugriffen am 09. Mai 2016].
- [21] R. Klinke and S. Silbernagl. *Lehrbuch der Physiologie. 3. vollständig überarbeitete Auflage*. Georg Thieme Verlag, 2001.
- [22] Bert-Uwe Köhler. *Konzepte der statistischen Signalverarbeitung*. Springer-Verlag, 2005.
- [23] Teuvo Kohonen. Self-organizing maps, vol. 30 of springer series in information sciences, 2001.
- [24] Seong-Whan Lee and Alessandro Verri. *Pattern Recognition with Support Vector Machines: First International Workshop, SVM 2002, Niagara Falls, Canada, August 10, 2002. Proceedings*, volume 2388. Springer, 2003.
- [25] Jörg Liesen and Volker Mehrmann. *Lineare Algebra: Ein Lehrbuch über die Theorie mit Blick auf die Praxis*, chapter Die Singulärwertzerlegung, pages 313–321. Springer Fachmedien Wiesbaden, Wiesbaden, 2015.
- [26] H. Lippert. *Lehrbuch Anatomie. 5. Auflage*. Urban & Fischer Verlag, 2000.
- [27] G. Braccini L. Edenbrandt M. Lagerholm, C. Peterson and L. Sörnmo. Clustering ecg complexes using hermite functions and self-organizing maps. *IEEE Transactions on Biomedical Engineering*, 47(7):838–848, Jul 2000.

- [28] Olvi L Mangasarian and David R Musicant. Lagrangian support vector machines. *The Journal of Machine Learning Research*, 1:161–177, 2001.
- [29] R. Mark and G. Moody. *MIT-BIH Arrhythmia Database*, 1997.
- [30] Kurt Meyberg and Peter Vachenauer. *Höhere Mathematik 1: Differential- und Integralrechnung Vektor- und Matrizenrechnung*. Springer-Verlag, 2013.
- [31] Mark RG Moody GB. The impact of the mit-bih arrhythmia database. *IEEE Eng in Med and Biol*, (20(3)):45–50, (May-June 2001). (PMID: 11446209).
- [32] C. L. Nikias and J. M. Mendel. Signal processing with higher-order spectra. *IEEE Signal processing magazine*, 10(3):10–37, 1993.
- [33] D. Tax P. Juszczak and R.P.W. Duin. Feature scaling in support vector data description. In *Proc. ASCI*, pages 95–102. Citeseer, 2002.
- [34] PhysioNet. Physiobank. <http://physionet.org/physiobank/database/mitdb/>.
- [35] John C Platt. 12 fast training of support vector machines using sequential minimal optimization. *Advances in kernel methods*, pages 185–208, 1999.
- [36] Gerd Platzgummer. Evaluierung von qualitätsmaßen für selbstorganisierte karten. Master's thesis, Technische Universität Wien, 2008.
- [37] L.T. Hoai S. Osowski and T. Markiewicz. Support vector machine-based expert system for reliable heartbeat recognition. *Biomedical Engineering, IEEE Transactions on*, 51(4):582–589, 2004.
- [38] Jörn Schmidt, Christina Klüver, and Jürgen Klüver. Neuronale netze. In *Programmierung naturanaloger Verfahren*, pages 139–225. Springer, 2010.
- [39] Ananthram Swami, Jerry M Mendel, and Chrysostomos L Nikias. *Higher-Order Spectral Analysis Toolbox: For Use with MatLab®*. MathWorks Incorporated, 1998.
- [40] H.-P. Schuster und H.-J. Trappe. *EKG-Kurs für Isabel*. Georg Thieme Verlag, 4. auflage edition, 2005.
- [41] K. Voss und H. Süße. *Praktische Bildverarbeitung. Hanser Studienbücher der Informatik*. Carl Hanser Verlag, München, Wien, 1991.
- [42] C. Hamm und S. Willems. *Checkliste EKG*. Georg Thieme Verlag, 4. auflage edition, 2014. Checklisten der aktuellen Medizin. Begründet von F. Largiadèr, A. Sturm, O. Wicki.
- [43] Thieme via medici. Herzzyklus: Phasen der herzaktion. <https://viamedici.thieme.de/lernmodule/physiologie/herzzyklus+phasen+der+herzaktion>, 2015. [Online; Zugriffen am 21. April 2016].
- [44] Wellach. *Praxisbuch EEG - Einführung in die Befundung, Beurteilung und Differenzialdiagnose*. Georg Thieme Verlag KG, 2011.
- [45] Jenna Marleau Wiens. Machine learning for patient-adaptive ectopic beat classification. Master's thesis, Massachusetts Institute of Technology, June 2010.