

Fachhochschule Aachen
Campus Jülich

Fachbereich 9
Medizintechnik und Technomathematik

Klassifikation von Herzfehlern in Mehrkanal-EKGs mit KI: Erste Erkenntnisse mit Big Data

Seminararbeit
im Studiengang Angewandte Mathematik und Informatik

von

Mohammad Soufian Noor

Matr.-Nr.: 3277449

26. Dezember 2022

1. Prüfer: Prof. Dr. Melanie Hollstein
2. Prüfer: Onno Linschmann, M.Sc.

Eidesstattliche Erklärung

Hiermit versichere ich, dass ich die Seminararbeit mit dem Thema „Klassifikation von Herzfehlern in Mehrkanal-EKGs mit KI: Erste Erkenntnisse mit Big Data“ selbstständig verfasst und keine anderen als die angegebenen Quellen und Hilfsmittel benutzt habe, alle Ausführungen, die anderen Schriften wörtlich oder sinngemäß entnommen wurden, kenntlich gemacht sind und die Arbeit in gleicher oder ähnlicher Fassung noch nicht Bestandteil einer Studien- oder Prüfungsleistung war.

Ich verpflichte mich, ein Exemplar der Seminararbeit fünf Jahre aufzubewahren und auf Verlangen dem Prüfungsamt des Fachbereiches Medizintechnik und Technomathematik auszuhändigen

Ort, Datum

Mohammad Soufian Noor

Abstract

Herz-Kreislaufkrankungen zählen weltweit zu den führenden Todesursachen. Wie auch bei anderen Krankheiten, ist eine frühzeitige Erkennung essenziell für die Behandlung der Patienten.

Zu diesem Zweck kann das Elektrokardiogramm (EKG) eine wichtige Rolle spielen.

Was ein Elektrokardiogramm ist und welche Aussagekraft es bezüglich der Erkennung von Herzfehlern hat, wird in dieser Arbeit grundlegend dargestellt.

Darüber hinaus liegt der Fokus dieser Arbeit auf der Nutzung künstlicher Intelligenz (KI), um Diagnosen aus einem EKG auszuwerten.

Dafür werden die PhysioNet/Computing in Cardiology Challenges aus dem Jahr 2020 und 2021 vorgestellt. Diese befassen sich mit der Klassifikation von Herzfehlern in Mehrkanal-EKGs mit KI.

Schließlich werden die Ergebnisse der Challenges verglichen und die daraus resultierenden Erkenntnisse zusammengetragen.

Inhaltsverzeichnis

Abkürzungsverzeichnis	ix
Abbildungsverzeichnis	xi
Tabellenverzeichnis	xiii
1 Einleitung	1
1.1 Motivation und Ziel der Arbeit	1
1.2 Gliederung	1
2 Grundlagen	3
2.1 Medizinische Grundlagen	3
2.1.1 Erregungsausbreitung am Herzen	3
2.1.2 Elektrokardiographie	4
2.2 Technische Grundlagen	8
2.2.1 Big Data	9
2.2.2 Künstliche Intelligenz	9
2.2.3 Künstliche Neuronale Netze	10
3 PhysioNet/CinC Challenge 2020/21	13
3.1 Aufgabe	13
3.1.1 2020	14
3.1.2 2021	15
3.1.3 Bewertung	16
3.2 Datensätze	18
3.2.1 Datenquellen	19
3.2.2 Datenanalyse	21
3.3 Partizipationen	22
3.3.1 Datenaufbereitung	23
3.3.2 Methoden	26
3.4 Ergebnisse	27
4 Schlusswort	29
4.1 Diskussion	29

Inhaltsverzeichnis

4.2 Fazit	29
Anhang	30
A CinC Challenge	31
Literatur	33

Abkürzungsverzeichnis

Abkürzungen

CinC Computing in Cardiology

KI Künstliche Intelligenz

SNOMED CT Systematisierte Nomenklatur der Medizin

KNN Künstlich Neuronale Netze

DL Deep Learning

ML Machine Learning

EKG Elektrokardiogramm

Abbildungsverzeichnis

2.1	Aufbau des Herzens	4
2.2	Die drei Einthoven Ableitungen (I, II, III) und die drei Ableitungen nach Goldberger (aVR, aVL, aVF)	5
2.3	Brustwandableitungen nach Wilson (V1-V6)	6
2.4	Sinusrhythmus	7
2.5	Architektur eines künstlichen neuronalen Netzes	10
2.6	Darstellung eines künstlichen Neurons	11
3.1	Beispiel einer Konfusionsmatrix	17
3.2	Visuelle Darstellung des TDSP-Lebenszyklus	22
A.1	Die Rewardmatrix aus dem Jahr 2020	31
A.2	Die Rewardmatrix aus dem Jahr 2021	32

Tabellenverzeichnis

3.1	Für die Bewertung zählende Diagnosen aus dem Jahr 2020	14
3.2	Für die Bewertung zählende Diagnosen aus dem Jahr 2021	15
3.3	Verwendete Ableitungssysteme für das verborgene Validierung- und Testset	16
3.4	Quelle, Standort und Referenz für jede Datenbank, die für die Challenges genutzt wurde	19
3.5	Die verwendeten Datenbanken mit ihrer Anzahl der Patienten und ihrer Aufteilung in Trainings-, Validierungs- und Testset, für das Jahr 2020 . .	20
3.6	Die verwendeten Datenbanken mit ihrer Anzahl der Patienten und ihrer Aufteilung in Trainings-, Validierungs- und Testset, für das Jahr 2021 . .	20
3.7	Ausgewählte Eigenschaften der Datensätze aus dem Jahr 2020	21
3.8	Ausgewählte Eigenschaften der Datensätze aus dem Jahr 2020	21
3.9	Übersicht der verwendeten Methoden zur Datenaufbereitung.	25

1 Einleitung

1.1 Motivation und Ziel der Arbeit

Weltweit ist die führende Todesursache Herz-Kreislauf-erkrankungen (HKE). Zur Veranschaulichung: im Jahre 2019 sind schätzungsweise 17,9 Millionen Menschen an HKE verstorben, das sind ca. 32% aller globalen Todesfälle (vgl. [WHO21]). So war es auch in 2021 die häufigste Todesursache in Deutschland (vgl. [Des22]).

Wie auch bei allen Krankheiten spielt die frühzeitige Erkennung eine wichtige Rolle in der Behandlung.

Dafür ist das Elektrokardiogramm (EKG) eines der wichtigsten Werkzeuge für die Ärzte. „Das EKG ist rasch registriert, billig und nichtinvasiv, und es liefert wichtige und unentbehrliche Informationen“ ([Ger08, S. 2]). Denn mit Hilfe des EKGs lassen sich verschiedenste HKE feststellen. Jedoch ist die richtige Auswertung des EKGs auf keinen Fall trivial und erfordert Training und Erfahrung. (vgl. [Ger08; Bay+21; Kli+07])

Daher ist es nicht verwunderlich, dass mit der Weiterentwicklung der Technologien im Bereich der „Künstlichen Intelligenz“, diese auch für das EKG eine bedeutende Rolle spielen könnten. KI, die in der Lage ist EKG-Signale auszuwerten und auf mögliche Krankheiten zu untersuchen, wären damit eine Unterstützung für Ärzte oder könnten diese sogar ersetzen. (vgl. [HSI22a])

Welche Möglichkeiten sich in der EKG-Diagnostik mit der KI ergeben, sind Inhalt dieser Seminararbeit. Zu diesem Zweck werden die PhysioNet/CinC Challenges aus den Jahren 2020 und 2021 betrachtet, die sich genau mit diesem Thema beschäftigen.

1.2 Gliederung

Zunächst werden in Kapitel 2 die medizinischen und technischen Grundlagen erläutert, die zum Verständnis des Themas und dieser Arbeit beitragen.

Anschließend werden in Kapitel 3 die PhysioNet/CinC Challenges beschrieben und Erkenntnisse dieser zusammengetragen.

Letztlich werden in Kapitel 4 die Ergebnisse diskutiert und ein Fazit gezogen.

2 Grundlagen

In den folgenden Abschnitten werden die medizinische Grundlagen erläutert, die für ein Grundverständnis für das Elektrokardiogramm (EKG) benötigt werden. Des Weiteren wird auf die nötigen technischen Grundlagen zur Künstlichen Intelligenz eingegangen.

2.1 Medizinische Grundlagen

In diesem Kapitel geht es darum, grundlegend zu verstehen, was ein EKG ist. Dabei sind die physikalischen Grundlagen, die zur Entstehung des Bildes beitragen, für diese Arbeit unbedeutend. Dies lässt sich damit begründen, dass es nicht um die Entstehung der Bilder geht, sondern um die Auswertung. Eine detaillierte Erklärungen zur „Entstehung des EKG“ finden Sie bei Klinke et al. [Kli+10, S. 161ff.]

2.1.1 Erregungsausbreitung am Herzen

„Die Erregung des Herzens breitet sich, ausgehend vom Sinusknoten (primärer Schrittmacher), über Vorhof, AV-Knoten, His-Bündel, Kammerschenkel und Purkinje-Fasern“ [Kli+10, S. 161].

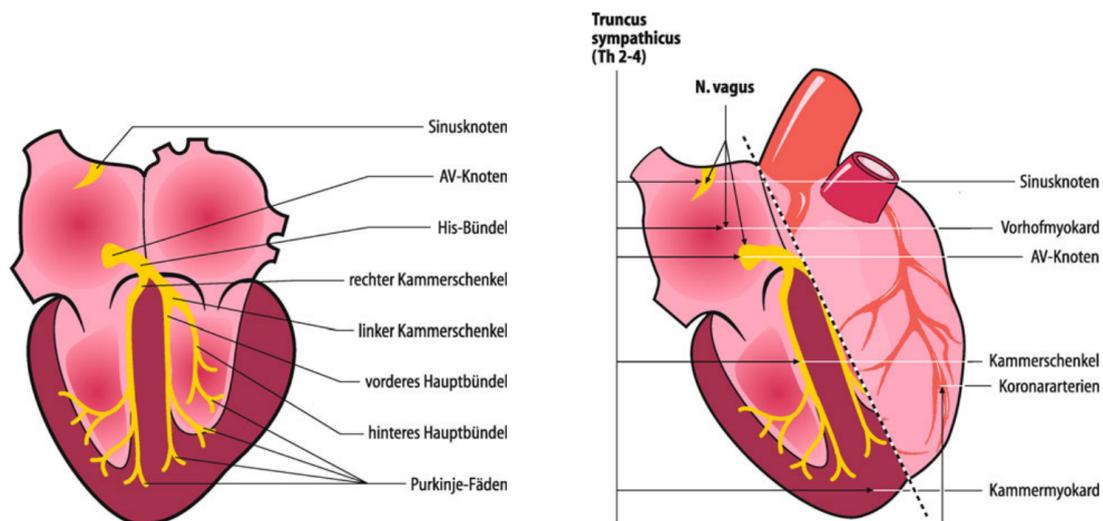


Abbildung 2.1: Aufbau des Herzens.
[SLH11, Abb. 25.5, Abb. 25.6]

Davon ausgehend wird der Hohlraum des Herzens (Ventrikel) erregt, indem die Erregung von einer Herzmuskelzelle (Myokardzelle) auf die nächste übertragen wird. Die Dauer der Erregungsausbreitung im Ventrikel beläuft sich auf 140ms. Dagegen hat das gesamte Aktionspotential eine Dauer von 300ms. Dadurch kann sich der Herzmuskel nicht wieder selbst erregen. Da es zu dem Zeitpunkt, an dem es wieder möglich wäre ein Aktionspotential auszulösen, kein Reiz über erregte Zellen mehr möglich ist. vgl. [Kli+10]

2.1.2 Elektrokardiographie

„Die Elektrokardiographie ist ein Verfahren zur Registrierung der elektrischen Aktivitäten des Herzens. Das dabei erzeugte Kurvenbild nennt man Elektrokardiogramm (EKG)“ [Red20]. „Bei der Registrierung eines EKG werden Veränderungen der Potentialdifferenz zwischen zwei Punkten auf der Körperoberfläche gegen die Zeit aufgezeichnet“ [Kli+10, S. 161]. Eine Potentialdifferenz entsteht zwischen erregtem und unerregtem Muskelgewebe. Zudem breitet sich dessen elektrisches Feld im Körper aus. Dadurch sind die bei der Erregung des Herzmuskels auftretenden Potentialschwankungen auf der Körperoberfläche in Form des EKGs nachweisbar (vgl. [Kli+10, S. 169]). Eine Messung dieser Schwankungen wird auch Ableitung genannt, wobei diese nach der Messmethodik unterscheiden kann (vgl. [Ant+22]). Es folgen die Standardableitungen und Weiteres zum EKG.

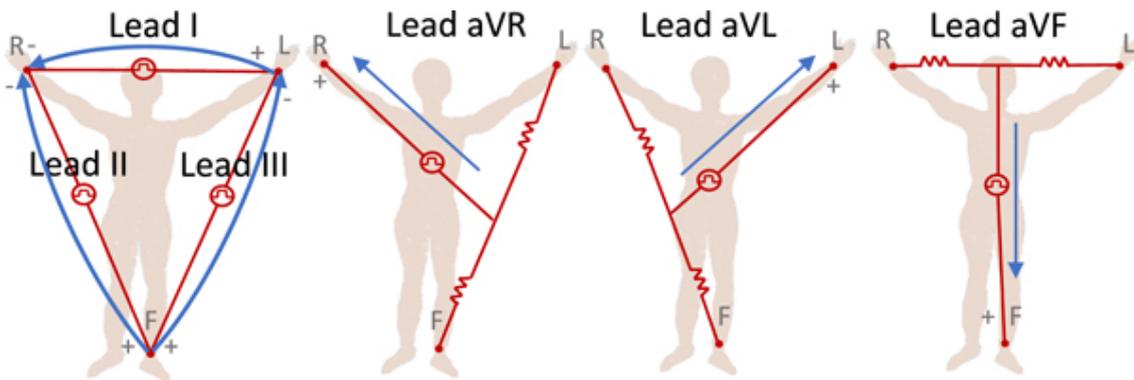


Abbildung 2.2: Die Einthoven Ableitungen (I, II, III) und die drei Ableitungen nach Goldberger (aVR, aVL, aVF). (aus [Rey+22, Fig. 1])

Ableitungen nach Einthoven

Bei den Ableitungen nach Einthoven (I, II, III; siehe Abb. 2.2) handelt es sich um „bipolare Extremitätenableitungen“. Der Name ergibt sich aus der Platzierung der Elektroden, da diese an den beiden Armen und an dem linken Fuß angebracht werden (Extremitäten). Außerdem bilden diese Ableitungsorte Eckpunkte zu einem Dreieck, welches „Einthoven-Dreieck“ genannt wird. Die Ableitung I erfasst die Potentialschwankungen zwischen rechtem und linkem Arm gegeben. Ableitung II die zwischen rechtem Arm und linkem Bein und Ableitung III die zwischen linkem Arm und linkem Bein. (vgl. [Kli+10, S.164])

Ableitung nach Goldberger

Die „Pseudo unipolare Ableitungen“ nach Goldberger werden durch jeweils einem Eckpunkt und dem Zusammenschluss der beiden anderen Eckpunkte des Einthoven-Dreiecks gebildet. Durch den Zusammenschluss zweier Eckpunkte entsteht ein virtueller Ableitungsort in der Mitte der Seite des Dreiecks. Die Ableitungen werden aVR, aVL und aVF genannt, aV steht für „augmented voltage“ (verstärkte Spannung). Das R (rechter Arm), L (linker Arm) oder F (linker Fuß) gibt an, welcher Eckpunkt des Einthoven Dreiecks nicht zusammen geschlossen wurde. So ist aVR die Ableitung, welches die Spannung zwischen dem rechten Arm und den Zusammenschluss des linken Arms und des linken Fußes misst. (vgl. [SLH11, S. 533])

Die Ableitungen sind ebenfalls veranschaulicht in Abb. 2.2.

Ableitungen nach Wilson

Weitere unipolare Ableitungen sind die Brustwandableitungen nach Wilson $V_1 - V_6$ (vgl. [Kli+10, S. 166]). Dabei „werden Ableitelektroden präkordial an genau definierten Stellen des Thorax angebracht“ [Kli+10, S. 166].

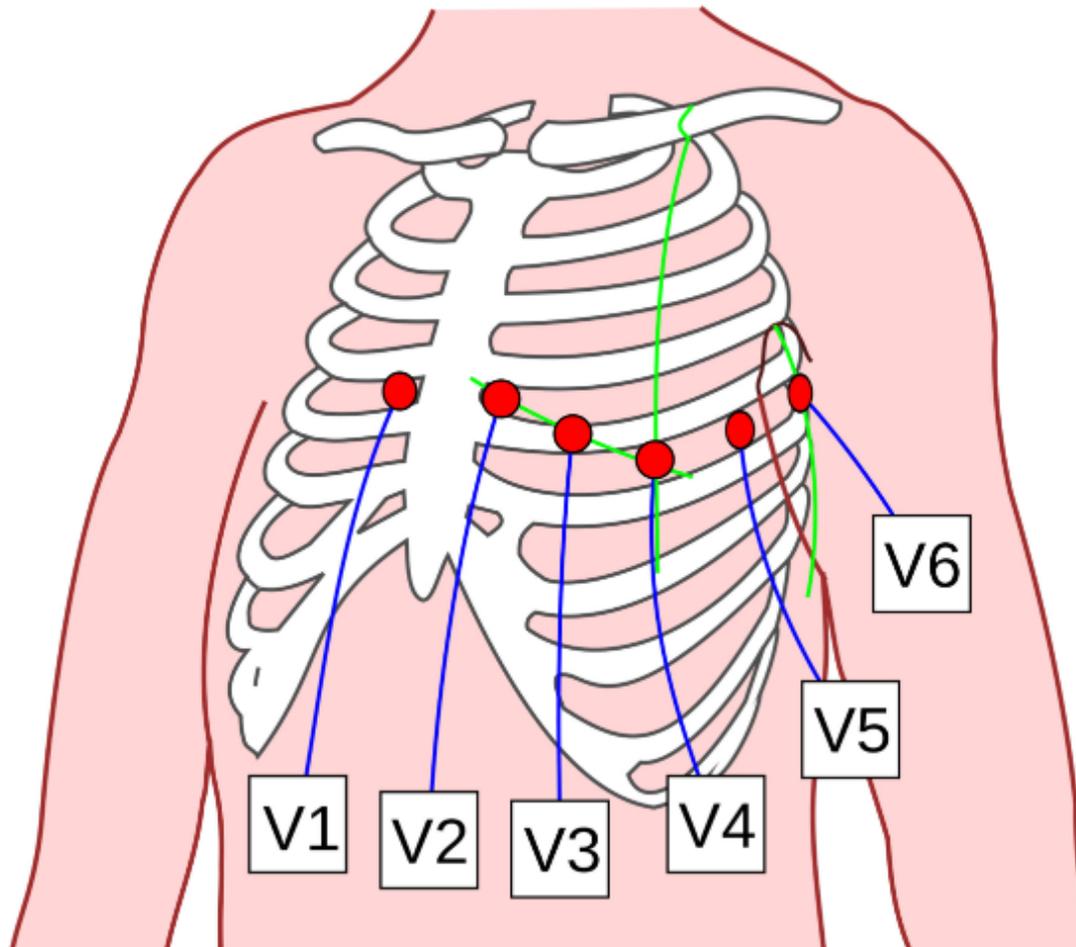


Abbildung 2.3: Brustwandableitungen nach Wilson ($V_1 - V_6$) (Bild von [Nog])

Mehrkanal-EKG

„Zusammen mit Einthoven und Goldberger stehen damit 12 Kanäle zur Verfügung. Dieses Ableitsystem stellt das klassische 12-Kanal-EKG dar, das heutzutage als Goldstandard in der Elektrokardiographie gilt“ [Car]. Neben dem genannten gibt es noch weitere Mehrkanal Ableitsysteme. Diese werden nach der Anzahl der verwendeten Ableitungen benannt, zum Beispiel wird bei drei verwendeten Ableitungen der Ausdruck "3-Kanal-EKG" benutzt. Hierbei ist zu beachten, dass die zu Grunde liegenden Ableitungen variieren können (vgl. [Cad; Ant+22; Rey+22, Tab. 3]).

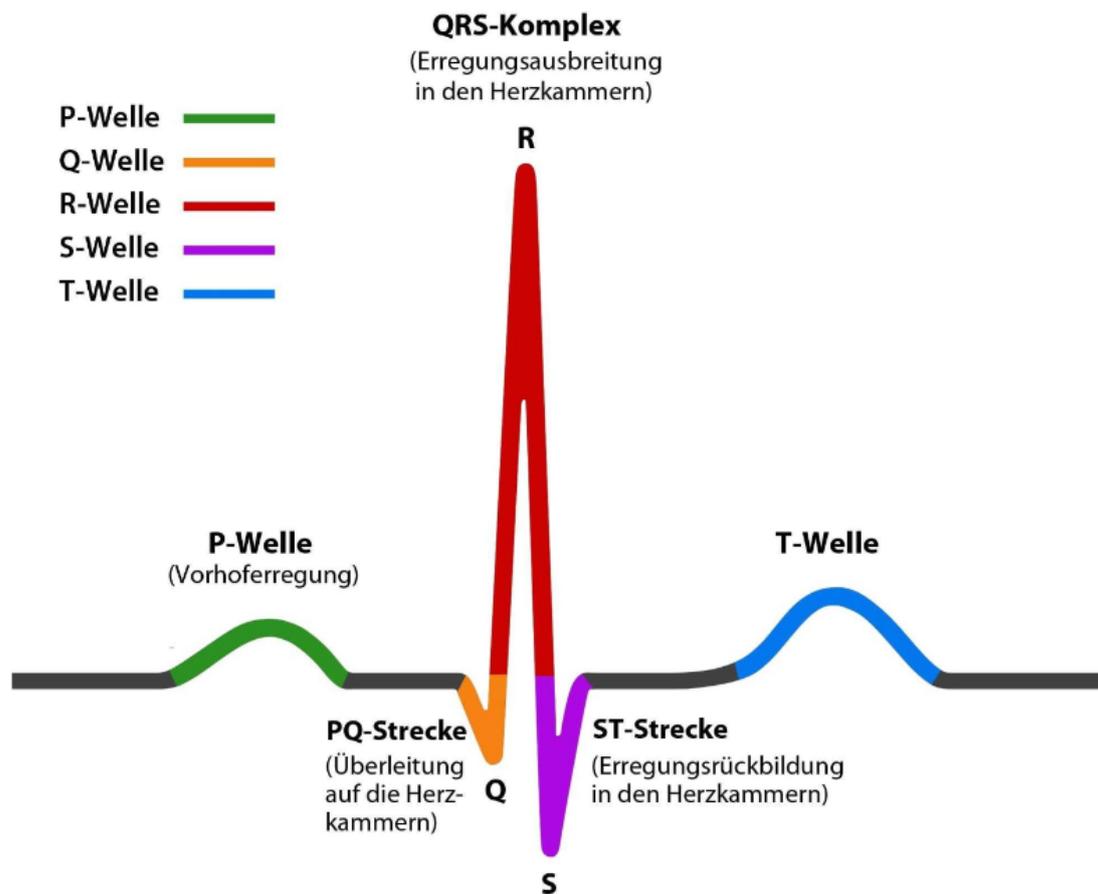


Abbildung 2.4: Sinusrhythmus (Bild aus [Med21] ursprünglich von [uda])

Elektrokardiogramm

Nachdem die Grundlagen geklärt wurden, wird nun erläutert werden wie ein „normales“ EKG, auch als Sinusrhythmus bekannt (siehe 2.4) aussieht.

Der Sinusrhythmus, erkennbar in Ableitung II, beginnt mit der P-Welle, welche durch die Vorhoferregung entsteht. Nachdem die Vorhöfe vollständig erregt wurden, erreicht die Spannung wieder die Nulllinie. Dadurch entsteht das PQ-Intervall.

Darauf folgend werden Teile der Herzscheidewand erregt, welches durch die Q-Zacke im EKG sichtbar wird. Durch weitere Erregung des Hohlraumes (Ventrikel) entsteht der gesamte QRS-Komplex. Nachdem der Ventrikel komplett erregt wurde, erreicht die Spannung wieder Null und es folgt die das ST-Intervall. Schlussendlich sorgt die Repolarisation des Ventrikels für die T-Welle, welche den Rhythmus schließt. (vgl. [Kli+10, S. 163f. SLH11, S. 530ff.])

Aussagemöglichkeiten des Elektrokardiogramms

Durch das EKG lassen sich Rückschlüsse auf die Herzschlagfrequenz ziehen. Ein zu schneller Herzschlag (mehr als 80 Schläge die Minute) wird Tachykardie genannt und ein verlangsamter Herzschlag (weniger als 60 Schläge die Minute) nennt sich Bradykardie. (vgl. [Kli+10, S. 170])

Des Weiteren lassen sich Herzrhythmusstörungen erkennen wie etwa Extrasystolen, Kammerflimmern oder Kammerflattern. (vgl. [Kli+10, S. 170])

Auch können Störungen der Erregungsleitung festgestellt werden und bei einem Herzinfarkt kann das EKG helfen den Ort, Ausdehnung und Verlauf zu bestimmen. (vgl. [Kli+10, S. 170])

Zusammenfassend lässt sich sagen, dass „Störungen der Erregungsbildung und der Erregungsausbreitung diagnostiziert werden können“ [Kli+10, S. 167]. Wie umfangreich diese Diagnosemöglichkeiten sind lässt sich in Marc Gertschs Werk „Das EKG“ sehen, indem er in mehr als 20 Kapiteln „übliche EKG-Bilder und Arrhythmien“ behandelt (vgl. [Ger08]).

Limitationen

Nachdem die Möglichkeiten des EKGs aufgezeigt wurden, ist es genauso wichtig „Grenzen des EKGs“ zu erwähnen. Zu aller Erst ist ein normales EKG-Bild kein Garant für die Gesundheit, selbst für die oben erwähnten Krankheiten. Als Weiteres kann das EKG nicht allein als Diagnose-Mittel verwendet werden, da es obligatorisch ist, dieses im klinischen Kontext zu betrachten. Des Weiteren ist es möglich, dass die körperliche Verfassung, Fehlbildungen der Brust, die Ethnie oder auch das Geschlecht, Einfluss auf das EKG haben. Neben Limitationen durch die verwendete Technik, ist ein signifikantes Problem die Expertise des Arztes. Da die Auswertung des EKGs nicht trivial ist, ist es besonders wichtig Ärzte gezielt darauf auszubilden. Je besser das Training ist und damit das Wissen des Arztes, desto besser kann das Potential des EKGs ausgeschöpft werden. [Bay+21, S. 19; Kli+07; Ger08, S. 2]

2.2 Technische Grundlagen

Dieses Kapitel soll einen Überblick über die im weiteren Verlauf wichtigen technischen Begrifflichkeiten geben. Außerdem dient es als Einstieg zum Thema Künstliche Intelligenz (KI).

2.2.1 Big Data

Für den Begriff „Big Data“ gibt es bisher keine einheitliche Definition. Im Allgemeinen versteht man darunter eine große Menge an Daten, die sich in ihrer Struktur und Quelle unterscheiden können und mittels herkömmlichen Verfahren oder Softwarewerkzeugen nicht mehr zu verarbeiten sind.

Die Meisten Datenwissenschaftler (Data Scientist) einigen sich auf folgende drei Eigenschaften oder auch „drei V’s“ genannt: Volume (Volumen), Variety (Vielfalt) und Velocity (Geschwindigkeit). Volume meint die Menge der Daten, Variety beschreibt die Vielfalt in der die Daten vorliegen, also Dateiformate oder auch sonstige Eigenschaften und Velocity kennzeichnet die Geschwindigkeit in der Daten entstehen bzw. verarbeitet werden. (vgl. [Mei18, S. 5]).

2.2.2 Künstliche Intelligenz

Künstliche Intelligenz (KI) dient als Überbegriff, für computerbasierte Technologien, die intelligentes Verhalten nachahmen. Es wird zwischen Machine Learning (ML) und Deep Learning (DL) unterschieden, wobei die Abgrenzung teilweise schwierig ist, da Deep Learning auch ein Teil von Machine Learning darstellt (siehe [HSI22a, Abb. 1]). Grundsätzlich lässt sich sagen, das Machine Learning sich damit beschäftigt Muster in Daten zu erkennen. Deep Learning wird es, wenn die Mustererkennung von vielschichtigen künstlichen neuronalen Netzwerken (KNN) übernommen wird. (vgl. [HSI22a, S. 235])

In dem Gebiet der künstlichen Intelligenz werden drei Arten des Lernens unterschieden (vgl. [HSI22a, S. 235]). Diese werden nachfolgend aufgelistet.

Überwachtes Lernen

Beim überwachten Lernen (engl. supervised learning) bestehen die Trainingsdaten aus Paaren von Eingabe- und Ausgabenwerten (engl. labels). Dadurch kann das System beim Erlernen eines Algorithmus die Labels verwenden, um seine Richtigkeit zu prüfen. Das Ziel ist es neue Eingabedaten mit entsprechenden Labels versehen zu können.

Man unterscheidet zwischen Klassifikation, das heißt das System lernt unterschiedliche Eingabedaten in Klassen zuzuordnen und Regression, wie man sie aus der Mathematik kennt. (vgl. [HSI22a, S. 234; Kün19])

Unüberwachtes Lernen

Beim unüberwachten Lernen (engl. unsupervised learning) beinhalten die Trainingsdaten keine Labels (vgl. [HSI22a]). Hier muss das System selbst „Muster in den Eingabedaten entdecken“ (vgl. [Kün19]).

Verstärkendes Lernen

Das verstärkende Lernen (engl. reinforcement learning) unterscheidet sich komplett von den vorherigen Lernverfahren. Denn in dieser Art des Lernen ist es dem System möglich Handlungen in einer vorgegebenen Umgebung durchzuführen. Das Lernen erfolgt dann durch das Belohnen oder Bestrafen der Handlungen.

Ein berühmtes Beispiel einer Anwendung, die mit dieser Lernmethode trainiert wurde ist „AlphaGo“, welche im Jahre 2016 den weltweit besten AlphaGo Spieler geschlagen hatte. (vgl. [HSI22a; Kün19])

2.2.3 Künstliche Neuronale Netze

Künstliche Neuronale Netze (KNN) bestehen aus einer Eingabeschicht (Input Layer), mindestens einer verborgenen Schicht (hidden layers) und aus einer Ausgabeschicht (Output Layer). Jede Schicht besteht aus künstlichen Neuronen (Knoten). (vgl. [HSI22a])

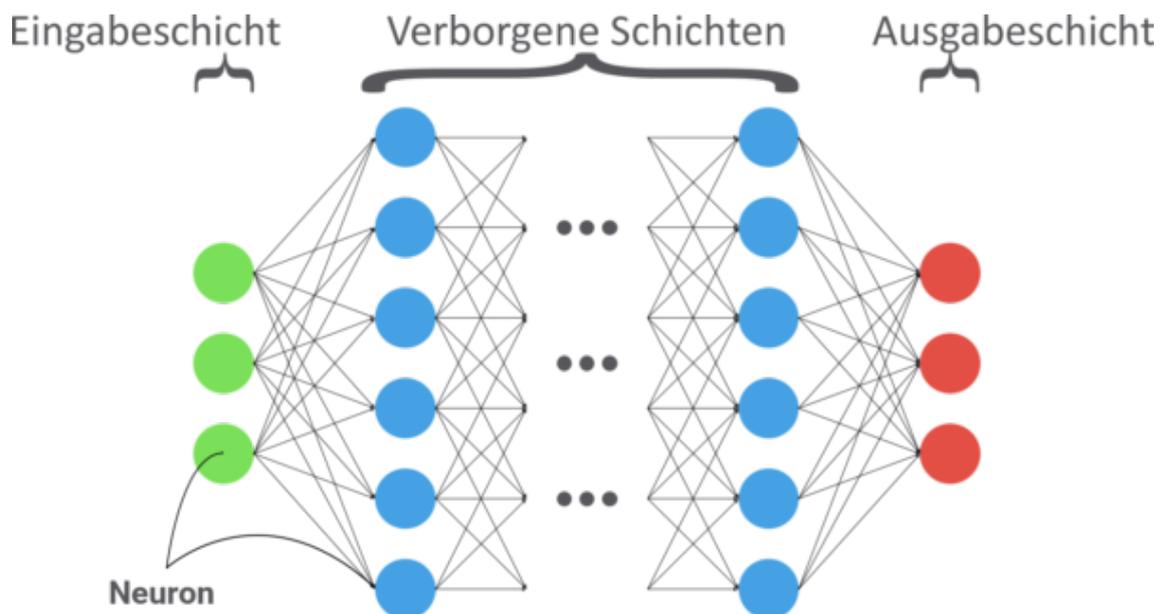


Abbildung 2.5: Architektur eines künstlichen neuronalen Netzes. (Bild aus [Don21])

In der Eingabeschicht werden die übergebenen Informationen von den Neuronen aufgenommen, gewichtet und an die erste Schicht der verborgenen Schichten weitergeleitet. Die Gewichtung ist ein Maß zur Bestimmung der Relevanz der Informationen.

In den verborgenen Schichten, werden die Informationen für jede Schicht neu verarbeitet und gewichtet. Hierbei sind die genaue Verarbeitung und Gewichtung nicht sichtbar. Umso größer die Anzahl der verborgenen Schichten, desto „tiefer“ ist das Netz. Dadurch bildet sich der Zusammenhang zum Deep Learning bei besonders tiefen Netzen.

Die letzte verborgene Schicht leitet die verarbeiteten Informationen an die Ausgangschicht. Die Neuronen der Ausgangschicht geben das Ergebnis aus. (vgl. [HSI22a; Stu])

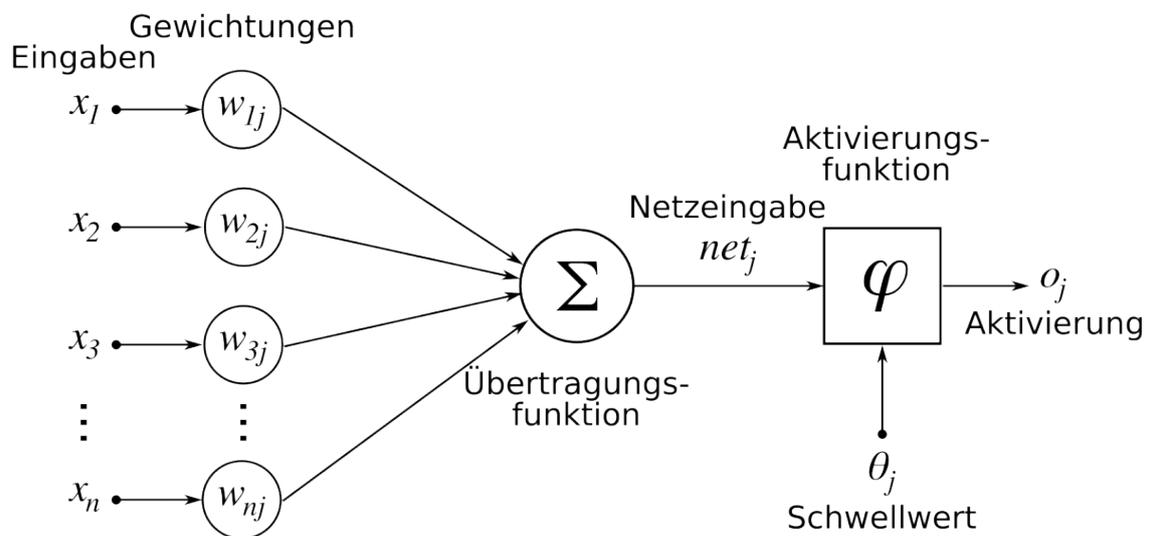


Abbildung 2.6: Darstellung eines künstlichen Neurons. (Bild aus [Kom15])

Die Weiterleitung von Neuron zu Neuron ist nicht trivial. Bis auf die Neuronen aus der Eingabeschicht, ist ein Neuron mit den Neuronen der vorherigen Schicht über Kanten verbunden. Von diesen erhält das Neuron jeweils seine Informationen (Eingaben) und die dazugehörigen Gewichte. Die Gewichte werden mit den zugehörigen Gewichten multipliziert und an die Übertragungsfunktion gegeben. Der aus der Übertragungsfunktion resultierende Wert geht an die Aktivierungsfunktion.

Die Aktivierungsfunktion ist eine Funktion, die mithilfe eines Schwellwertes entscheidet, ob eine Weiterleitung stattfindet oder nicht. Die Aktivierungsfunktion kann dann auch eine Funktionsvorschrift vorgeben, das heißt der Wert aus der Übertragungsfunktion wird in die Aktivierungsfunktion eingesetzt und wird damit der Eingabewert für das nächste Neuron. (vgl. [HSI22a; Stu])

Es gibt verschiedene Arten von künstlich neuronalen Netzen. „Sie unterscheiden sich hinsichtlich ihrer Architektur und Struktur“ [Stu].

Vorwärts gerichtetes neuronales Netz

Das vorwärts gerichtete neuronale Netz (Feed Forward Neural Network) hat die Besonderheit, dass es keine Rückkopplungen gibt. Damit ist gemeint, dass die Informationsweiterleitung aus der Eingabeschicht strikt in Richtung der Ausgabeschicht geht.

Damit gibt es für die Neuronen nur gerichtete Kanten auf die jeweils nächsthöhere Schicht. (vgl. [HSI22a; Stu])

Rekurrentes neuronales Netz

Im Gegensatz zu dem vorwärts gerichteten neuronalen Netz, gibt es im rekurrenten Netz Rückkopplungen. Das heißt es gibt Kanten, die zu Neuronen derselben oder zu der vorangegangenen Schicht führen.

Dadurch erhält das Netz eine Art Gedächtnis. (vgl. [HSI22a; Stu])

Konvolutionales neuronales Netz

Ein konvolutionales neuronales Netz (Convolutional neural network) „besteht im Wesentlichen aus Filtern (genannt Convolutional Layer) und Aggregations-Schichten (genannt Pooling Layer), die sich abwechselnd wiederholen, und am Ende aus einer oder mehreren Schichten von „normalen“ vollständig verbundenen Neuronen (genannt Dense oder auch Fully Connected Layer)“ [WEG19].

In jeder Schicht findet eine immer feiner werdende Mustererkennung statt und die eingegebenen Daten werden nach und nach komprimiert, indem Teile der Daten mittels Faltung (convolution) kombiniert werden.

Der Einsatz dieser neuronalen Netze ist vor allem in der Bildanalyse. (vgl. [WEG19; HSI22a; Stu])

3 PhysioNet/CinC Challenge 2020/21

Die PhysioNet/Computing in Cardiology (CinC) Challenge ist ein jährlicher Wettbewerb mit dem Ziel die Forschung von klinisch und praktisch relevanten Problemen voranzutreiben.

Dabei ist es den Veranstaltern wichtig, dass alle Inhalte und Resultate öffentlich und frei zugänglich sind (Open Source). Das übernimmt PhysioNet, die auch unabhängig von der Challenge, auf ihrer Web-Seite freien Zugriff auf diverse Daten und open-source Software bereitstellen. (vgl. [Cin; Gol+00])

Im Jahre 2020 ist das Thema „Klassifizierung von 12-Kanal-EKGs“ gewesen. Die Aufgabe bestand darin Abnormalitäten in einem 12-Kanal-EKG feststellen zu können. Ziel der Challenge ist gewesen, klinische Diagnosen aus einer 12-Kanal-EKG Aufzeichnung zu identifizieren. (vgl. [Ald+20, S. 2])

Die Challenge aus 2021 schließt sich thematisch der Challenge aus dem Vorjahr an. Mit dem Titel „Will Two Do? Varying Dimensions in Electrocardiography“ ist die Challenge der Frage nachgegangen, ob mit Standard-EKG trainierten Algorithmen, die gleiche Ergebnisse auch mit Mehrkanal-EKGs mit weniger Ableitungen erzielt werden können. Konkret wurden die Algorithmen auf Aufnahmen von zwei-, drei-, vier-, sechs- und 12-Kanal-EKGs getestet. (vgl. [Rey+21])

Im Folgenden werden diese Challenges näher beschrieben, um am Ende aus den Einreichungen der Teilnehmer Erkenntnisse zu gewinnen.

3.1 Aufgabe

Dieses Unterkapitel handelt von den detaillierten Aufgabenstellungen, die in den PhysioNet/CinC Challenges in den Jahren 2020/2021 gestellt wurden. Außerdem wird die Bewertungsmetrik erläutert.

3.1.1 2020

Die Teilnehmer wurden aufgefordert Open Source Algorithmen zu entwickeln, die Abnormalitäten in Aufzeichnungen des Standard 12-Kanal-EKGs erkennen können.

In den Trainings-Daten wurden die Daten jeweils mit 111 Diagnosen gelabelt. Von diesen 111 Diagnosen waren für die Challenge 27 relevant (siehe Tab. 3.1), die für das Punktesystem gewertet wurde. Trotzdem ist es den Teilnehmern gleichgestellt, wie viele Diagnosen sie berücksichtigen möchten. (vgl. [Ald+20])

Diagnose	Code	Abkürzung
AV-Block 1. Grades	270492004	IAVB
Vorhofflimmern	164889003	AF
Vorhofflattern	164890007	AFL
Bradykardie	426627000	Brady
Kompletter Rechtsschenkelblock	713427006	CRBBB
Inkompletter Rechtsschenkelblock	713426002	IRBBB
Linksanteriorer Hemiblock	445118002	LAnFB
Linksagetyp	39732003	LAD
Linksschenkelblock	164909002	LBBB
Niedrige QRS-Spannungen	251146004	LQRSV
Nicht spezifizierte intraventrikuläre Leitungsstörung	698252002	NSIVCB
Schrittmacherrhythmus	10370003	PR
Vorzeitige atriale Kontraktion	284470004	PAC
Vorzeitige ventrikuläre Kontraktion	427172004	PVC
Verlängertes PR-Intervall	164947007	LPR
Verlängertes QT interval	111975006	LQT
Abnormale Q-Zacke	164917005	QAb
Rechtslagetyp	47665007	RAD
Rechtsschenkelblock	59118001	RBBB
Sinus Arrhythmie	427393009	SA
Sinus Bradykardie	426177001	SB
Sinus Rhythmus	426783006	NSR
Sinus Tachykardie	427084000	STach
Supraventrikuläre Extrasystolen	63593006	SVPB
Abnormale T-Welle	164934002	TAb
T-Inversion	59931005	TInv
Ventrikuläre Extrasystolen	17338001	VPB

Tabelle 3.1: Diagnosen mit Systematisierte Nomenklatur der Medizin (SNOMED CT) Codes und Abkürzungen in den gegebenen Trainings-Datensätzen, die in die Bewertung eingehen (übersetzt aus [Ald+20, Tab. 3]).

Des Weiteren wurde angefordert, dass die Teilnehmer sowohl für das bereits Trainierte als auch zum Trainieren ihres Modells Code bereit zu stellen. Darüber hinaus müssen

die Algorithmen mit den gegebenen Trainingsdaten reproduzierbar sein, damit die verbundene Forschung nachvollziehbar ist und die Reproduzierbarkeit gewährleistet ist (vgl. [Ald+20]).

3.1.2 2021

Diagnose	Code	Abkürzung
Vorhofflimmern	164 889 003	AF
Vorhofflattern	164 890 007	AFL
Bündelzweigblock	6 374 002	BBB
Bradykardie	426 627 000	Brady
Kompletter Linksschenkelblock	713 427 002	CLBBB
Kompletter Rechtsschenkelblock	713 427 006	CRBBB
AV-Block 1. Grades	270 492 004	IAVB
Inkompletter Rechtsschenkelblock	713 426 002	IRBBB
Linkslagetyp	39 732 003	LAD
Linksanteriorer Hemiblock	445 118 002	LAnFB
Linksschenkelblock	164 909 002	LBBB
Verlängertes PR-Intervall	164 947 007	LPR
Niedrige QRS-Spannungen	251 146 004	LQRSV
Verlängertes QT interval	111 975 006	LQT
Nicht spezifizierte intraventrikuläre Leitungsstörung	698252002	NSIVCB
Sinus Rhythmus	426 783 006	NSR
Vorzeitige atriale Kontraktion	284 470 004	PAC
Schrittmacherrhythmus	10 370 003	PR
Verzögerte P-Progression	365 413 008	PRWP
Vorzeitige ventrikuläre Kontraktion	427 172 004	PVC
Abnormale Q-Zacke	164 917 005	QAb
Rechtslagetyp	47 665 007	RAD
Rechtsschenkelblock	59 118 001	RBBB
Sinus Arrhythmie	427 393 009	SA
Sinus Bradykardie	426 177 001	SB
Sinus Tachykardie	427 084 000	STach
Supraventrikuläre Extrasystolen	63 593 006	SVPB
Abnormale T-Welle	164 934 002	TAb
T-Inversion	59 931 005	TInv
Ventrikuläre Extrasystolen	17 338 001	VPB

Tabelle 3.2: Diagnosen mit Systematisierte Nomenklatur der Medizin (SNOMED CT) Codes und Abkürzungen in den gegebenen Trainings-Datensätzen, die in die Bewertung eingehen (übersetzt aus [Rey+22, Tab. 5]).

Von der Aufgabe unterscheidet sich die Challenge aus dem Jahr 2021 nicht großartig von der Challenge aus dem Vorjahr (vgl. Kap. 3.1.1). Anstatt 27 Abnormalitäten die festzustellen waren, wurden es in dem Jahr 30 (siehe Tab. 3.2).

Anzahl der Ableitungen	Anzahl der unabhängigen Ableitungen	Ableitungssystem
12	8	I, II, III, aVR, aVL, aVF, V1, V2, V3, V4, V5, V6
4	3	I, II, III, V2
3	3	I, II, V2
6	2	I, II, III, aVR, aVL, aVF
2	2	I, II

Tabelle 3.3: Verwendete Ableitungssysteme für das verborgene Validierung- und Testset. (übersetzt aus [Rey+22, Tab. 3])

Des Weiteren mussten die Algorithmen der Teilnehmer nicht nur Aufzeichnungen des Standard-EKGs klassifizieren können, sondern auch von zwei-, drei-, vier-, und sechs-Kanal-EKGs. Die Ableitungssysteme und die darin enthaltenen Informationen (Anzahl von unabhängigen Ableitungen) wurden in Tabelle 3.3 zusammengefasst (vgl. [Rey+21; Rey+22]).

3.1.3 Bewertung

Für die Bewertung der Klassifizierung durch die Algorithmen der Teilnehmer, haben die Veranstalter eine eigene Bewertungsmetrik entwickelt. Diese wurde erstmals in der Challenge in 2020 vorgestellt und mit minimaler Änderung auch für 2021 verwendet. (vgl. [Ald+20; Rey+21])

Alle weiteren Angaben zu dem Bewertungssystem in diesem Unterkapitel sind aus [Ald+20; Rey+21] entnommen.

	Elephant	25	3	0	2
Actual	Monkey	3	53	2	3
	Fish	2	1	24	2
	Lion	1	0	2	71
		Elephant	Monkey	Fish	Lion
		Predicted			

Abbildung 3.1: Beispiel einer Konfusionsmatrix. (Bild von [MLe21])

Für die Bewertungsmetrik wurde zuerst eine Konfusionsmatrix definiert. Dafür wurde folgendes definiert:

Sei $C = \{c_i\}_{i=1}^m$ die Menge an m verschiedenen Diagnosen für einen Datensatz mit n Aufzeichnungen. Weiter sei für $k = 1, \dots, n$: x_k definiert als die Menge der positiven Labels und y_k die Menge der positiven Ausgaben des Klassifikators (engl. positive classifier output) für die k -te Aufzeichnung.

Dann ist die Konfusionsmatrix $A = [a_{ij}]$ definiert durch:

$$a_{ij} = \sum_{k=1}^n a_{ijk} \quad (3.1)$$

mit

$$a_{ijk} = \begin{cases} \frac{1}{|x_k \cup y_k|} & c_i \in x_k \wedge c_j \in y_k \\ 0 & \text{sonst} \end{cases} \quad (3.2)$$

Als nächstes wird eine Belohnungsmatrix definiert (siehe für 2020 A.1 und für 2021 A.2). Diese ist essenziell und erfüllt den Wunsch ein Bewertungssystem zu haben, welches manche Fehldiagnosen schwerer als Andere gewichtet. Das begründet sich damit, dass auch in der Realität manche Fehldiagnosen schwerwiegender sind als Andere, da manche Fehldiagnosen zur einer ähnlichen Behandlung führen, wie die richtige Diagnose. Manche Fehldiagnosen sind daher schlechter, wenn der Patient eine falsche Behandlung bekommt. Für die klinische Richtigkeit dieser Belohnungsmatrix wurden bei ihrer Erstellung Kardiologen miteinbezogen.

Konkret gibt die Belohnungsmatrix die Belohnung für positive Ausgaben des Klassifikators. Dabei gibt es entweder die volle Belohnung, für das korrekte Klassifizieren, eine Teilbelohnung für eine Fehldiagnose oder keine Belohnung für den Fall das Diagnosen klassifiziert wurden die nicht in der Wertung enthalten sind (vgl. Kap. 3.1).

Damit ergibt sich aus der Konfusionsmatrix und der Belohnungsmatrix die nicht normalisierte Wertung s_U und die normalisierte Wertung s_N . Die Wertung wurde so normalisiert, dass ein Klassifikator s_T der immer die wahren Klassen klassifiziert die Wertung 1 erhält und ein Klassifikator s_I , der keine Abnormalitäten identifiziert also immer den Sinus Rhythmus klassifiziert, die Wertung 0 erhält.

Es gilt:

$$s_U = \sum_{i=1}^m \sum_{j=1}^m w_{ij} a_{ij} \quad (3.3)$$

und

$$s_N = \frac{s_U - s_I}{s_T - s_I} \quad (3.4)$$

Als letzte Anmerkung zu der Bewertung soll erwähnt sein, dass im Jahre 2020 und 2021 mehrere Diagnosen in der Reward Matrix als äquivalent angesehen wurden. In 2020 sind es CRBBB und RBBB und PVC und VPB gewesen. In 2021 ist CLBBB und LBBB als Äquivalente dazu gekommen. (vgl. [Ald+20; Rey+21])

3.2 Datensätze

In diesem Unterkapitel wird ein Überblick, über die mit den Challenges zusammenhängenden Datensätzen gegeben.

Vorab, für beide Jahre gilt, dass die Daten aus EKG-Aufzeichnungen mit dazugehörigen Diagnosen und demographischen Angaben versehen wurden (z.B. Alter und Geschlecht).

Dabei wurde versichert, dass die EKG-Aufzeichnung innerhalb eines klinischen Kontextes entstanden sind (vgl. [Rey+22; Rey+21; Ald+20]).

Außerdem gilt, dass die Trainingsdaten für die Teilnehmer frei zugänglich gewesen sind, die Validierungs- und Testdaten jedoch nicht (vgl. [Rey+22; Rey+21; Ald+20]).

3.2.1 Datenquellen

Dieser Abschnitt beschäftigt sich mit der Zusammensetzung der Daten, dass heißt woher diese stammen und wie diese in Trainings-, Validierungs-, und Testdaten eingeteilt sind. Außerdem werden die darin enthaltenen Informationen aufgeführt.

In Tabelle 3.4 sind alle Datenbanken aufgelistet, die für die beiden Jahre verwendet wurden (vgl. [Ald+20; Rey+21; Rey+22]).

Datenbank	Quelle	Standort	Referenz
Chapman-Shaoxing	Shaoxing People's Hospital	Shaoxing, Zhejiang, China	[Zhe+20b; Zhe+20a]
CPSC	CPSC 2018	Various Locations, China	[Liu+18]
CPSC-Extra	CPSC 2018	Various Locations, China	[Liu+18]
G12EC	Emory University Hospital	Atlanta, Georgia, USA	[Ald+20]
INCART	St. Petersburg Institute of Cardiological Technics	St. Petersburg, Russia	[Tih+08]
Ningbo	Ningbo First Hospital	Ningbo, Zhejiang, China	[Zhe+20b; Zhe+20a]
PTB	University Clinic Benjamin Franklin	Berlin, Germany	[BKS95]
PTB-XL	Physikalisch Technische Bundesanstalt	Various Countries, Europe	[Wag+20]
UMich	University of Michigan	Ann Arbor, Michigan, USA	[Rey+21]
Undisclosed	k.A.	USA	[Ald+20]

Tabelle 3.4: Quelle, Standort und Referenz für jede Datenbank, die für die Challenges genutzt wurde. (aus [Rey+22, Tab. 1])

Die *Chapman-Shaoxing* Datenbank ist aus der Datenbank abgeleitet, die von [Zhe+20b; Zhe+20a] vorgestellt wurde (vgl. [Rey+22]).

Die *CPSC*- und *CPSC-Extra*-Datenbank sind aus der „China Physiological Signal Challenge 2018“ (CPSC 2018) [Liu+18], wobei *CPSC-Extra* Daten beschreibt, die nicht für die CPSC 2018 genutzt wurden (vgl. [Rey+22]).

G12EC ist die Datenbank der „Georgia 12-lead ECG Challenge“ (vgl. [Ald+20]).

Vom „Institute of Cardiological Technics“ (INCART) aus Sankt-Petersburg wurde die *INCART*-Datenbank aus der von [Tih+08] vorgestellten Datenbank abgeleitet (vgl. [Rey+22]).

Die *Ningbo*-Datenbank ist ebenfalls eine von [Zhe+20b; Zhe+20a] abgeleitete Datenbank (vgl. [Rey+22]).

PTB und *PTB-XL* sind aus [BKS95; Wag+20] von der „Physikalisch-Technische Bundesanstalt“ zusammengesetzte Datenbanken (vgl. [Rey+22]).

UMich ist eine Datenbank der „University of Michigan“ (vgl. [Rey+22]).

Als *Undisclosed* wird ein Datensatz bezeichnet, der bisher nicht veröffentlicht wurde, aus einer nicht angegebenen amerikanischen Institution (vgl. [Rey+22]).

2020

In Tabelle 3.5 sind die Datenquellen und die Aufteilung der Daten zu sehen, die für die Challenge im Jahr 2020 verwendet wurden.

Datenbank	Anzahl der Patienten	Aufnahmen im Trainingsset	Aufnahmen im Validierungsset	Aufnahmen im Testset	Anzahl Aufnahmen
CPSC	9458	10 330	1463	1463	13 256
INCART	32	74	0	0	74
PTB	19 175	22 353	0	0	22 353
G12EC	15 742	10 344	5167	5167	20 678
Undisclosed	Unknown	0	0	10 000	10 000
Total	Unknown	43 101	6630	16 630	66 361

Tabelle 3.5: Die verwendeten Datenbanken mit ihrer Anzahl der Patienten und ihrer Aufteilung in Trainings-, Validierungs- und Testset, für das Jahr 2020. [Ald+20, Tab. 1]

2021

Für 2021 sind die Datenquellen mit den dazugehörigen Aufteilungen der Daten in Tabelle 3.6 zu sehen.

Datenbank	Anzahl der Patienten	Aufnahmen im Trainingsset	Aufnahmen im Validierungsset	Aufnahmen im Testset	Anzahl Aufnahmen
Chapman-Shaoxing	10 247	10 247	0	0	10 247
CPSC	Unknown	6877	1463	1463	9803
CPSC-Extra	Unknown	3453	0	0	3453
G12EC	15 738	10 344	5167	5161	20 672
INCART	32	74	0	0	74
Ningbo	34 905	34 905	0	0	34 905
PTB	262	516	0	0	516
PTB-XL	18 885	21 837	0	0	21 837
UMich	N/A	0	0	19 642	19 642
Undisclosed	N/A	0	0	10 000	10 000
Total	N/A	88 253	6630	36 266	131 149

Tabelle 3.6: Die verwendeten Datenbanken mit ihrer Anzahl der Patienten und ihrer Aufteilung in Trainings-, Validierungs- und Testset, für das Jahr 2021. [Rey+22, Tab. 2]

Außerdem ist zu erwähnen, dass für die Challenge immer 12-Kanal-EKG Aufzeichnungen als Trainingsdaten gegeben wurden. Zum Validieren und Testen wurden aus den Signaldaten entsprechende Versionen generiert, nach den in Tabelle 3.3 aufgeführten Ableitungssysteme (vgl. [Rey+22]).

3.2.2 Datenanalyse

Nachdem geklärt wurde, woher die Daten stammen und wie diese eingeteilt wurden, ist es wichtig zu wissen, wie die darin enthaltenen Informationen im Detail aussehen und variieren.

Datensatz	Anzahl der Aufnahmen	Mittlere Dauer (s)	Mittleres Alter (Jahren)	Geschlecht (m/w)	Samplingfrequenz(HZ)
CPSC (all data)	13 256	16.2	61.1	53%/47%	500
CPSC Training	6877	15.9	60.2	54%/46%	500
CPSC-Extra Training	3453	15.9	63.7	53%/46%	500
Hidden CPSC	2926	17.4	60.4	52%/48%	500
INCART	72	1800.0	56.0	54%/46%	257
PTB	516	110.8	56.3	73%/27%	1000
PTB-XL	21 837	10.0	59.8	52%/48%	500
G12EC (all data)	20 678	10.0	60.5	54%/46%	500
G12EC Training	10 344	10.0	60.5	54%/46%	500
Hidden G12EC	10 344	10.0	60.5	54%/46%	500
Undisclosed	10 000	10.0	63.0	53%/47%	300

Tabelle 3.7: Anzahl der Aufnahmen, mittlere Dauer (in Sekunden) der Aufnahmen, mittleres Alter der Patienten (in Jahren), Anteile der Geschlechter (männlich und weiblich in Prozent) und die Samplingfrequenz (in HZ) für jeden Datensatz aus dem Jahr 2020. [Ald+20, Tab. 2]

Datensatz	Anzahl der Aufnahmen	Mittlere Dauer (s)	Mittleres Alter (Jahren)	Geschlecht (m/w)	Samplingfrequenz(HZ)
Chapman-Shaoxing	10 247	10.0	60.1	56%/44%	500
CPSC	9803	16.4	60.0	53%/47%	500
- CPSC training	6877	15.9	60.2	54%/46%	500
- CPSC validation	1463	17.2	58.9	51%/49%	500
- CPSC test	1463	17.5	60.0	53%/47%	500
CPSC-Extra	3453	15.9	63.7	53%/47%	500
G12EC	20 672	10.0	60.5	54%/46%	500
- G12EC training	10 344	10.0	60.5	54%/46%	500
- G12EC validation	5167	10.0	60.3	53%/47%	500
- G12EC test	5161	10.0	60.7	54%/46%	500
INCART	74	1800.0	56.0	54%/46%	257
Ningbo	34 905	10.0	57.7	56%/43%	500
PTB	516	110.8	56.3	73%/27%	1000
PTB-XL	21 837	10.0	59.8	52%/48%	500
UMich	19 642	10.0	60.2	53%/47%	250/500
Undisclosed	10 000	10.0	63.0	53%/47%	300

Tabelle 3.8: Anzahl der Aufnahmen, mittlere Dauer (in Sekunden) der Aufnahmen, mittleres Alter der Patienten (in Jahren), Anteile der Geschlechter (männlich und weiblich in Prozent) und die Samplingfrequenz (in HZ) für jeden Datensatz aus dem Jahr 2021.[Rey+22, Tab. 4]

In den Tabellen 3.7 bzw. 3.8 für das Jahr 2020 bzw 2021 sind die folgenden Eigenschaften angegeben: Anzahl der Aufnahmen, die mittlere Dauer der Aufnahmen (in Sekunden), das mittlere Alter, die Anteile der Geschlechter (in Prozent) und die Samplingfrequenz (in HZ).

Dadurch ist festzustellen, dass sich die EKG-Daten als *Big Data* (vgl. Kap. 2.2.1) kategorisieren lassen. Aus den Tabellen entnimmt man *Volume* und *Variety*, da man es mit größeren Datenmengen zu tun hat, die auch in Ihren Eigenschaften variieren. Um den Bezug zu *Velocity* und *Volume* nochmal zu verdeutlichen: im Jahre 2016 wurde von *Reichlin et Al* geschätzt, dass jährlich in etwa 200 Millionen EKGs aufgezeichnet werden (vgl. [Rei+16]).

3.3 Partizipationen

Als nächstes geht es um die Beteiligungen der Teilnehmer. Besonders relevant ist hier, ob und wie die Teilnehmer die Daten aufbereitet haben und welche Methoden der künstlichen Intelligenz (vgl. Kap. 1.2.2) Anwendung gefunden haben, da diese Hauptbestandteile eines Data Science Projektes sind, welches man mitunter in dem Lebenszyklus des „Team Data Science-Prozess“ von Microsoft sehen kann (vgl. [Tab+22, 3.2]).

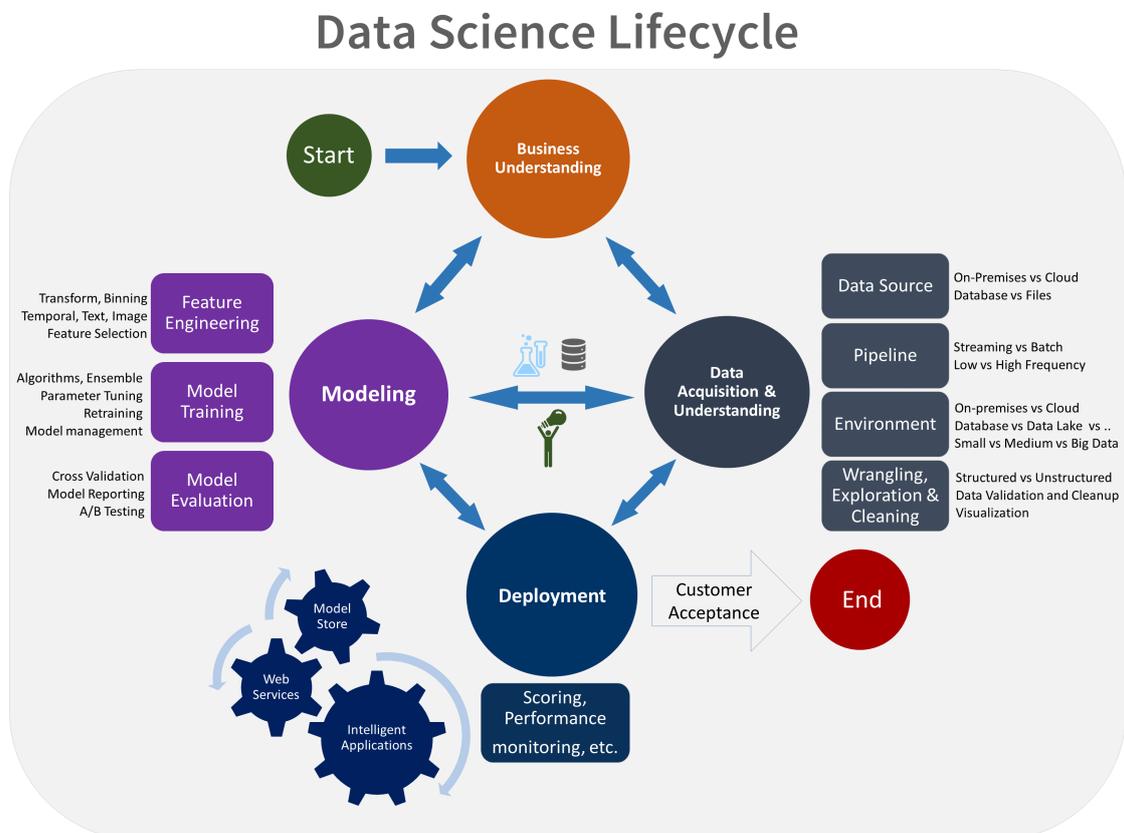


Abbildung 3.2: „Visuelle Darstellung des TDSP-Lebenszyklus“ [Tab+22]

Für 2020 sind Einreichungen von insgesamt 70 teilnehmenden Teams mit Hilfe des Testsets bewertet worden. Davon wiederum haben es lediglich 41 Teams geschafft, sich für die offizielle Rangliste zu qualifizieren. Die übrigen Teams wurden durch nicht Einhaltung der Formalien aus unterschiedlichen Gründen disqualifiziert. Dennoch findet man diese eingeteilt in der inoffiziellen Rangliste. (vgl. [Ald+20; Phy20])

Im Jahre 2021 sind es 39 teilnehmende Teams gewesen, die es in die offizielle Rangliste geschafft haben (vgl. [Rey+21; Phy21]).

3.3.1 Datenaufbereitung

„Der Prozess der Datenaufbereitung umfasst die Reinigung, Formung und Mischung von Daten, damit sie für analytische und andere Aufgaben in optimaler Qualität bereitstehen. Nur mit erstklassigen Daten lassen sich beispielsweise Lösungen für Machine Learning und Künstliche Intelligenz effizient, sicher und zuverlässig versorgen“ [ML19].

Um die Datenaufbereitung in den Jahren zu vergleichen, werden für 2020 die Beiträge der offiziell besten bzw. schlechtesten Teilnehmer verglichen (vgl. [Phy20]) und für 2021 wird sich auf [Rey+22] bezogen.

2020

Das Team, welches den ersten Platz auf der offiziellen Rangliste für 2020 belegt hat, fing damit an die unterschiedlichen Samplingfrequenzen mit einer Abtastratenkonvertierung (resampling) auf 500HZ auszugleichen. Des Weiteren nutzten sie einen Bandpassfilter mit endlicher Impulsantwort (engl. finite impulse response filter, FIR-Filter) mit einer Bandbreite zwischen 3 und 45 HZ, d.h., dass Signaldaten außerhalb der Bandbreite gefiltert werden. Außerdem werden die Daten normalisiert, sodass die Signaldaten jeder Ableitung im Intervall von $[-1,1]$ liegen. Zu guter Letzt wurden aus jeder Aufnahme zufällig fünfzehn-sekündige Sequenzen entnommen, falls die Sequenz unter den fünfzehn Sekunden liegt, wird diese mit Nulldaten entsprechend aufgefüllt (zero-padding). (vgl. [Nat+20])

Auch das Team auf dem zweiten Platz wendete resampling an, jedoch auf 257HZ. Ebenfalls wurde eine Länge von 4096 Datenpunkten festgelegt, welches sich mit ca. 16 Sekunden beschreiben lässt. Bei kürzeren Signaldaten wurde zero-padding angewandt und aus längeren Daten werden zufällig Sequenzen mit entsprechender Länge entnommen (truncating). Außerdem verwendet das Team für ihr Modell die Daten zum Geschlecht und Alter. Dafür skalierte sie das Alter in einem Intervall von $[0,1]$ und nutzten

„One-Hot-Kodierung“, um Geschlecht und Alter zu kodieren (vgl. [Zha+20]). One-Hot-Kodierung ist ein Verfahren, womit man kategoriale Variablen in binär Daten kodieren kann [Tea22].

Das Team „Heartbeats“ (Platz 3) entschied sich dafür den INCART Datensatz und Daten, ohne Label für die Wertung zählenden 27 Diagnosen, für das Training ihres Modells nicht zu berücksichtigen. Ebenfalls wurden die Ableitungen: III, aVR, aVL, und aVF ausgeschlossen. Für das Resampling entschieden sie sich für die Taktfrequenz 500HZ, da sie dadurch nur noch den PTB Datensatz resampeln mussten.

Zusätzlich haben sie festgestellt, dass der CPSC-Datensatz nur neun der 27 Diagnosen beinhalten, wobei die Verteilung der Diagnosen sich auch von den der anderen Datensätzen unterscheidet. Dadurch haben sie sich entschieden den Datensatz zu „relabeln“, das bedeutet die Daten neu mit Labels zu versehen. Im Konkreten, haben sie ein Basis-Modell mit dem originalen Trainingsdatensatz trainiert und den genutzt um den CPSC Datensatz zu klassifizieren. Danach haben sie die Diagnosen, für die ihr Modell eine Wahrscheinlichkeit von mind. 80% ausgegeben hat, zu den Labels der Daten hinzugefügt.

Des Weiteren haben sie ebenfalls eine feste Sequenzlänge bestimmt. Für das Basis-Modell wurden die ersten dreißig Sekunden der Signaldaten betrachtet. Für das erweiterte Modell wurde auf die ersten zehn Sekunden verkürzt. Dabei gilt bei beiden Modellen, dass bei kürzeren Signallängen zero-padding angewendet wurde und längere wurden geschnitten (truncating). Um die Signaldaten zu filtern, wurde eine „biorthogonale Wavelet-Transformation“ verwendet. (vgl. [Zhu+20])

„Triage“, das Team auf dem vierten Platz, hat neben bereits erwähnten Methoden, die Daten mit Mittelwert null und Varianz gleich eins normalisiert (z-Transformation). Zusätzlich haben sie die Daten mit der arctan Funktion transformiert, um die Ausschläge der R-Zacke zu verkleinern.

Außerdem haben sie sich auf Grund des Bewertungssystem, welches in Kapitel 3.1.3 näher beschrieben wurde, dazu entschieden mehrere Klassen zusammenzuführen. Dadurch hatten sie nur noch 24 Klassen zu klassifizieren. [Opp+20]

Die fünft Platzierten verfolgten im Gegensatz zu den bisherigen Teams ein anderes Ziel mit ihrer Datenaufbereitung. Ihr Ziel ist es gewesen die Daten diverser zu machen und damit eine Art Pseudo-Vermehrung (data augmentation) zu erlangen. Hierfür wurden folgende Datenbearbeitungsschritte zufällig auf Daten angewandt: das Ersetzen von einzelnen Ableitungen mit entweder einem Nullsignal oder einem niederfrequentem Signal, die Vertauschung von zwei oder mehreren Ableitungen, das Nutzen eines Bandpassfilters, die Skalierung des Signals oder das zufällige Verschieben durch das Anhängen eines Versatzes. Außerdem hatten sie eine feste Signallänge, die sie in ihrem Modell verarbeitet haben. Jedoch wurden längere Signale zufällig passend geschnitten oder stärker

gekürzt. Die stärker Gekürzten wurden, wie original kürzere Signale, zufällig aufgefüllt. (vgl. [HBS20])

Dagegen haben die Teams, die sich auf den letzten Plätzen befinden, teilweise ähnliche, aber auch teilweise andere Methoden verwendet.

„Cordi-Ak“ das Team auf Platz 37 von 41 hat aus den Daten drei Teile segmentiert: Beginn, Mitte und Ende des Datensignals (vgl. [IBM20])

Das am schlechtesten platzierte Team hat einige Schritte angewendet, die bisher nicht aufgeführt wurden.

Sie haben eine Überprüfung durchgeführt, ob zwei Elektroden vertauscht wurden und entsprechend korrigiert. Außerdem haben sie eine Überprüfung der Signalqualität durchgeführt. So wurden Daten mit schlechter Signalqualität aussortiert.

Des Weiteren haben sie neben Bandpassfilter auch zwei Kerbfilter eingesetzt, bei einer Frequenz von 50HZ und 60HZ.

Als Letztes haben sie die Aufzeichnungen des INCART Datensatzes in zehn-sekündige Sequenzen aufgeteilt und als unabhängige EKG-Aufzeichnungen behandelt. (vgl. [Ass+20])

Platz	Testset Ergebnis	Methoden	Referenz
1.	0.533	Resampling auf 500HZ, feste Sequenzlänge (15s.), zero-padding, Normalisierung, Bandpassfilter (3-45HZ)	[Nat+20]
2.	0.520	Resampling auf 257HZ, feste Sequenzlänge (ca. 16s.), zero-padding und truncating, One-hot Kodierung von Alter und Geschlecht	[Zha+20]
3.	0.514	Resampling auf 500HZ, feste Sequenzlänge (30s.), zero-padding und truncating, Relabelling, Singal-Filterung (Wavelet-Transformation), Auslassung von Daten: INCART, Daten ohne relevante Labels und einige Ableitungen	[Zhu+20]
4.	0.485	Resampling auf 500HZ, feste Sequenzlänge (20,48s.), Klassenvereinigung, data augmentation, z-score Normalisierung, Singal-Filterung (Transformation mit arctan), Auslassung von Daten: Daten ohne relevante Labels	[Opp+20]
5.	0.437	Resampling auf 250HZ, feste Sequenzlänge, Normalisierung zufälliges padding, data augmentation, Auslassung von Daten: Daten ohne relevante Labels	[HBS20]
37.	0.485	Segmentierung in drei Teilen (je 1800 Datenpunkte)	[IBM20]
38.	0.485	Resampling auf 50HZ, 100Z oder 150HZ, feste Sequenzlänge(3000 Datenpunkte), zero-padding oder Signalwiederholung und truncating Auslassung von Daten: Daten ohne relevante Labels	[Sal+20]
40.	0.485	Resampling auf 500HZ, feste Sequenzlänge (≤ 1 min.), Bandpassfilter (0,67-30HZ)	[BRS20]
41.	0.485	Resampling auf 500HZ, Bandpassfilter (0,13-88HZ), Zwei Kerbfilter (bei 50 bzw. 60HZ), Klassenvereinigung, Validation der Elektrodenanordnung, Aufspaltung der Daten aus INCART, Auslassung von Daten: Daten ohne relevante Labels und Daten mit niedriger Signalqualität	[Ass+20]

Tabelle 3.9: Übersicht der verwendeten Methoden zur Datenaufbereitung.

Die verwendeten Methoden zur Datenaufbereitung, der bisher erwähnten und weiterer Teilnehmer wurden in Tabelle 3.9 zusammengefasst.

2021

Die Methoden der Datenaufbereitung im Jahre 2021 unterscheiden sich nicht großartig von denen aus dem Vorjahr. Die verwendeten Methoden sind u.a. resampling, Normalisierung, Filterung, Rauschreduktion und Verwerfung von Daten. (vgl. [Rey+22])

Es wurden verschiedene Arten von Normalisierungen verwendet, u.a. z-score Normalisierung oder Min-Max Normalisierung. (vgl. [Rey+22])

Einer der am häufigsten verwendeten Methoden, welche von 64% der Teilnehmer verwendet wurde, ist die Signalfilterung. Dabei wurden, wie auch in 2020 verschiedene Arten von Bandpassfiltern verwendet. (vgl. [Rey+22])

Des Weiteren wurden von Einigen die Signalqualität überprüft oder auch data augmentation angewendet. (vgl. [Rey+22])

Viele Teams, die in der oberen Hälfte der Rangliste abgeschnitten haben, verwendeten wie in 2020 feste Signallängen, um die Signale zu segmentieren. (vgl. [Rey+22])

Dagegen hat keiner der besten Teams ganze Datensätze ausgelassen. (vgl. [Rey+22])

Eine detailliertere Auflistung der verwendeten Methoden je Team findet sich in [Rey+22, Tab. A1].

3.3.2 Methoden

In diesen Unterkapitel soll es darum gehen, welche Arten der Künstlichen Intelligenz (vgl. 1.2.2) in den Jahren der Challenges Anwendung gefunden haben. Hierbei werden die Jahre nicht differenziert, sondern zusammen betrachtet.

Die häufigsten Ansätze der Teilnehmer sind basierend auf Deep Learning Methoden, insbesondere Konvolutionale Neuronale Netze generell und Residuale Neuronale Netze (ResNet) im Spezifischen. (vgl. [Ald+20; Rey+22])

Ein ResNet ist eine Spezialisierung des KNN und löst das Problem, dass ab einer gewissen Tiefe eines NN der Lernerfolg geringer wird. Darüber hinaus ist es möglich, dass durch eine zu hohe Tiefe des NN die Ergebnisse schlechter werden. Dieses Problem wird durch das Phänomen „Vanishing Gradient“ beschrieben. (vgl. [Mül21; Höf22])

Was in 2020 beliebt war, aber in 2021 abgenommen hatte, waren klassische Klassifizierungsverfahren so wie: „Random Forest“, „Support Vector Machine“ und „Gradient Boosting“ und oberflächliche, also nicht tiefe neuronale Netze (shallow neural networks). Diese wurden meistens in Zusammenhang mit selbst erstellten Merkmalen („hand-crafted features“) genutzt. (vgl. [Ald+20; Rey+21])

Darunter versteht man das Extrahieren von Merkmalen aus den gegebenen Daten mit Hilfe von beliebigen Algorithmen bzw. Verfahren. So haben zum Beispiel [Váz+21]

Merkmale, wie die Amplitude der P- oder T-Welle oder auch das PR-Intervall, aus den EKG-Daten extrahiert.

Ein weiterer Zusammenhang mit hand-crafted features ergab sich besonders im Jahr 2021, indem sich Teilnehmer dieser bedienten, um ihre deep Learning Modelle robuster zu gestalten. Robustheit bezieht sich hierbei darauf, wie das Modell mit Eingabedaten umgehen kann, das heißt ein robustes System kann auch mit Ausreißern zurecht kommen. (vgl. [Rey+22])

Ansonsten spielt die Verlustfunktion im Kontext von neuronalen Netzen eine Rolle. Eine Verlustfunktion gibt an, wie „gut“ die Ergebnisse, also die Ausgabe, eines neuronalen Netzes sind. Dafür wird die Ausgabe in ein Verhältnis zu den Zielwerten gesetzt. Hierbei gilt je höher der Wert der Verlustfunktion, desto schlechter die Vorhersage durch das neuronale Netz. Die Verlustfunktion wird zum Trainieren des Netzes verwendet, mit dem Ziel die Funktionswerte zu minimieren. (vgl. [La 19; Bro19])

Die am häufigsten verwendete Verlustfunktion im Jahre 2021 ist der Log-Verlust (engl. Binary Cross Entropy loss/Log Loss) Funktion gewesen, die von beinahe ein Drittel der offiziellen Teilnehmer verwendet wurde. Dennoch haben auch von den Teilnehmern benutzerdefinierte Funktionen Anwendung gefunden. (vgl. [Rey+21])

Zu guter Letzt wird kurz auf die zwei besten Teams eingegangen.

Das Team auf dem ersten Platz „ISIBrno-AIMT“ ([Nej+21]) nutzte ein benutzerdefiniertes ResNet Modell mit einer Mischung von mehreren Verlust-Funktionen. Die Mischung besteht aus der Log-Verlust Funktion, eine benutzerdefinierte Verlust Funktion, um die Challenge Bewertung zu approximieren und eine Verlust Funktion auf Grundlage von einem evolutionären Algorithmus, um die Wahrscheinlichkeit der richtigen Vorhersage für jede Klasse zu optimieren. (vgl. [Rey+22])

Die zweit Platzierten „DSAIL_SNU“ ([Par+21]) nutzten eine Modifikation des ResNet, das „Wide Residual Network“, welches erstmals von [ZK16] vorgestellt wurde. Zusätzlich nutzten sie ein „Squeeze and Excitation“-Block (SE-Block) nach [Hu+17]. Diese beiden Architekturen übersteigen die Komplexität dieser Arbeit, da für sie ein tieferes Verständnis neuronaler Netzwerke erforderlich ist. Ich wollte sie dennoch anführen, da sie Teil des momentanen Stands der Technik sind.

3.4 Ergebnisse

In diesem Unterkapitel geht es darum, die Ergebnisse der Challenges zusammen zu tragen.

Insgesamt erzielten die Siegerteams aus dem Jahr 2020 bzw. 2021, das Ergebnis 0,53 bzw. 0,58, nach der in 3.1.3 vorgestellten Bewertungsmetrik (vgl. [Phy20; Phy21]). Wobei der Wert für das Jahr 2021, gemittelt wurde über die Leistung aller Ableitungskombinationen (vgl. [Rey+21]).

Eine relevante Erkenntnis, ist die Wichtigkeit der Datenaufbereitung. Die Sieger der Challenge im Jahr 2021, haben auch im Vorjahr teilgenommen. Nach eigenen Aussagen haben sie im Jahr 2021 ihre Schritte zur Datenaufbereitung verbessert und die Vermutung aufgestellt, dass vor allem die Signalfilterung mittels eines Bandpassfilters ihre Ergebnisse stark verbessert hat. (vgl. [Nej+21])

Des Weiteren zeigte sich im Jahr 2020 ein deutlicher Leistungsverlust (siehe [Ald+20, Fig. 3]) der Algorithmen in der Anwendung auf den nicht veröffentlichten Datensätzen. Das verdeutlicht einerseits, wie wichtig es ist verschiedene Datensätze zu betrachten und andererseits, dass darauf zu achten ist, dass die Algorithmen sich nicht zu sehr für einen bestimmten Datensatz spezialisieren. (vgl. [Ald+20])

Dasselbe Phänomen ließ sich auch im Jahr 2021 beobachten (siehe [Rey+22, Fig. 6]).

Außerdem gilt für beide Jahre, dass die Nutzung von Algorithmen aus anderen Anwendungen kein guter Ansatz gewesen ist, da diese nicht besser als benutzerdefinierte ML-Algorithmen abschneiden. ([Rey+22; Ald+20])

Schließlich hatte die Challenge im Jahre 2021 im Gegensatz zu der Challenge im Jahre 2020, eine Frage in ihrer Aufgabenstellung (vgl Kap. 2.1) „Will two do?“ und diese Frage konnten von mehreren Teams, so wie von den Aufgabestellenden schließlich mit „Ja“ beantwortet werden. Das ergibt sich daraus, dass alle Teams ähnliche Ergebnisse auf allen Ableitungskombinationen erzielt haben (siehe [Rey+22, Fig. 6]). Die mittlere Abweichung der Bewertungsmetrik beläuft sich auf weniger als 2%. (vgl. [Rey+22; Váz+21])

4 Schlusswort

4.1 Diskussion

Ein Aspekt, der bisher nicht angesprochen wurde ist, dass eine Verzerrung (Bias) in den Datensätzen die Leistung der Modelle beeinträchtigen können. Eine Verzerrung könnte in dem Kontext, beispielsweise durch Fehler der medizinischen Geräte entstehen, die zur Aufnahme der EKG verwendet werden oder durch ungenaue oder falsche Platzierung von Elektroden auf dem Körper entstehen. (vgl. [HSI22b; Kli+07])

Ein weiteres Problem ist, dass die Genetik und Ethnie einen Einfluss auf das EKG haben können (vgl. Kap. 2.1.2), welche nicht in den Datensätzen definiert sind. Daher ist es durchaus wahrscheinlich, dass die Modelle unterschiedlichen Leistungen zeigen, für die Variationen dieser Eigenschaften. (vgl. [Rey+22])

Zu guter Letzt ist für die klinische Praxis wichtig, dass die Entscheidungen der KI nachvollziehbar gestaltet sind, wie dies umgesetzt wird, wird sich in der Zukunft zeigen. (vgl. [HSI22a; HSI22b])

4.2 Fazit

Abschließend kann man sagen, dass die KI bereits gute Ergebnisse für die Klassifizierung von Herzkrankheiten erzielt. Darüber hinaus hat die KI das Potential für neue Erkenntnisse zu sorgen, wie in der CinC Challenge 2021. (vgl. [Ald+20; Rey+22])

Jedoch ist die KI nicht zuverlässig genug, um einen Arzt zu ersetzen. Im Gegenteil es ist wichtig und empfohlen, dass die Ergebnisse von einem Arzt bewertet und in einem klinischen Kontext gesetzt werden. (vgl. [HSI22b; Kli+07])

Insgesamt kann man sagen, dass die KI als Werkzeug für Ärzte in der Zukunft vielversprechend sein sollte. Und persönlich bin ich gespannt darauf, wie Innovationen im Bereich der KI, das Gebiet der Medizin in den nächsten Jahren beeinflussen wird.

A CinC Challenge

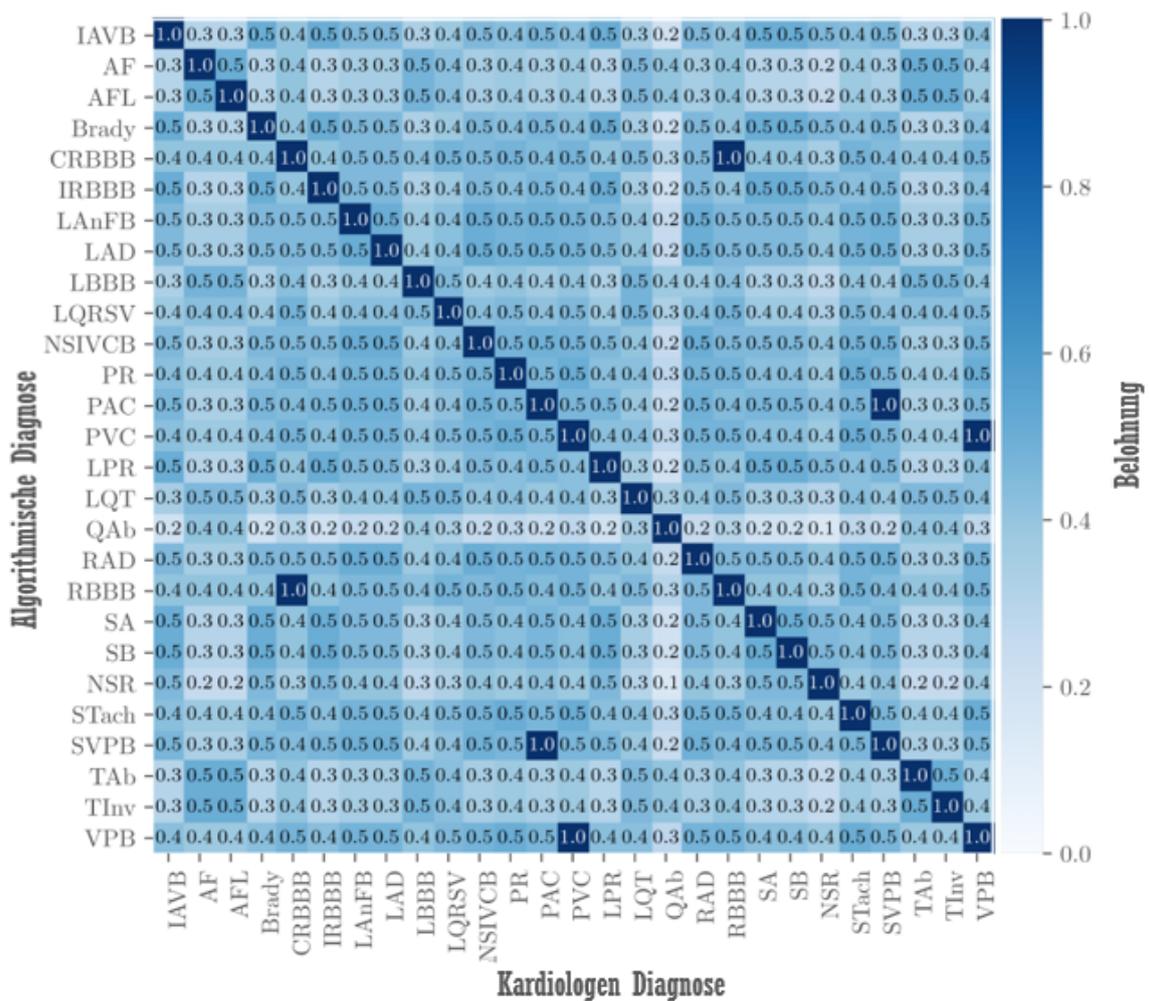


Abbildung A.1: Die Rewardmatrix aus dem Jahr 2020. (übersetzt aus [Ald+20])

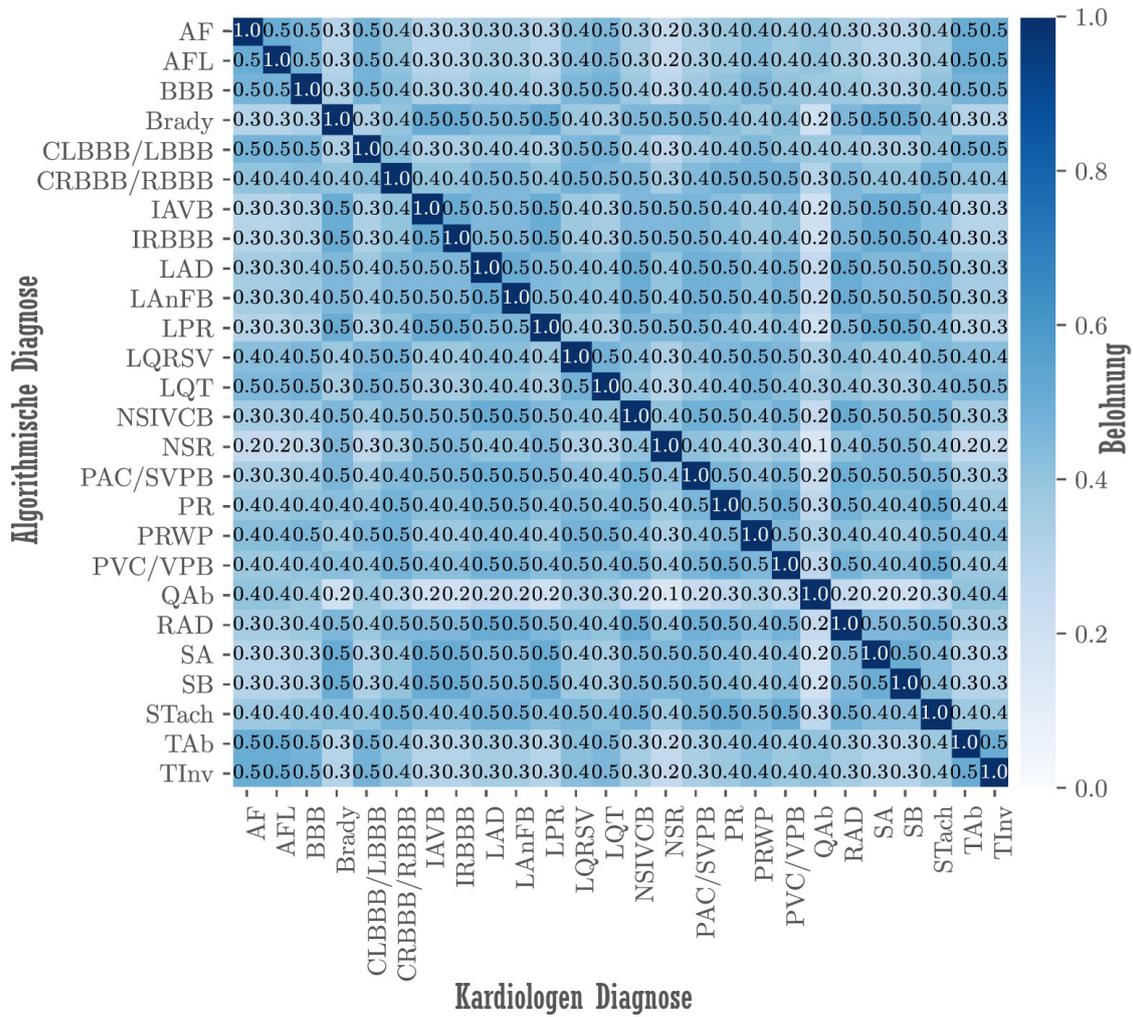


Abbildung A.2: Die Rewardmatrix aus dem Jahr 2021. (übersetzt aus [Rey+21])

Literatur

- [Ald+20] E. A. Alday E A P et al. „Classification of 12-lead ECGs: the PhysioNet/Computing in Cardiology Challenge 2020“. In: *Physiological Measurement* 41 (2020).
- [Ant+22] Frank Antwerpes et al. *Elektrokardiogramm*. DocCheck Flexicon. Sep. 2022. URL: <https://flexicon.doccheck.com/de/Elektrokardiogramm> (besucht am 05. 12. 2022).
- [Ass+20] David Assaraf et al. „Classification of 12-lead ECGs using digital biomarkers and representation learning“. In: *2020 Computing in Cardiology Conference (CinC)*. Computing in Cardiology, 2020.
- [Bay+21] A. Bayés De Luna et al. *Clinical Electrocardiography*. John Wiley & Sons, Ltd, 2021.
- [BKS95] R. Bousseljot, D. Kreiseler und A. Schnabel. „Nutzung der EKG-Signaldatenbank CARDIODAT der PTB über das Internet“. In: *Biomedizinische Technik/Biomedical Engineering* (1995), S. 317–318.
- [Bro19] Jason Brownlee. *Loss and Loss Functions for Training Deep Learning Neural Networks*. 2019. URL: <https://machinelearningmastery.com/loss-and-loss-functions-for-training-deep-learning-neural-networks/> (besucht am 20. 12. 2022).
- [BRS20] Matteo Bodini, Massimo W Rivolta und Roberto Sassi. „Classification of 12-lead ECG With an Ensemble Machine Learning Approach“. In: *2020 Computing in Cardiology Conference (CinC)*. Computing in Cardiology, 2020.
- [Cad] Mike Cadogan. URL: <https://litfl.com/ecg-lead-positioning/> (besucht am 07. 12. 2022).
- [Car] CardioSecur. *Ableitungssysteme von EKGs*. URL: <https://www.cardiosecur.com/de/ihr-herz/fachartikel-rund-um-das-herz/ableitungssysteme-von-ekgs> (besucht am 07. 12. 2022).
- [Cin] Cinc. *The PhysioNet/CinC Challenge*. URL: <https://cinc.org/physionet-cinc-challenge-awards/> (besucht am 09. 12. 2022).

- [Des22] Statistisches Bundesamt (Destatis). *Gestorbene: Deutschland, Jahre, Todesursachen, Geschlecht*. 2022. URL: <https://www-genesis.destatis.de/genesis/online?sequenz=tabelleErgebnis&selectionname=23211-0002> (besucht am 23. 12. 2022).
- [Don21] Artem Dontsov. *Was sind Neuronale Netze und warum sind sie so wichtig?* 2021. URL: <https://nativdigital.com/neuronale-netze/> (besucht am 23. 12. 2022).
- [Ger08] Marc Gertsch. *Das EKG. Auf einem Blick und im Detail*. Springer, 2008.
- [Gol+00] A. Goldberger et al. „PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals“. In: *Circulation* 101.23 (Juni 2000).
- [HBS20] Hosein Hasani, Adeleh Bitarafan und Mahdih Soleymani. „Classification of 12-lead ECG Signals With Adversarial Multi-Source Domain Generalization“. In: *2020 Computing in Cardiology Conference (CinC)*. Computing in Cardiology, 2020.
- [Höf22] Jürgen Höfling. *Was ist ResNet50?* 2022. URL: <https://www.datacenter-insider.de/was-ist-resnet50-a-1107209/> (besucht am 20. 12. 2022).
- [HSI22a] W. Haverkamp, N. Strodthoff und Israel. „EKG-Diagnostik mithilfe künstlicher Intelligenz: aktueller Stand und zukünftige Perspektiven – Teil 1“. In: *Herzschrittmachertherapie + Elektrophysiologie*. Bd. 33. 2022, S. 232–240.
- [HSI22b] W. Haverkamp, N. Strodthoff und Israel. „EKG-Diagnostik mithilfe künstlicher Intelligenz: aktueller Stand und zukünftige Perspektiven – Teil 2“. In: *Herzschrittmachertherapie + Elektrophysiologie*. Bd. 33. 2022, S. 305–311.
- [Hu+17] Jie Hu et al. *Squeeze-and-Excitation Networks*. 2017.
- [IBM20] Paul Samuel Ignacio, Jay-Anne Bulauan und John Rick Manzanares. „A Topology Informed Random Forest Classifier for ECG Classification“. In: *2020 Computing in Cardiology Conference (CinC)*. Computing in Cardiology, 2020.
- [Kli+07] P Klingfield et al. „Recommendations for the Standardization and Interpretation of the Electrocardiogram“. In: *Circulation*. Bd. 115. Lippincott Williams & Wilkins, 2007, S. 1306–1324.
- [Kli+10] R Klinke et al. „5 Das Herz“. In: *Physiologie*. Bd. 6. Georg Thieme Verlag, 2010.

-
- [Kom15] Komoluna. 2015. URL: https://wiki.delphigl.com/index.php/Datei:ArtificialNeuronModel_deutsch.png (besucht am 23.12.2022).
- [Kün19] Ronald Künneth. *Künstliche Intelligenz – Maschinen lernen nie aus*. 2019. URL: <https://www.automation-valley.de/2019/03/13/ki-maschinen-lernen-nie-aus/> (besucht am 22.12.2022).
- [La 19] Frank La Vigne. *Wie lernen neuronale Netze?* 2019. URL: <https://learn.microsoft.com/de-de/archive/msdn-magazine/2019/april/artificially-intelligent-how-do-neural-networks-learn> (besucht am 20.12.2022).
- [Liu+18] Feifei Liu et al. „An Open Access Database for Evaluating the Algorithms of Electrocardiogram Rhythm and Morphology Abnormality Detection“. In: *Journal of Medical Imaging and Health Informatics* 8.7 (2018), S. 1368–1373.
- [Med21] Medpertise. *EKG*. 2021. URL: <https://www.medpertise.de/ekg/> (besucht am 20.12.2022).
- [Mei18] A. Meier. „Was heißt Big Data?“ In: *essentials. Werkzeuge der digitalen Wirtschaft: Big Data, NoSQL & Co*. Springer, 2018.
- [ML19] Michael Matzer und Nico Litzel. *Data Preparation. Datenaufbereitung ist ein unterschätzter Prozess*. März 2019.
- [MLe21] MLee. *Visual Guide to the Confusion Matrix*. 2021. URL: <https://towardsdatascience.com/visual-guide-to-the-confusion-matrix-bb63730c8eba> (besucht am 22.12.2022).
- [Mül21] Stephan Müller. *Car Model Classification I: Transfer Learning mit ResNet*. 2021. URL: <https://www.statworx.com/content-hub/blog/car-model-classification-1-transfer-learning-mit-resnet/> (besucht am 20.12.2022).
- [Nat+20] Annamalai Natarajan et al. „A Wide and Deep Transformer Neural Network for 12-Lead ECG Classification“. In: *2020 Computing in Cardiology Conference (CinC)*. Bd. 47. Computing in Cardiology, 2020.
- [Nej+21] Petr Nejedly et al. „Classification of ECG Using Ensemble of Residual CNNs with Attention Mechanism“. In: *2021 Computing in Cardiology Conference (CinC)*. Computing in Cardiology, 2021.

- [Nog] Jordi March i Nogué. URL: https://dccdn.de/www.doccheck.com/data/vj/fh/xm/s6/pj/3w/2000px-precordialleads2-svg-kopie_1g.jpg (besucht am 21. 12. 2022).
- [Opp+20] Maximilian Oppelt et al. „Combining Scatter Transform and Deep Neural Networks for Multilabel ECG Signal Classification“. In: *2020 Computing in Cardiology Conference (CinC)*. Computing in Cardiology, 2020.
- [Par+21] Sangha Park et al. „Towards High Generalization Performance on Electrocardiogram Classification“. In: *2021 Computing in Cardiology Conference (CinC)*. Computing in Cardiology, 2021.
- [Phy20] CinC PhysioNet. *PhysioNet/CinC Challenge 2020 Results*. 2020. URL: <https://moody-challenge.physionet.org/2020/results/> (besucht am 13. 12. 2022).
- [Phy21] CinC PhysioNet. *PhysioNet/CinC Challenge 2020 Results*. 2021. URL: <https://moody-challenge.physionet.org/2021/results/> (besucht am 13. 12. 2022).
- [Red20] Redaktion. *Elektrokardiographie*. Öffentliches Gesundheitsportal Österreichs. Juli 2020. URL: <https://www.gesundheit.gv.at/labor/untersuchungen/funktionsdiagnostik/ekg.html> (besucht am 05. 12. 2022).
- [Rei+16] T Reichlin et al. „Advanced ECG in 2016: is there more than just a tracing?“ In: *Swiss Medical Weekly* (2016).
- [Rey+21] Matthew A Reyna et al. „Will Two Do? Varying Dimensions in Electrocardiography: The PhysioNet/Computing in Cardiology Challenge 2021“. In: *2021 Computing in Cardiology (CinC)*. Bd. 48. 2021, S. 1–4.
- [Rey+22] Matthew Reyna et al. „Issues in the automated classification of multilead ecgs using heterogeneous labels and populations“. In: *Physiological Measurement*. Bd. 43. IOP Publishing, Aug. 2022.
- [Sal+20] Marwen Sallem et al. „Detection of Cardiac Arrhythmias From Varied Length Multichannel Electrocardiogram Recordings Using Deep Convolutional Neural Networks“. In: *2020 Computing in Cardiology Conference (CinC)*. Computing in Cardiology, 2020.
- [SLH11] Robert F Schmidt, Florian Lang und Manfred Heckmann. „VI Herz und Kreislauf“. In: *Physiologie des Menschen. Mit Pathophysiologie*. 2011.

-
- [Stu] Studyflix. *Neuronale Netze*. URL: <https://studyflix.de/informatik/neuronale-netze-4297> (besucht am 23. 12. 2022).
- [Tab+22] Mark Tabladillo et al. Nov. 2022. URL: <https://learn.microsoft.com/de-de/azure/architecture/data-science-process/lifecycle> (besucht am 13. 12. 2022).
- [Tea22] Data Science Team. *Maschinelles Lernen. One Hot Encoding*. 2022. URL: <https://datascience.eu/de/maschinelles-lernen/one-hot-encoding/> (besucht am 15. 12. 2022).
- [Tih+08] Viktor Tihonenko et al. *St.-Petersburg Institute of Cardiological Technics 12-lead Arrhythmia Database*. 2008. URL: <https://physionet.org/content/incartdb/>.
- [uda] udaix. URL: <https://www.shutterstock.com/g/udaix> (besucht am 20. 12. 2022).
- [Váz+21] Cristina Gallego Vázquez et al. „Two Will Do: CNN With Asymmetric Loss, Self-Learning Label Correction, and Hand-Crafted Features for Imbalanced Multi-Label ECG Data Classification“. In: *2021 Computing in Cardiology Conference (CinC)*. Computing in Cardiology, 2021.
- [Wag+20] Patrick Wagner et al. „PTB-XL, a large publicly available electrocardiography dataset“. In: *Scientific Data* 7.1 (2020).
- [WEG19] WEGOFIVE. *Was sind „Convolutional Neural Networks“ (CNN)?* 2019. URL: <https://www.wegofive.net/2019/01/29/was-sind-convolutional-neural-networks-cnn/> (besucht am 23. 12. 2022).
- [WHO21] WHO. *Cardiovascular diseases (CVDs)*. 2021. URL: [https://www.who.int/en/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/en/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds)) (besucht am 02. 12. 2022).
- [Zha+20] Zhibin Zhao et al. „Adaptive lead weighted ResNet trained with different duration signals for classifying 12-lead ECGs“. In: *2020 Computing in Cardiology Conference (CinC)*. Computing in Cardiology, 2020.
- [Zhe+20a] Jianwei Zheng et al. „A 12-lead electrocardiogram database for arrhythmia research covering more than 10,000 patients“. In: *Scientific Data* 7.1 (2020).
- [Zhe+20b] Jianwei Zheng et al. „Optimal Multi-Stage Arrhythmia Classification Approach“. In: *Scientific Reports* 10.1 (2020).

- [Zhu+20] Zhaowei Zhu et al. „Classification of Cardiac Abnormalities From ECG Signals Using SE-ResNet“. In: *2020 Computing in Cardiology Conference (CinC)*. Computing in Cardiology, Dez. 2020.
- [ZK16] Sergey Zagoruyko und Nikos Komodakis. *Wide Residual Networks*. 2016.