

Unterstützung des Prozesses der Ernährungsberatung für hochaltrige Personen, die vom
geriatrischen Frailty-Syndrom betroffen sind, mit Hilfe von Technik und Digitalisierung

.....

Von der Fakultät für Medizin und Gesundheitswissenschaften der Carl von Ossietzky Universität
Oldenburg zur Erlangung des Grades und Titels eines

Doktors der Ingenieurwissenschaften (Dr.-Ing.)

.....

angenommene Dissertation

von Herrn Elfert, Patrick

geboren am 26.09.1985 in Cloppenburg

Gutachter

Prof. Dr.-Ing. Andreas Hein

Weitere Gutachter

Prof. Dr. rer. medic. Norbert Rösch

Tag der Disputation

2. Februar 2024

Danksagung

An dieser Stelle möchte ich mich zunächst bei Prof. Dr.-Ing. Andreas Hein und Prof. Dr. Norbert Rösch für das entgegen gebrachte Vertrauen sowie für die wissenschaftliche Betreuung meiner Arbeit bedanken. Insbesondere die zahlreichen Gespräche mit Prof. Hein haben dazu beigetragen, Herausforderungen immer wieder aus einem neuen Blickwinkel zu betrachten und dadurch oft sehr pragmatisch lösen zu können.

Weiterhin möchte ich mich bei allen Kolleg:innen bedanken, mit denen ich zahlreiche interdisziplinäre Gespräche führen durfte und von deren Wissen ich profitieren konnte. Hier möchte ich insbesondere Dr. rer. nat. Marco Eichelberg, Dr.-Ing. Frerk Müller-von Aschwege, Dr. oec. troph. Rebecca Diekmann und Frau Julia Berndt nennen. Weiterhin möchte ich mich bei allen Studierenden bedanken, die mir z. B. in Form von Abschlussarbeiten zugearbeitet haben. Nennen möchte ich hier Henning Sander, Enes Tiryaki, Simon Siggelkow, Torben Logemann, Mathias Steger sowie Svenja Schuirmann. Zudem möchte ich in dieser Danksagung das Bundesministerium für Bildung und Forschung und von diesem geförderte Projekt DiDiER (Förderkennzeichen 02K14A150) nennen, da diese Arbeit in Teilen von diesem finanziert wurde.

Darüber hinaus möchte ich meinen Freunden und vor allem meiner Familie meine tiefe Dankbarkeit und Wertschätzung aussprechen. Sie haben Rückschläge mit mir gemeistert, Selbstzweifel beseitigt, mir die notwendigen Freiräume gewährt und mich durch ihr unerschütterliches Vertrauen immer wieder motiviert.

Patrick Elfert

Abstract

The high pace of innovation in medicine, care as well as in the technology sector is leading to enormous progress and constantly evolving diagnostic and therapeutic procedures. These in turn lead to significant improvements in the health care system and thus to a higher life expectancy. Therefore, these developments support all our efforts to live as long, healthy and independently as possible.

However, the geriatric frailty syndrome, the prevalence of which increases with age, stands in the way of these aspirations. The syndrome is characterised by diminished individual reserves in the face of internal and external stressors and is often accompanied by reduced physical strength and activity, general fatigue and unintentional weight loss. This increases the likelihood of comorbidity and mortality.

Nutritional counselling or therapy is often used to record and adjust the consumption behaviour of affected persons, as they are frequently affected by malnutrition and the course of the frailty syndrome can be positively influenced by adjusting this consumption behaviour. Despite the speed of innovation mentioned above, relevant data on current consumption behaviour, physical activity, body composition, but also on the faeces of affected persons are collected retrospectively in personal interviews using paper.

However, such a survey is subject to various influencing factors and limitations, e.g. cognitive limitations, small amounts of data or inaccurate statements due to shame. Therefore, the question arises: *„In what ways can technology and digitization be used to enable very elderly people affected by frailty syndrome to independently gather relevant*

information for nutritional counseling?” For this purpose, two digital food diaries were developed to show that by adapting the software to the needs of the people concerned, it is possible to enable them to record their consumption behaviour independently despite their limitations. Within the scope of two studies, the System Usability Scale (SUS) of the diaries was assessed. These were able to confirm the hypothesis mentioned with corresponding results (DND v1: SUS: 51.66 ± 11.93 and v2: SUS: 76.40 ± 11.90). Also examined in these studies were an activity tracker and a body composition scale. The results of the body composition scale (SUS: 29.79 ± 8.42) show that a single function can make this technology unsuitable for the target group. The results of the activity tracker (SUS: 82.50 ± 5.54), on the other hand, show that in particular an ambient and, if possible, automated data collection is best suitable to achieve a high usability for the target group.

On the basis of the above findings, the second part of this work investigated: *„Which technical aids can be used to further simplify the keeping of a digital nutrition diary for the very elderly people affected by the frailty syndrome?”* The AI-based, interactive, dynamic and interview-like input method developed here, was also evaluated in two studies. Due to the prevailing COVID-19 pandemic at the time of the studies, they could not be conducted with test persons from the target group. However, the results show that this method, which is integrated into the digital food diary, provides good results (assisted DND v1: SUS: 85.83 ± 8.03 and v2: SUS: 89.67 ± 8.98).

Even an adapted diet can only be effective if the necessary micro- and macronutrients are absorbed by the body. This is often not the case with the addressed target group. The form of the faeces, the stool form, can provide important information in this regard. Since current methods can be influenced by factors such as cognitive performance, shame, concealment by sanitary products and the physical set-up of sanitary facilities, the third part of this paper examines the question: *„What technical means can be used to achieve automated classification of stool forms to replace manual image acquisition and verbal description?”* Therefore, a method was developed which records faeces orthogonally to the direction of fall with the help of cameras. The results of the general feasibility studies carried out under laboratory conditions show that classification, based on the Bristol Stool Form Scale (BSFS), is possible using artificial intelligence. With a Convolutional Neural Network (CNN), an accuracy of 93.46 % could be achieved here on RGB images.

Overall, this work shows different approaches and methods on how technologies can be adapted to make them more accessible for the target group of elderly people affected by geriatric frailty syndrome.

Zusammenfassung

Das hohe Innovationstempo in der Medizin, der Pflege sowie im Technologiesektor führt zu enormen Fortschritten und sich ständig weiterentwickelnden Diagnose- und Therapieverfahren. Diese wiederum bewirken signifikante Verbesserungen in der Gesundheitsversorgung und damit auch eine höhere Lebenserwartung. Entsprechend unterstützen diese Entwicklungen unser aller Bestreben, ein möglichst langes, gesundes und selbstbestimmtes Leben zu führen.

Das geriatrische Frailty-Syndrom, dessen Prävalenz mit dem Alter zunimmt, steht diesen Bestrebungen jedoch entgegen. Das Syndrom ist gekennzeichnet durch verminderte individuelle Reserven gegenüber internen und externen Stressoren und geht häufig einher mit verminderter körperlicher Kraft und Aktivität, allgemeiner Erschöpfung und unbeabsichtigtem Gewichtsverlust. Dies erhöht die Wahrscheinlichkeit von Komorbidität und Mortalität.

Ernährungsberatung bzw. -therapie wird häufig zur Erfassung und Anpassung des Verzehrverhaltens der Betroffenen eingesetzt, da diese häufig von Mangelernährung betroffen sind und der Verlauf des Frailty-Syndroms durch eine Anpassung dieses Verzehrverhaltens positiv beeinflusst werden kann. Relevante Daten zum aktuellen Verzehrverhalten, zur körperlichen Aktivität, zur Körperzusammensetzung, aber auch zu den Fäzes der Betroffenen werden trotz der erwähnten Innovationsgeschwindigkeit i. d. R. retrospektiv im persönlichen Gespräch auf Papier erhoben.

Eine derartige Erhebung unterliegt jedoch verschiedenen Einflussfaktoren und Limitationen, z. B. durch kognitive Einschränkungen, geringe Datenmengen oder

Verzerrungen aufgrund von Schamgefühlen. Daher stellt sich die Frage: *„Auf welche Art und Weise lassen sich Technologie und Digitalisierung nutzen, um hochaltrige Personen, die vom Frailty-Syndrom betroffen sind, eine selbstständige Erfassung relevanter Informationen für die Ernährungsberatung zu ermöglichen?“* Zu diesem Zweck wurden zwei digitale Ernährungstagebücher entwickelt, um zu zeigen, dass es durch eine Anpassung der Software an die Bedürfnisse der Betroffenen möglich ist, diese trotz ihrer Einschränkungen in die Lage zu versetzen ihr Verzehrverhalten selbstständig zu protokollieren. Im Rahmen von zwei Studien wurde die Usability (via SUS) der Tagebücher jeweils durch die Zielgruppe bewertet. Diese konnten die genannte Hypothese mit entsprechenden Ergebnissen belegen (DNDv1: SUS: $51,66 \pm 11,93$ und v2: SUS: $76,40 \pm 11,90$). Ebenfalls wurden in diesen Studien ein Aktivitätstracker und eine Körperkompositionswaage untersucht. Die Ergebnisse der Körperkompositionswaage (SUS: $29,79 \pm 8,42$) zeigen, dass eine einzige Funktion diese Technik für die Zielgruppe ungeeignet machen kann. Auf der anderen Seite zeigen die Ergebnisse des Aktivitätstrackers (SUS: $82,50 \pm 5,54$), dass insbesondere eine ambiente und möglichst automatisierte Datenerfassung geeignet ist, um eine hohe Usability für die Zielgruppe zu erreichen.

Auf Basis der genannten Erkenntnisse, wurde im zweiten Teil dieser Arbeit untersucht: *„Mit welchen technischen Hilfsmitteln kann das Führen eines digitalen Ernährungstagebuchs für hochaltrige und vom Frailty-Syndrom betroffene Personen weiter vereinfacht werden?“* Der hier entwickelte KI-basierte, interaktive, dynamische und interviewartige Eingabemodus wurde ebenfalls in zwei Studien evaluiert. Aufgrund der zum Zeitpunkt der Studien vorherrschenden COVID-19 Pandemie, konnten diese jedoch nicht mit Proband:innen aus der Zielgruppe durchgeführt werden. Dies Resultate zeigen jedoch, dass diese in das digitale Ernährungstagebuch integrierte Methode gute Ergebnisse liefert (assisted DND v1: SUS: $85,83 \pm 8,03$ und v2: SUS: $89,67 \pm 8,98$).

Auch eine angepasste Ernährung kann nur dann erfolgreich sein, wenn die notwendigen Mikro- und Makronährstoffe vom Körper aufgenommen werden. Dies ist bei der Zielgruppe oft nicht der Fall. Die Beschaffenheit der Fäzes, bzw. die Stuhlform, kann hier wichtige Informationen liefern. Da die derzeitigen Methoden durch Faktoren wie kognitive Fähigkeiten, Scham, Verdeckung durch Hygieneartikel sowie die physische Gestaltung der sanitären Anlagen beeinflusst werden können, wird im dritten Teil dieser Arbeit der Frage nachgegangen: *„Mit welchen technischen Mitteln kann eine automatisierte Klassifizierung von Stuhlformen erreicht werden, um*

die manuelle Bildaufnahme und die verbale Beschreibung zu ersetzen?“ Hierzu wurde eine Methode entwickelt, welche Fäzes mithilfe von Kameras orthogonal zur Fallrichtung aufnimmt. Die Ergebnisse der unter Laborbedingungen durchgeführten Studien zur generellen Machbarkeit zeigen, dass eine Klassifikation basierend auf der BSFS mittels künstlicher Intelligenz möglich ist. Mit einem CNN konnte hier eine Genauigkeit von 93,46 % auf RGB-Bildmaterial erreicht werden.

Insgesamt zeigt diese Arbeit verschiedene Ansätze und Methoden auf, wie Technologien so angepasst werden können, dass sie auch für die Zielgruppe der hochaltrigen und vom geriatrischen Frailty-Syndrom betroffenen Menschen zugänglicher werden.

Inhaltsverzeichnis

1. Einleitung	1
2. Medizinischer Hintergrund	7
2.1. Frailty-Syndrom	8
2.1.1. Konzepte zur Diagnostik	9
2.1.2. Prävention und Intervention	11
2.2. Ernährungsberatung	13
2.2.1. Allgemeiner Ernährungszustand	13
2.2.2. Verzehr- und Trinkmengenerfassung	16
2.2.3. Fäzes	20
2.2.3.1. Stuhlform	21
2.2.3.2. Färbung	23
2.2.3.3. Konsistenz	23
2.2.3.4. Volumen	24
2.3. Zusammenfassung und Fazit	24
3. Stand der Technik	27
3.1. Datenerfassung	28
3.1.1. Digitalkameras	29
3.1.2. Tiefenerkennung	30
3.1.2.1. Stereoskopie	31
3.1.2.2. Structured-Light	33
3.1.2.3. Time-of-Flight	34
3.1.2.4. Darstellung	35

3.1.3.	Aktivitätstracker	36
3.1.4.	Körperkompositionswaagen	41
3.2.	Datenverarbeitung	42
3.2.1.	Bildverarbeitung	43
3.2.2.	Künstliche Intelligenz	44
3.2.2.1.	Support Vector Machines	45
3.2.2.2.	Künstliche Neuronale Netzwerke	47
3.2.2.3.	Tiefe neuronale Netzwerke	48
3.2.2.4.	Convolutional Neural Networks	48
3.3.	Verwandte Arbeiten	54
3.4.	Zusammenfassung und Fazit	61
4.	Eigene Ansätze	65
4.1.	Digitales Ernährungstagebuch und Sensorik	66
4.1.1.	Methoden	67
4.1.2.	Implementierung DNDv1	68
4.1.3.	Sensorik	70
4.1.4.	Studiensetting DNDv1	70
4.1.5.	Ergebnisse DNDv1	73
4.1.6.	Diskussion	75
4.1.7.	Implementierung DNDv2	77
4.1.8.	Studiensetting DNDv2	81
4.1.9.	Ergebnisse DNDv2	82
4.1.10.	Diskussion und Fazit	88
4.2.	Automatisierte Verzehrsmengenerhebung	90
4.2.1.	Methoden	90
4.2.2.	Implementierung aDNDv2	92
4.2.2.1.	Konzeption KI	93
4.2.2.2.	Integration KI	97
4.2.3.	Studiensetting	100
4.2.4.	Ergebnisse	104
4.2.5.	Experimentelle Volumenerfassung	110
4.2.5.1.	Laborexperimente und Ergebnisse	115
4.2.6.	Diskussion und Fazit	116

4.3. Automatisierte Klassifikation der Stuhlform	120
4.3.1. Methoden	121
4.3.1.1. Sitzerrhöhung	122
4.3.1.2. Kameras	123
4.3.1.3. Beleuchtung	124
4.3.1.4. Steuerung	125
4.3.2. Implementation	126
4.3.2.1. KI-Konzeption	128
4.3.3. Ergebnisse	133
4.3.3.1. Klassifikation: RGB-Daten	135
4.3.3.2. Klassifikation: RGB-D-Daten	135
4.3.4. Diskussion und Fazit	140
5. Zusammenfassung und Fazit	145
5.1. Diskussion	147
5.2. Fazit & Ausblick	153
5.3. Schlusswort	155
A. Anhang	157
A.1. Personas und Szenarien	157
A.1.1. Persona: Patient Heinz Janssen	157
A.1.2. Szenario: Ist-Situation Heinz Janssen	158
A.1.2.1. Identifikation von Problemfaktoren	159
A.1.3. Szenario: Soll-Situation Heinz Janssen	159
B. Abkürzungsverzeichnis	170
C. Abbildungsverzeichnis	172
D. Tabellenverzeichnis	175
E. Literaturverzeichnis	176
F. Eigene Veröffentlichungen	195

Kapitel 1

Einleitung

Der demografische Wandel in Europa wird, neben anderen Faktoren, charakterisiert durch die sich ändernde Altersstruktur der Bevölkerung. Durch sinkende Geburtenraten sowie die Entwicklungen in der Medizin und der Pflege, steigt der Anteil der älteren Menschen immer stärker an. Wurde für das Jahr 2004 noch von 461 Millionen Menschen mit einem Alter von über 65 Jahren ausgegangen, so wird für das Jahr 2050 schon mit rund 1,5 Milliarden Menschen mit einem Alter von über 65 Jahren gerechnet [1, 2]. Diese Überalterung der Bevölkerung, in Verbindung mit dem aktuell schon vorherrschenden Mangel an Fach- und Pflegekräften, führt insbesondere für die Medizin und die Pflege im geriatrischen Bereich zu großen Herausforderungen [3]. Die resultierenden Auswirkungen auf die älteren Bevölkerungsschichten werden maßgeblich davon abhängen, wie sich die einzelnen Länder und deren Gesundheitssysteme auf diese Veränderungen vorbereiten.

Unter anderem wird erwartet, dass ein Viertel bis die Hälfte aller Menschen über 85 Jahren vom geriatrischen Frailty-Syndrom betroffen sein wird [4, 5]. Es gibt zwar noch keine eindeutige Definition für das Syndrom, es besteht jedoch allgemein Einigkeit darüber, dass Frailty ein multifaktorielles geriatrisches Syndrom ist, welches durch den physiologischen Alterungsprozess und dessen pathologische Folgen ausgelöst wird [5, 6]. Es ist zwar normal, dass mit zunehmendem Alter die physiologischen Reserven des Körpers langsam zurückgehen, jedoch ist dieser Rückgang beim Frailty-Syndrom beschleunigt [7, 8]. Ältere Menschen, die vom Frailty-Syndrom betroffen sind, haben, im Vergleich zu nicht betroffenen älteren

Menschen, ein erhöhtes Risiko für Stürze, Frakturen, Infektionen, Krankenhausaufenthalte, Multimorbidität und Mortalität [9, 10]. Die Relevanz des Frailty-Syndroms wird durch die Beantragung der Aufnahme in den ICD-10 Katalog unterstrichen. Hierzu soll die aktuell bestehende Klasse „R54 Senilität: Altersschwäche, hohes Alter, Seneszenz“ in „R54: Gebrechlichkeit (Frailty)“ umbenannt werden.¹

Ein Modell zur Diagnose ist der Frailty-Phänotyp, siehe Kapitel 2.1. In diesem Modell sind eine reduzierte Handgriffstärke, Schrittgeschwindigkeit, körperliche Aktivität sowie Gewichtsverlust und Erschöpfung die hauptsächlichen Faktoren, um zu bestimmen, ob eine Person vom Frailty-Syndrom betroffen ist [5, 6]. Dementsprechend sind physische Rehabilitationsmaßnahmen naheliegende Behandlungsmethoden. Dass physische Rehabilitationsmaßnahmen besonders effektiv sind, wenn diese durch eine entsprechende therapeutische Diät begleitet werden, wird durch verschiedene Studien belegt [11, 12, 13]. Mehr noch ist die Ernährung nicht nur ein beeinflussbarer Faktor bei der Behandlung von Frailty-Patient:innen, sie kann auch zur Prävention eingesetzt werden [14]. Wie genau das Verzehrverhalten einer vom Frailty-Syndrom betroffenen Person angepasst werden sollte, kann mithilfe von Ernährungsberatung ermittelt werden.

Speziell im geriatrischen Kontext findet sowohl die Ernährungsberatung als auch die Erhebung notwendiger Informationen im direkten Austausch zwischen Ernährungsberater:innen und Patient:innen statt [15]. Dabei werden in der Regel auf Papier basierende (analoge) Protokolle zur Erhebung des allgemeinen Ernährungszustands verwendet, z. B. mit dem Mini Nutritional Assessment (MNA) [16] oder der Mini Nutritional Assessment Short-Form (MNA-SF) [17]. Speziell das Verzehrverhalten wird häufig mit dem 24-Hours Recall Protocol (24h-Recall) [18] erhoben. Mit diesen Protokollen wird nicht nur der aktuelle Status der Patienten einmalig erhoben, sondern durch die wiederholte Anwendung auch der Verlauf einer therapeutischen Diät bewertet. Verfahren, die über einen spezifischen Zeitraum das Verzehrverhalten einer Person erfassen, sind elementare Instrumente für die Ernährungsberatung. Als fundamentale Informationsquelle für die ernährungstherapeutische Behandlung ist es wichtig, dass die Daten in einer entsprechenden Qualität und Quantität vorliegen. Für die hochaltrigen Frailty-Patient:innen, und auch für gesunde Menschen, ist es kognitiv oft herausfordernd retrospektiv alle

¹<https://web.archive.org/web/20130719002119/http://www.dimdi.de/dynamic/de/klassi/downloadcenter/icd-10-gm/vorschlaege/vorschlaege2005/59gebrechlichkeit.pdf>, letzter Zugriff 14.7.2023

Getränke, Nahrungsmittel und Nahrungsergänzungsmittel qualitativ und quantitativ korrekt wiederzugeben. Weiterhin basiert das unmittelbare Feedback für die Patient:innen auf dem Fachwissen der Ernährungsberater:innen, falls diese die Daten aus der Erfahrung heraus bewerten können. Alternativ können die Daten auch mit einem Nährwertberechnungsprogramm ausgewertet werden. Hierzu müssen die analog vorliegenden Protokolle jedoch in das Programm übertragen werden. Eine derartige Auswertung findet häufig in einem nachgelagerten Prozess statt, sodass sich das Feedback für die Patient:innen verzögert und Übertragungsfehler auftreten können.

Das Ziel dieser Arbeit ist es zu untersuchen, wie der Prozess der Ernährungsberatung für vom Frailty-Syndrom betroffene Personen mithilfe von Technik und Digitalisierung unterstützt werden kann. Dadurch sollen sowohl Ernährungsberater als auch Betroffene perspektivisch kognitiv entlastet und gleichzeitig die Qualität und Quantität der Daten verbessert werden. Zunächst wird hierzu untersucht: *„Auf welche Art und Weise lassen sich Technologie und Digitalisierung nutzen, um hochaltrige Personen, die vom Frailty-Syndrom betroffen sind, eine selbstständige Erfassung relevanter Informationen für die Ernährungsberatung zu ermöglichen?“* Hierbei wird nicht nur die Erfassung des Verzehrverhaltens untersucht, sondern auch die Erfassung von körperlicher Aktivität und Körperkompositionsdaten. Für die Erfassung des Verzehrverhaltens existieren schon zahlreiche Lösungen in Form von mobilen Anwendungen. Diese Anwendungen sind jedoch i. d. R. nicht für die Zielgruppe dieser Arbeit entwickelt worden, siehe Abschnitt 3.3. Daher wurde ein digitales Ernährungstagebuch (engl. Digital Nutrition Diary) (DND) entwickelt, um auch hochaltrigen Personen das selbstbestimmte Protokollieren ihres Verzehrverhaltens zu ermöglichen. Weiterhin wurde in diesem Kontext untersucht, ob schon existierende Sensorik zur Erfassung von körperlicher Aktivität und Körperkompositionsdaten für diese Zielgruppe geeignet ist. Ein Ergebnis der zweistufigen Evaluation mit Proband:innen aus der Zielgruppe war, dass die Benutzbarkeit des DND durch das nutzerzentrierte Design zwar an die Zielgruppe angepasst werden konnte, eine höhere Benutzbarkeit jedoch durch eine möglichst ambiente Erfassung erzielt werden kann. Entsprechend befasst sich der zweite Teil dieser Arbeit mit der Fragestellung: *„Mit welchen technischen Hilfsmitteln kann das Führen eines digitalen Ernährungstagebuchs für hochaltrige und vom Frailty-Syndrom betroffene Personen weiter vereinfacht werden?“* Hierzu wurden verschiedene Ansätze aus dem aktuellen Stand der Wissenschaft miteinander kombiniert, um das DND weiter zu

optimieren. Das Ergebnis, das assisted DND (aDND), basiert auf einer hybriden Eingabemethode. Diese Eingabemethode orientiert sich am interviewartigen Charakter der Ernährungsberatung und kombiniert diesen mit künstlicher Intelligenz zur semi-automatischen Objekterkennung. Auch das aDND wurde durch zwei Nutzerstudien evaluiert. Neben dem aDND zur semi-automatischen Erfassung des Verzehrverhaltens, wurde ein Verfahren untersucht, um auch das Volumen semi-automatisch erfassen zu können. Auch hier lag der Fokus auf der Zielgruppe und damit auf der Erfassung von geringen Verzehrmenen. Neben der zugeführten Menge an Kalorien und Proteinen, der Aktivität und den Körperkompositionsdaten, sind auch Defäkation und Fäzes wichtige Informationsquellen. Speziell die Form und Struktur der Fäzes, bzw. die Stuhlform, kann Rückschlüsse auf die Darmdurchgangszeit ermöglichen und damit auch auf die Effektivität der Verdauung. Da die Themen Defäkation und Fäzes schambehafte sind und auch der nonverbale Informationsaustausch über die Fotomethode Nachteile hat, siehe Abschnitt 2.2.3, untersucht diese Arbeit die folgende Fragestellung: *„Mit welchen technischen Mitteln kann eine automatisierte Klassifizierung von Stuhlformen erreicht werden, um die manuelle Bildaufnahme und die verbale Beschreibung zu ersetzen?“* Es konnte gezeigt werden, dass es möglich ist, Stuhlformen ambient und automatisiert zu erfassen, indem orthogonal zur Richtung der Defäkation bzw. zur Fallrichtung der Fäzes ausgerichtete Kameras und einer Datenbank mit Bildern für das Training einer Künstlichen Intelligenz (KI) verwendet wurden.

Im nachfolgenden Kapitel werden die für diese Arbeit relevanten medizinischen Hintergründe zusammengefasst. Es wird dabei auf das Frailty-Syndrom sowie die Ernährungsberatung eingegangen. Außerdem werden die Auswirkungen von körperlicher Aktivität und Körperkompositionsdaten dargestellt. Es folgt die Betrachtung der Stuhlformen als wichtiger Indikator für die Effektivität der Verdauung.

Im nächsten Kapitel, dem Stand der Technik, werden die technischen Hintergründe und Hilfsmittel im Kontext der Unterstützung der Ernährungsberatung von hochaltrigen Personen zusammengefasst. Weiterhin werden die wichtigsten Punkte bzgl. der Erhebung und der Verarbeitung von Daten sowie die verwandten Arbeiten im Kontext dieser Arbeit zusammengefasst.

Im vierten Kapitel werden die drei bearbeiteten Fragestellungen beschrieben. Dabei werden jeweils die Methodik, die entstandene Systemarchitektur, die Implementierung der resultierenden Systeme, die durchgeführten Studien und die Ergebnisse

Kapitel 1. Einleitung

dieser Studien beschrieben. Abgeschlossen werden diese Abschnitte zu den drei Fragestellungen jeweils mit einer Diskussion und einem Fazit.

Das fünfte Kapitel fasst die Inhalte dieser Arbeit zusammen, diskutiert die Ergebnisse und stellt den Bezug zum Stand der Wissenschaft und Technik her. Abgeschlossen wird dieses letzte Kapitel durch einen Ausblick.

Kapitel 2

Medizinischer Hintergrund

Ziel dieses Kapitels ist, den medizinischen Hintergrund und damit die Grundlagen für die in dieser Arbeit behandelten Themengebiete aufzuführen. Hierzu wird der aktuelle Stand der Wissenschaft im Bereich des Frailty-Syndroms als auch der in der Ernährungsberatung für die Zielgruppe der Frailty-Patient:innen beschrieben.

Hierzu wird zunächst auf das Frailty-Syndrom eingegangen und erläutert, welche Faktoren für das Auftreten des Syndroms verantwortlich sind und welche Auswirkungen das Frailty-Syndrom auf die Betroffenen hat. Ebenfalls werden Methoden aufgeführt, welche dazu eingesetzt werden können, das Frailty-Syndrom zu erkennen. Weiterhin wird auf präventive und kurative Maßnahmen im Kontext des Frailty-Syndroms eingegangen. Eine solche Maßnahme ist die Ernährungsberatung. Da Ernährungsberatung oftmals mit der Akquise von Daten einhergeht, werden die eingesetzten Methoden zur Erhebung des allgemeinen Ernährungszustandes, des Verzehrverhaltens, der Aktivität, der Körperkompositionsdaten sowie des Stuhlgangs ebenfalls aufgeführt. Abgeschlossen wird das Kapitel durch eine Diskussion und ein Fazit, um Optimierungspotential im Kontext der Ernährungsberatung für hochaltrige und vom Frailty-Syndrom betroffene Personen aufzuzeigen, welches mithilfe von Technik und Digitalisierung adressiert werden kann.

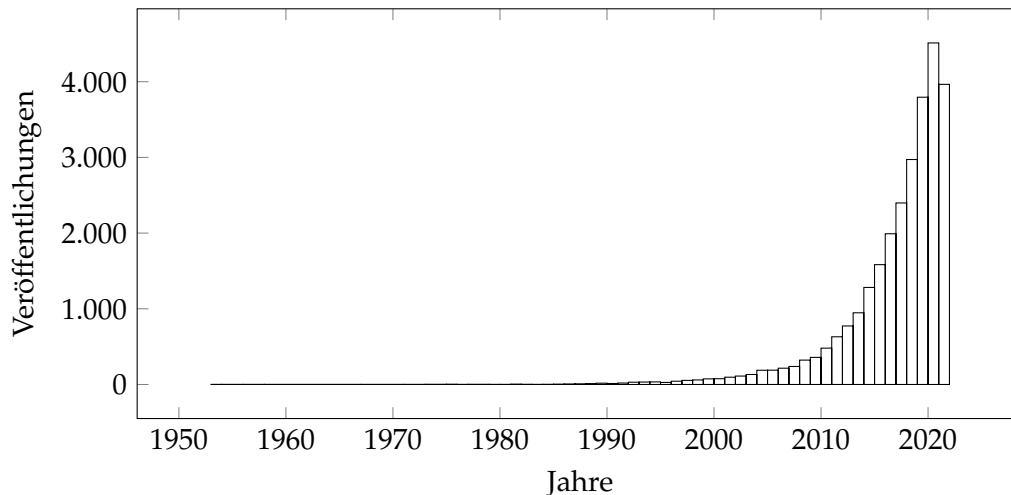


Abbildung 2.1.: Anzahl an Publikationen von 1953 bis 2022, welche über die Suchmaschine für wissenschaftliche Arbeiten PubMed bis zum 27.10.2022 unter dem Begriff „Frailty“ zu finden sind.

2.1. Frailty-Syndrom

Obwohl das geriatrische Frailty-Syndrom kontinuierlich in verschiedenen wissenschaftlichen Disziplinen an Bedeutung gewinnt, siehe Abbildung 2.1, mangelt es an einer einheitlichen und international anerkannten Definition [19]. Es besteht jedoch eine gewisse Einigkeit darüber, dass Frailty ein multidimensionales Syndrom beschreibt. Dieses wird durch verminderte individuelle Reserven und der daraus resultierenden erhöhten Vulnerabilität gegenüber internen und externen Stressfaktoren charakterisiert. Das Risiko im Laufe des Lebens vom Frailty-Syndrom betroffen zu sein, hängt von einer Vielzahl soziodemografischer, klinischer, lebensstilbezogener und biologischer Faktoren ab [20, 5, 6, 19], siehe Abbildung 2.2. Führen diese Faktoren dazu, dass die individuellen Reserven zu stark abnehmen, beginnen die homöostatischen Prozesse des Körpers zu versagen und die Betroffenen erholen sich nur noch verlangsamt oder gar nicht mehr von solchen Stressfaktoren [21]. Somit führt Frailty zu einer erhöhten Morbiditäts- als auch Mortalitätsrate [22].

Neben der Mehrdimensionalität besteht weiterhin Einigkeit darüber, dass die Prävalenz bezüglich Frailty mit steigendem Alter zunimmt, Frailty daher eine extreme, pathologische Folge des Alterungsprozesses ist, welche bis zu einem gewissen Punkt kurz vor dem Tod potenziell vermieden werden kann [19]. Zudem




Abbildung 2.2.: Risikofaktoren für die Entstehung und der Progression von Frailty, nach Hoogendijk et al. [19].

kann eine betroffene Person zwischen den verschiedenen Schweregraden des Frailty-Syndroms wechseln [19]. Darum eignet sich der Begriff Frailty weder dazu, eine Personengruppe ab einem gewissen Mindestalter zu beschreiben, noch dazu hochaltrige Personen zu beschreiben, die von Erkrankungen oder Behinderungen betroffen sind [23].

2.1.1. Konzepte zur Diagnostik

Neben der Frage nach einer Definition für das Frailty-Syndrom beschäftigt sich die Wissenschaft mit der Standardisierung von Screening- und Bewertungs-Tools zur Erfassung des Frailty-Syndroms. In einem Review von Roberta Vella Azzopardi et al. konnten insgesamt 79 originale oder adaptierte Screening- und Bewertungs-Tools identifiziert werden [24]. Wie auch bei der Definition gibt es hier noch keinen Konsens, welche dieser in den letzten Dekaden entwickelten Methoden am besten für die Diagnostik des Frailty-Syndroms geeignet ist [20, 19, 25]. Die Bandbreite

reicht hierbei von einfachen Methoden zur Erhebung einzelner Parameter, welche somit zwar die Mehrdimensionalität des Syndroms nicht berücksichtigen, jedoch trotzdem eine Korrelation zu einer vorhandenen Frailty oder einer entsprechenden Vorstufe aufweisen. Unter diese Parameter fallen z. B. die Gehgeschwindigkeit [26] oder die Handkraft [27, 28] aber auch umfangreiche geriatrische Assessments zur Erhebung eines breiten Spektrums möglicher psychischer und sozialer Defizite. Die meisten Modelle, welche die Mehrdimensionalität des Frailty-Syndroms berücksichtigen, beruhen dabei auf dem Frailty-Phänotyp (FP) [5] oder dem Frailty Index (FI) [29]. Neben dem FP werden in der klinischen Praxis häufig auch die Clinical Frailty Scale (CFS) [30] oder der Simple Frailty Questionnaire (FRAIL-Scale) [31, 10] angewendet. Seltener werden die Edmonton Frail Scale (EFS) [32] oder der Groningen Frailty Indicator (GFI) [33, 34] eingesetzt [35].

Frailty-Phänotyp: Der Frailty-Phänotyp nach Fried et al. basiert auf dem Konzept, dass das Frailty-Syndrom mit der Störung mehrerer physiologischer Regelkreise einhergeht, wie dem endokrinologischen, immunologischen, hämatologischen und muskuloskeletalen System [5]. Erhoben werden hierzu fünf verschiedene Kriterien:

- Ein unbeabsichtigter Gewichtsverlust von mehr als fünf Kilogramm pro Jahr (bzw. nach der Deutschen Gesellschaft für Ernährung definiert als Gewichtsverlust von mehr als fünf Prozent in drei Monaten oder mehr als zehn Prozent in sechs Monaten),
- eine Abnahme der Körperkraft um 20 Prozent (gemessen über Handkraftmessung und verglichen mit der Vergleichspopulation),
- eine Reduktion der Gehgeschwindigkeit um 20 Prozent (gemessen über eine Strecke von 4,572 m und verglichen mit der Vergleichspopulation),
- eine subjektiv empfundene Erschöpfung und
- ein reduziertes allgemeines Aktivitätslevel [5].

Treffen drei oder mehr dieser Kriterien zu, geht man davon aus, dass eine Frailty vorliegt. Bei einem oder zwei Kriterien wird von der sogenannten Pre-Frailty gesprochen. Trifft keines der Kriterien zu, so spricht man von robusten Personen [5, 6].

Frailty-Index: Im Vergleich zum FP ist der FI deutlich umfangreicher, da er entwickelt wurde, um Frailty als eine Akkumulation von Defiziten zu erfassen. Der FI erfasst nicht nur funktionelle Aspekte aus den Bereichen Kraft, Mobilität und Aktivität, sondern auch eine große Anzahl von funktionellen Defiziten und krankheitsassoziierten Beschwerden in einem Wert zusammen. Dabei wird davon ausgegangen, dass die Wahrscheinlichkeit, dass eine Person vom Frailty-Syndrom betroffen ist, mit der Anzahl von Defiziten ansteigt [20, 29, 36].

2.1.2. Prävention und Intervention

Forschungsergebnisse zeigen immer wieder, dass eine gesunde und ausgewogene Ernährung nicht nur ein sehr wichtiger Bestandteil eines gesunden Lebensstils ist [37], sondern auch, dass eine angepasste Ernährung bei gesundheitlichen Problemen mitunter sogar notwendig ist, um den gewünschten Genesungsprozess zu erreichen [38]. Dies gilt ebenfalls für das Frailty-Syndrom [14]. Weiterhin besteht Evidenz darüber, dass eine solche Ernährung in Kombination mit körperlicher Aktivität (z. B. spezielles Krafttraining) die Entstehung und das Fortschreiten des Frailty-Syndroms positiv beeinflussen kann [39, 40, 41].

Bei einer auf das Frailty-Syndrom angepassten Ernährung steht neben einer ausreichenden Energiezufuhr vor allem auch eine proteinreiche Ernährung als wichtiger Faktor für den Erhalt bzw. die Steigerung der Muskelmasse und des Aktivitätsniveaus im Vordergrund [14, 42, 43]. Speziell für den Makronährstoff Protein empfehlen Expert:innen einen täglichen Verzehr von 1,0-1,2 g pro kg Körpergewicht [44]. Für verschiedene körpereigene Prozesse werden etwa 20 unterschiedliche Proteine, oder proteinogene Aminosäuren, benötigt. Unter diesen befinden sich neun Aminosäuren, welche der Körper nicht (essenziell) oder nur in unzureichender Menge (semi-essenziell) über den Zellstoffwechsel bilden kann. Aus diesem Grund müssen diese regelmäßig und in ausreichendem Maße über die Ernährung zugeführt werden. Das ausreichende Maß ist nicht nur abhängig von physischen Merkmalen (z. B. Geschlecht, Gewicht, Größe und Alter), sondern auch von der Stresssituation (z. B. Unfälle, Verletzungen oder Infekte), welche speziell beim Frailty-Syndrom eine erhöhte Auftrittswahrscheinlichkeit aufweisen [45]. Der Abbau von Skelettmuskulatur, z. B. ausgelöst durch eine Unterversorgung an (essenziellen) Aminosäuren, kann zu einer Störung bei der Regulation des Stressstoffwechsels führen, was wiederum negative Auswirkungen auf die Anpassungsfähigkeit gegenüber Krankheits-

und Stresssituationen hat [19]. Aber auch eine Unterversorgung mit anderen Makronährstoffen (Kohlenhydrate und Fette) erhöht das Risiko vom Frailty-Syndrom betroffen zu werden [46].

Neben der kalorischen Bilanz und der Verteilung der Makronährstoffe ist auch die ausreichende Versorgung mit Vitamin D wichtig. Diese wird für die Muskelfunktion und Leistungsfähigkeit benötigt und ein Mangel führt zu Muskelsymptomen wie Schwäche, Muskelschmerzen und Gangstörungen. Entsprechende Studien haben gezeigt, dass Vitamin D im direkten Zusammenhang mit dem Sturzrisiko hochaltriger Personen steht [47, 48, 49, 50]. Ebenfalls negativ auf die Muskelfunktionen kann sich oxidativer Stress auswirken, z. B. durch Entzündungszustände. In der Prävention von Frailty gilt es daher, oxidativen Stress zu minimieren. Eine ausgewogene Ernährung mit dem Verzehr antioxidanzienreicher Lebensmittel kann hierzu einen Beitrag leisten. Zu den antioxidativ wirksamen Nährstoffen zählen die Vitamine C und E, Karotinoide und die Spurenelemente Selen und Zink [51, 52, 41]. Omega-3-Fettsäuren besitzen entzündungshemmende Eigenschaften, welche sowohl der Entstehung als auch dem Fortschreiten von Frailty entgegenwirken können. Der ausreichende Verzehr von Omega-3-fettsäurehaltigen Lebensmitteln ist darum ein wichtiger Bestandteil einer auf das Frailty-Syndrom angepassten Ernährung [41, 53].

Neben diesen Faktoren ist auch eine ausreichende Trinkmenge wichtig, da sonst verschiedene körpereigene Prozesse, und damit die Gesamtleistungsfähigkeit, negativ beeinträchtigt werden [54]. Eine unzureichende Trinkmenge kann z. B. zu Obstipation (Verstopfung) führen, den gesamten Stoffwechselprozess stören und damit einen Verlust von Körpergewicht verursachen [55]. Diese Zusammenhänge sind den vom Frailty-Syndrom betroffenen Patient:innen nicht immer bewusst. Besonders die Abnahme von Körpergewicht wird, z. B. aufgrund von Übergewicht oder genereller Unzufriedenheit mit der eigenen Figur, oftmals als positiv empfunden. Eine Gewichtsabnahme führt, unabhängig vom Ausgangsgewicht, in der Regel zu einem Verlust an Muskelmasse, der neben den oben beschriebenen Auswirkungen auch mit Einbußen der Funktionalität einhergeht [19, 20]. Für den Erfolg einer an die Bedürfnisse von Frailty-Patient:innen angepassten therapeutischen Ernährung ist es daher wichtig, bei diesen ein Bewusstsein für die oben genannten Zusammenhänge und die Notwendigkeit einer entsprechenden Ernährung zu schaffen.

2.2. Ernährungsberatung

Bei der Ernährungsberatung muss grundsätzlich zwischen den beiden Bereichen „Primärpräventive Ernährungsberatung“ für gesunde Menschen und „Ernährungstherapie“ für kranke Menschen unterschieden werden. Nach § 20 SGB V ist für Ernährungsberatung keine ärztliche Bescheinigung notwendig und kann somit von jeder Person in Anspruch genommen werden. Bei der Ernährungs- oder Diättherapie hingegen ist nach § 43 SGB V eine ärztliche Bescheinigung notwendig [56, 57]. Da sich die Inhalte dieser Arbeit jedoch auf das Frailty-Syndrom fokussieren, und betroffene Personen sowohl von der Ernährungsberatung als auch von der Ernährungstherapie profitieren können, wird der Begriff Ernährungsberatung in dieser Arbeit synonym für die primärpräventive Ernährungsberatung und die Ernährungstherapie eingesetzt, falls nicht anders angezeigt.

Das Ziel der Ernährungsberatung ist, unabhängig davon, ob jemand krank ist oder nicht, über die verschiedenen physiologischen und medizinischen Aspekte von Ernährung aufzuklären [58]. Damit Ernährungsberater:innen auf die sehr individuellen Situationen, z. B. von Personen, die vom Frailty-Syndrom betroffen sind, eingehen können, müssen entsprechende Informationen erhoben werden. Nur so können Ernährungsberater:innen die individuellen Ressourcen von betroffenen Personen mobilisieren und diese zu einem situationsangepassten und unabhängigen Ernährungshandeln befähigen, um eine Restitution von Gesundheit und Handlungsvermögen zu erreichen [58, 57].

Die Datenerhebung für die Ernährungsberatung, im Kontext des Frailty-Syndroms, findet häufig im direkten Austausch zwischen Ernährungsberater:innen und Patient:innen statt. Erhoben wird hier z. B. der allgemeine Ernährungszustand, aber auch das individuelle Verzehrverhalten von Patient:innen [15]. Neben dem Verzehrverhalten können auch andere Faktoren für die Ernährungsberatung wichtig sein, wie das Körpergewicht, die Körperkompositionsdaten [59], das physische Aktivitätslevel oder die Fäzes (menschlicher Stuhl) [60].

2.2.1. Allgemeiner Ernährungszustand

Die Erhebung des Ernährungszustandes ist eine wichtige Maßnahme, um eine Mangelernährung feststellen zu können. Für hochaltrige Personen bedeutet dieser

pathologische Zustand ein deutlich erhöhtes Risiko, die eigene Selbstständigkeit zu verlieren oder auch ins Krankenhaus eingeliefert werden zu müssen [61]. Bei stark unterernährten hochaltrigen Personen steigt die Mortalitätsrate für die folgenden 12 Monate auf annähernd 50 % [62]. In den meisten Fällen ist die Entstehung von Mangelernährung bei älteren Menschen ein multifaktorieller Prozess [63]. In den 1990er Jahren wurde das Mini Nutritional Assessment® (MNA; Nestle Nutrition, Verey, Schweiz) entwickelt, um den Ernährungszustand zu ermitteln [16, 64]. Berücksichtigt werden dabei eine Vielzahl von antropometrischen Messungen (Gewichtsverlust, Gewicht, Größe, mittlerer Armumfang, Wadenumfang), eine allgemeine Beurteilung (Lebensstil, Medikation, akute Krankheit, Mobilität, neuropsychologische Probleme, Hautläsionen), die Ernährung (Anzahl von Mahlzeiten, Nahrungs- und Flüssigkeitsaufnahme, Appetit und Ernährungsweise), die subjektive Bewertung (Eigenwahrnehmung des Ernährungszustandes und Vergleich des eigenen Gesundheitszustandes mit anderen) sowie biochemische Marker (Serumspiegel von Albumin, Präalbumin, Cholesterin, Lymphozytenzahl) [61, 64]. Auch wenn der MNA in der Regel in 10–15 Minuten durchgeführt werden kann, [65, 66] ist er in der Praxis oft zu zeitintensiv, sodass er nur unregelmäßig angewendet wird [61, 67]. Dieses Problem adressiert die Kurzfassung des MNA, der MNA-SF, welcher ältere Personen in zwei Kategorien einteilt: wohlernährte Personen und Personen, die unter Verdacht stehen, von einer Mangelernährung betroffen zu sein. Da die diagnostische Genauigkeit des MNA-SFs bezüglich der nicht gefährdeten bzw. wohlernährten hochaltrigen Personen mit dem MNA vergleichbar ist, wird der MNA nur dann benötigt, wenn der MNA-SF das Risiko für eine vorliegende Mangelernährung anzeigt [17].

Wie schon angeführt, sind neben dem Körpergewicht auch die Körperkompositionsdaten eine wichtige Information für die Ernährungsberatung. Zur Erfassung dieser Körperkompositionsdaten kann grundsätzlich zwischen direkten, indirekten und doppelt indirekten Verfahren unterschieden werden. Die direkten Methoden werden post mortem durchgeführt und eignen sich daher nicht für die Ernährungsberatung. Die indirekten Methoden umfassen z. B. Hydrodensitometrie und Dual Energy X-ray Absoptiometry (DEXA), welche als Goldstandard zur Messung der Körperdichte gelten. Diese stationären Verfahren sind jedoch durch den Einsatz von Fachpersonal und Anschaffungsaufwendungen entsprechend kostenintensiv und erfordern eine hohe Kooperationsbereitschaft [68].

Die doppelt indirekten Methoden leiten Informationen über die verschiedenen Körperkompartimente über Modelle ab, welche Statistiken über bekannte Zusammenhänge zwischen den Messdaten und den gewünschten Daten enthalten. Somit können z. B. über Hautfaltendicken (Messdaten) Informationen über das Körperfett (gewünschte Daten) abgeleitet werden. Eine kostengünstige, portable, schnelle und einfache Methode unter den doppelt indirekten Methoden ist die Bioelektrische Impedanzanalyse (BIA). Die BIA ist eine Methode, die auf der Tatsache beruht, dass die verschiedenen Körperkompartimente des menschlichen Körpers unterschiedliche elektrische Eigenschaften besitzen. Durchgeführt werden BIA-Messungen im medizinischen Kontext in der Regel mithilfe von separaten Messgeräten. Diese erfordern es, dass die Personen sich in liegender Ruhelage befinden. Weiterhin müssen die Elektroden an Händen und Füßen angebracht werden. Durch das Anlegen von Wechselströmen und der Messung des resultierenden elektrischen Widerstandes sowie der Phasenverschiebung können Schätzungen über die verschiedenen Körperkompartimente abgeleitet werden [68, 69, 70]. Zur Auswertung der gemessenen Parameter ist eine zusätzliche Software erforderlich. Weiterhin ist die Eingabe von zusätzlichen Informationen (z. B. Geschlecht, Alter, Größe) über die zu messende Person notwendig, damit eine Auswertung durch die Software erfolgen kann [71, 72]. Ermittelt werden durch diese dann:

- Fettmasse
- fettfreie Masse (Magermasse)
 - Körperzellen der Magermasse
 - extrazelluläre Bestandteile der Magermasse

Ein weiterer Vorteil der BIA-Methode ist, dass diese Messmethode nicht nur im klinischen Kontext eingesetzt werden kann, sondern auch in Geräten für den privaten Gebrauch verfügbar ist, den sogenannten Körperkompositionswaagen (engl. Body Composition Scales) (BCSs), siehe Abschnitt 3.1.4.

Für Personen, die vom Frailty-Syndrom betroffen sind, wird die Erhebung des allgemeinen Ernährungszustandes nicht nur einmal zu Beginn des Prozesses, bzw. des Zeitraumes der therapeutischen Diät, durchgeführt, sondern oft auch zum Ende des Zeitraumes als Follow-up, um die getroffenen Maßnahmen zu beurteilen

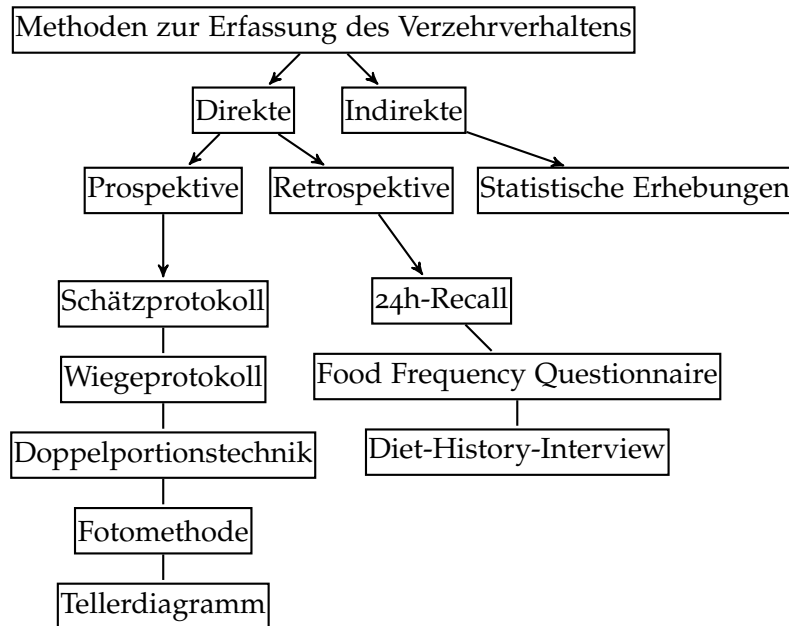


Abbildung 2.3.: Übersicht der verschiedenen Methoden zur Erhebung des Verzehrverhaltens, in Anlehnung an Frisch et al. [75].

und eventuell eine Neubewertung durchführen zu können [73]. Bei Komplikationen wird das Verzehrverhalten hochfrequenter erhoben, um möglichst schnell Zusammenhänge erkennen zu können und dementsprechend zu reagieren.

2.2.2. Verzehr- und Trinkmängenerfassung

Grundsätzlich wird bei den Ernährungserhebungsmethoden zwischen den direkten und indirekten Verfahren unterschieden. Indirekte Verfahren geben einen Überblick über das Verzehr- und Trinkverhalten von größeren Menschengruppen bzw. Bevölkerungsgruppen. Das Ergebnis solcher Verfahren kann z. B. ein bestimmter Verbrauch, wie Käse oder Fleisch, pro Kopf sein. Die direkten Verfahren hingegen werden dazu eingesetzt, um die individuellen Verzehr- und Trinkmengen einzelner Personen zu erheben. Hierbei kann wiederum zwischen retrospektiven und prospektiven Verfahren [53, 74] unterschieden werden, siehe Abbildung 2.3. Eine Zusammenfassung der Vor- und Nachteile der retrospektiven und prospektiven Ernährungserhebungsmethoden kann den Tabellen A.2 und A.1 entnommen werden.

Unabhängig davon, welche Verfahren zum Einsatz kommen, werden häufig sogenannte Nährwertberechnungsprogramme eingesetzt, um aus den erhobenen Verzehr- und Trinkmengen die Energie- und Nährstoffzufuhr zu berechnen. Diese Nährwertberechnungsprogramme sind an Datenbanken angebunden, z. B. an den Bundeslebensmittelschlüssel (BLS). Der BLS wird in der Praxis häufig verwendet. Die zugehörige Datenbank umfasst etwa 15.000 verschiedene Lebensmittel- und Getränke und wird fortlaufend aktualisiert und erweitert [53].

Retrospektive Methoden

Retrospektive Methoden werden dazu eingesetzt, das zurückliegende Verzehrverhalten über Tage, Wochen oder Monate zu erfassen. Die Datenerhebung kann dabei sowohl über selbst auszufüllende Fragebögen als auch über Interviews erfolgen [76]. Speziell im geriatrischen Kontext findet diese Datenerhebung im direkten Austausch zwischen Ernährungsberater:innen und Patient:innen statt [15]. Wenngleich diese Instrumente in der Regel weniger reaktiv sind, so haben sie doch auch den Vorteil, dass die Daten weniger beeinflusst werden. Nachteilig kann sich hier wiederum ein unzureichendes Erinnerungsvermögen auswirken, wobei die Anforderung an dieses mit dem zu erfassenden Zeitraum skaliert. Somit können retrospektive Verfahren, insofern dies der Anwendungsbereich zulässt, an die kognitiven Bedarfe der jeweiligen Zielgruppe angepasst werden [53]. Diese Anpassbarkeit unterliegt natürlichen Grenzen, sodass diese Methoden nicht für jede Zielgruppe geeignet sind.

24-Hour Recall: Das 24h-Recall wird zur semiquantitativen und individuellen Erfassung der Verzehr- und Trinkmengen des Vortages verwendet. Diese Daten werden durch geschulte Interviewer:innen direkt oder per Telefon erhoben [76]. Seit einiger Zeit können diese Daten jedoch auch mithilfe eines computergestützten Interviews erfolgen. Dabei existieren z. B. webbasierte Instrumente, welche die Nutzer:innen beim Ausfüllen des Protokolls unterstützen und die Daten teilweise automatisch weiterverarbeiten [77, 78, 79]. Weiterhin existieren computergestützte Systeme, welche für die telefonische Erfassung von Daten entwickelt wurden und den Interviewer:innen bei der systematischen und standardisierten Erfassung des 24h-Recall unterstützen (EPIC-SOFT) [80].

Diet-History-Interview: Das Diet-History-Interview (DHI) ist eine Methode zur retrospektiven Erfassung von Verzehr- und Trinkmengen. Üblicherweise umfasst das DHI einen Zeitraum von einigen Wochen bis hin zu mehreren Monaten. Es soll dazu dienen, neben der Nahrungsmittelaufnahme auch Ernährungsmuster zu identifizieren [75, 81, 82]. Eine Möglichkeit ist die dreistufige Erfassung, bei der im ersten Schritt eine geschulte Fachkraft die häufig verzehrten Lebensmittel und Getränke in einem Interview erfragt. Für das DHI wurde eine computergestützte Methode, die Software DISHES 98 (Diet Interview Software for Health Examination Studies), entwickelt. Diese Software umfasst einen retrospektiven Zeitraum von bis zu vier Wochen [76]. Im nächsten Schritt wird häufig das 24h-Recall oder auch das im folgenden Abschnitt beschriebene Food Frequency Questionnaire (FFQ) eingesetzt, um mithilfe des aktuellen Verzehrs auch weniger häufig verzehrte Lebensmittel zu erfassen [76].

Food Frequency Questionnaire: Das FFQ ist ebenfalls ein retrospektives Verfahren zur Erfassung der Verzehrhäufigkeiten, Mahlzeitenfrequenzen sowie der Portionsgrößen. Das FFQ stellt dabei qualitative und deskriptive Daten im Vordergrund. Der Erfassungszeitraum kann zwischen 24 Stunden bis hin zu einem Jahr variieren. Die Erhebung der Daten kann durch eine geschulte Fachkraft in einem Interview erfolgen oder durch die Patient:innen selbst, durch das Ausfüllen eines Fragebogens [83].

Prospektive Methoden

Prospektive Methoden erfassen das aktuelle Verzehrverhalten über einen gewissen Zeitraum. Die erwartete Genauigkeit der Ergebnisse ist dabei stark abhängig von der ausgewählten Methode [76]. Ein Vorteil der prospektiven Methoden ist die geringere Anforderung an die Erinnerungsfähigkeit der Zielgruppe [53]. Nachteilig wirken sich jedoch die hohen zeitlichen und monetären Aufwendungen aus. Weiterhin können die Ergebnisse durch „Under- oder Overreporting“ verfälscht sein [76].

Schätzprotokoll: Bei dem Schätzprotokoll sollen die verzehrten Lebensmittel detailliert, wenn möglich, mit Markennamen, Sorte, Fettgehalt und Angaben zur

Zubereitung protokolliert werden. Die Mengen dürfen dabei in haushaltsüblichen Maßen oder mithilfe von Abbildungen geschätzt werden. Die Dokumentation sollte hierbei möglichst unmittelbar nach dem Essen erfolgen [75].

Wiegeprotokoll: Das Wiegeprotokoll kann dazu eingesetzt werden, Mahlzeiten vor dem Verzehr grammgenau zu messen. Nicht verzehrte Reste werden ebenfalls grammgenau abgemessen. Die resultierenden Differenzen repräsentieren dann die verzehrten Mengen. Damit ist das Wiegeprotokoll zwar eine sehr genaue Methode, jedoch auch mit einem sehr hohen Aufwand verbunden [76, 75].

Doppelportionstechnik: Eine ebenfalls sehr aufwändige Methode ist die Doppelportionstechnik. Bei diesem Verfahren wird zu jeder Mahlzeit eine identische Portion hergestellt und auf ihre Inhaltsstoffe analysiert. Diese Methode wird jedoch aufgrund des Aufwandes und der immer besser werdenden Lebensmitteldatenbanken nur selten eingesetzt [53].

Fotomethode: Ein sehr einfaches Instrument zur Protokollierung von Verzehr- und Trinkmengen ist die Fotomethode. Durch die weit verbreitete digitale Fotografie (Smartphones) ist dies eine hochverfügbare und schnelle Möglichkeit als Alternative zur manuellen und/oder analogen Dokumentation. Die korrekte Erfassung der verzehrten Mengen, Zutaten sowie Informationen zur Zubereitung, gestaltet sich mit dieser Methode jedoch als schwierig [53].

Tellerdiagramm: Das Tellerprotokoll wurde speziell für den Einsatz in Krankenhäusern entwickelt, da dort eine relevante Anzahl von Patient:innen nicht bedarfsgerecht ernährt wird [84]. Studien haben gezeigt, dass etwa 20-60 % der Patient:innen im Krankenhaus von einer Unterernährung betroffen sind [85, 86, 87]. Das Tellerdiagramm wird vom Krankenhauspersonal erfasst. Dabei wird die Mahlzeit in Viertel aufgeteilt, sodass es sich in sehr kurzer Zeit ausfüllen lässt. Sind im Diagramm nur zwei oder weniger Viertel über einen längeren Zeitraum markiert, so weist dies auf eine unzureichende Nahrungszufuhr hin [84].

2.2.3. Fäzes

Wie schon in Abschnitt 2.2 angeführt, kann auch der menschliche Stuhl, bzw. die Fäzes, eine wichtige Informationsquelle im Kontext der Ernährungsberatung sein. Schon in der Antike, zur Zeit von Hippokrates und Galenos, wurden mithilfe der Koprooskopie, bzw. Stuhlschau, Rückschlüsse über die Gesundheit einer Person gezogen [88, 89]. Auch heute noch werden viele Informationen über Fäzes gewonnen. Bei der Betrachtung der Fäzes zur Differenzialdiagnostik sind z. B. Färbung, Konsistenz und Volumen von Bedeutung [90]. Für die Ernährungsberatung sind jedoch insbesondere Informationen oder Hinweise auf das Vorliegen einer chronischen Obstipation (Verstopfung) oder Diarrhö (Durchfall) wichtig. Beide Krankheiten können die Qualität der Verstoffwechslung verzehrter Getränke, Lebensmittel und Nahrungsergänzungsmittel negativ beeinflussen [91].

Auslöser für eine Obstipation können z. B. Dehydration oder auch Nebenwirkungen von Medikamenten (z. B. Eisenpräparate, Antidepressiva oder blutdrucksenkende Medikamente) sein [92]. Weiterhin können auch Unverträglichkeiten eine Obstipation auslösen, welche z. B. durch eine Ernährungsumstellung auftreten können. Eine Obstipation kann dazu führen, dass Betroffene unter Appetitlosigkeit leiden und die Nahrungsmittelzufuhr verringern [93]. Die Prävalenz von Obstipation liegt bei 7–12 % bei der Altersgruppe der über 65 Jahre alten Personen und steigt graduell bis auf 25 % für die Altersgruppe der über 85 Jahre alten Personen an [94]. Eine zum Zeitpunkt dieser Arbeit aktuelle Studie mit Personen über 70 Jahren hat Obstipation in Zusammenhang mit Frailty untersucht. Diese konnte zeigen, dass die Prävalenz von Obstipation bei Personen mit Pre-Frailty (33,9 %) und mit Frailty (41,7 %) deutlich höher ist als die durchschnittliche Prävalenz (26,9 %) [95].

Diarrhö kann ebenfalls einen negativen Effekt auf den Stoffwechsel haben, da diese dazu führen kann, dass die zugeführten Nahrungsmittel nicht richtig verdaut werden. Weiterhin muss die Trinkmenge angepasst werden, da bei einer anhaltenden Diarrhö schnell eine Dehydration auftreten kann [93]. Zur Prävalenz von Diarrhö existieren verschiedene Studien [96]. Eine auf dem 2009–2010 National Health and Nutrition Examination Survey Daten beruhende Studie hat eine durchschnittliche Prävalenz von 6,6 % für alle Altersgruppen ergeben, für die Altersgruppe 60–69 Jahre 9,7 % und für die Altersgruppe über 70 Jahre 9,6 % [96].

Die Darmpassagezeit ist in diesem Kontext eine wichtige Größe und kann dazu eingesetzt werden, den Grad einer pathologischen Verdauungsstörung zu messen. Zur Messung dieser Zeitspanne können sowohl direkte als auch indirekte Messmethoden verwendet werden. Eine Möglichkeit zur direkten Messung der Darmpassagezeit ist die kontinuierliche Messung von eingenommenen Markern, z. B. Röntgenkontrastmittel [60]. Es konnte gezeigt werden, dass eine Korrelation zwischen der Form und Beschaffenheit der Fäzes, bzw. die Stuhlform und der Darmpassagezeit gibt [97].

2.2.3.1. Stuhlform

Die Korrelation zwischen der Stuhlform und der Darmpassagezeit ermöglicht eine indirekte Messung, sodass in vielen Fällen auf eine direkte Messung verzichtet werden kann. Um mithilfe dieser Korrelation ein diagnostisches Hilfsmittel zu entwickeln, haben Simon J. Lewis et al. den Stuhl nach seiner Form und Beschaffenheit in insgesamt sieben Klassen eingeteilt und damit den Bristol Stool Form Scale (BSFS) [97] entwickelt, siehe Abbildung 2.4.

Klasse 1 und 2 weisen dabei auf das Vorliegen einer Obstipation hin. Die Klassen 3 bis 5 stehen für einen durchschnittlichen und normalen Stuhlgang und weisen nicht auf Krankheiten oder Unverträglichkeit hin. Die Klassen 5 bis 7 weisen auf eine Diarrhö hin [98]. Somit lassen sich, mithilfe des BSFS, Informationen über die Darmpassagezeit direkt im Austausch zwischen Ernährungsberater:innen und Patient:innen erheben. Alternative Methoden zur Erfassung der Stuhlformen nach BSFS, wie das eigenständige Erstellen von Fotos oder eines Protokolls, über entsprechende Bilder mit Beispielen, wie es bei Kindern praktiziert wird, können Nachteile mit sich bringen [99]. Neben den notwendigen Reserven, welche für eine selbstständige Erfassung von Form und Beschaffenheit des eigenen Stuhls notwendig sind, spielt bei derartigen Methoden häufig auch die subjektive Einschätzung der Patient:innen eine Rolle. Die Fotomethode ist zwar objektiv, jedoch kann z. B. der physische Aufbau von Toiletten, insbesondere der von Tiefspültoiletten, dazu führen, dass der zu fotografierende Stuhl nach der Defäkation nicht mehr sichtbar ist. Weiterhin kann der Stuhl durch Toilettenpapier verdeckt werden. Auch bei Diarrhö kann der eigentliche Stuhl oft nicht mehr fotografiert werden, da sich dieser stark mit dem Wasser in der Toilette vermengt, sodass auch hier ein Foto an Aussagekraft verliert.

Klasse 1 Einzelne, feste Kügelchen	
Klasse 2 Klumpig und wurstartig	
Klasse 3 Wurstartig mit rissiger Oberfläche	
Klasse 4 Wurstartig mit glatter Oberfläche	
Klasse 5 Weiche Klumpen mit klaren Kanten	
Klasse 6 Breiige Klumpen mit ausgefransten Kanten	
Klasse 7 Flüssig ohne feste Stücke	

Abbildung 2.4.: Künstliche BSFS-Testkörper, welche mithilfe herkömmlicher Knete und Schokoladenpudding, in Anlehnung an [97], erstellt wurden.

Neben der BSFS existieren weitere Möglichkeiten, den menschlichen Stuhl zu klassifizieren. Eine ist die Brussels Infant and Toddler Stool Scale (BITSS) [100]. Diese ist jedoch speziell für Kinder und Kleinkinder entwickelt worden, da die BSFS nicht unmittelbar auf diese Zielgruppe angewendet werden kann. Weiterhin gibt es umfangreichere Methoden, um den eigenen Stuhl zu klassifizieren, wie die Kings Stool Scale (KSS). Diese verfügt über vier verschiedene Klassen von Stuhlformen und drei verschiedene Mengenangaben pro Klasse, sodass sich in Summe 12 Klassen ergeben [101]. Ziel dieser Methoden ist ebenfalls zu erkennen, ob es Hinweise auf einen pathologischen Zustand gibt, z. B. Obstipation oder Diarrhö.

2.2.3.2. Färbung

Im gesunden Zustand reicht die Farbe des Stuhls von hell- bis dunkelbraun. Bedingt durch Ernährung kann sich diese Farbe jedoch verändern, z. B. durch Blaubeeren oder einen hohen Konsum von Milchprodukten. Ebenso kann die Einnahme von Medikamenten Einfluss auf die Stuhlfarbe haben. So kann sich der Stuhl durch die Einnahme von Kohle- oder Eisenpräparaten schwarz färben. Farbveränderungen können jedoch auch ein Anzeichen für erkrankte Verdauungsorgane sein. Eine rotbraune Färbung kann auf Blutungen im Dickdarm hinweisen, hellrote Blutauflagerungen auf Blutungen aus Hämorrhoiden, Fissuren oder Dickdarmpolypen. Schwarzer Stuhlgang kann auf Blutungen im oberen Verdauungstrakt hinweisen und flüssiger, grünlicher auf Durchfallerkrankungen durch Salmonellen [102, 103].

2.2.3.3. Konsistenz

Im gesunden Zustand ist die Konsistenz des Stuhls homogen. Lediglich bei sehr ballaststoffreicher Ernährung sind noch unverdaute Elemente, wie Körner, erkennbar. Auflagerungen auf dem Stuhl lassen auf Krankheiten schließen (Schleim: Reizdarmsyndrom; Blut-, Schleim-, Eiterauflagerungen: Morbus Crohn, Colitis ulcerosa). Im Stuhl können auch erkennbare Beimengungen, wie Parasiten oder unverdaute Nahrung in Folge von Verdauungsstörungen sowie ungenügendem Kauen, sein [102].

2.2.3.4. Volumen

Die Stuhlmenge bei einem gesunden Menschen ist abhängig von der Ernährungsform und schwankt zwischen 100 - 500 g täglich. Bei einer ballaststoffreichen Ernährung mit Vollkornprodukten kann diese auch bis zu 1000 g betragen [91]. Beim Fasten oder bei ballaststoffarmer Ernährung sind geringere Stuhlmengen, weniger als 100 g am Tag, charakteristisch. Geringe Mengen an Stuhl bei einer ausgewogenen Ernährung können auf eine Obstipation hinweisen. Sollte eine solche geringe Stuhlmenge eine schwarz- grüne Färbung aufweisen und aus Schleim- und Darmzellen bestehen, ist dies ein Zeichen für Hungerzustände [102]. Große Mengen an Stuhl, die nicht auf die Ernährung zurückzuführen sind, deuten auf eine verminderte Nährstoffausnutzung aufgrund von Beeinträchtigungen im Verdauungstrakt (Malassimilation) hin [90, 102].

2.3. Zusammenfassung und Fazit

Frailty ist ein multifaktorielles Syndrom, welches sich durch verminderte individuelle Reserven und der daraus folgenden erhöhten Vulnerabilität gegenüber internen und externen Stressfaktoren auszeichnet und damit zu einer erhöhten Morbiditäts- als auch Mortalitätsrate führt, siehe Abschnitt 2.1. Hier hat sich besonders Ernährung als wichtiger und modifizierbarer Faktor erwiesen. Entsprechend hat sich die Ernährungsberatung als fundamentale Maßnahme zur Prävention als auch zur Intervention bewährt, siehe Abschnitt 2.1.2.

Es existiert, wie im Abschnitt 2.2.2 beschrieben, zwar eine große Bandbreite an Methoden zur Erfassung des Verzehrverhaltens, jedoch eignen sich viele dieser Methoden nicht für die Zielgruppe dieser Arbeit. Da sich Betroffene oftmals in einem Zustand verminderter physischer und psychischer Belastbarkeit befinden, sind aufwändige Verfahren, wie die Wiegemethode, nicht geeignet. Das Tellerdiagramm, welches vom Personal geführt werden kann, belastet die Patient:innen zwar nicht, der Informationsgehalt des Tellerdiagramms würde aber nicht dazu ausreichen, die Verzehr- und Trinkmengen für den gesamten Tag zu erfassen, da etwaige Zwischenmahlzeiten nicht erfasst werden würden. Mitunter aus diesen Gründen werden Verzehr- und Trinkmengen von Frailty-Patient:innen häufig im

direkten Austausch zwischen Ernährungsberater:innen und Patient:innen mithilfe des 24h-Recall erhoben.

Das 24h-Recall fordert als retrospektive Methode jedoch eine hohe kognitive Leistungsfähigkeit, da sich die Patient:innen detailliert an alle Verzehr- und Trinkmengen erinnern müssen [53, 75, 76]. Insbesondere die Details, also nicht nur, ob Kaffee konsumiert wurde, sondern auch, in welchem Umfang Zucker, Süßstoff, Kaffeesahne oder Milch hinzugefügt wurden, spielen bei der Erfassung des Verzehrverhaltens häufig eine Rolle. Auch wenn sich Patient:innen detailliert an alle Getränke, Nahrungsmittel und Nahrungsergänzungsmittel erinnern können, und die Mengen mit der entsprechenden Genauigkeit wiedergeben, bekommen Ernährungsberater:innen dennoch nur eine Aussage über das Verzehrverhalten eines einzelnen Tages.

Neben dem Verzehrverhalten sind auch die körperliche Aktivität und das Gewicht (bzw. die Körperkompositionsdaten) wichtige Informationen für die Ernährungsberatung. Erfasst werden können diese Faktoren mithilfe von Instrumenten zur Erfassung des Frailty-Syndroms und des allgemeinen Ernährungszustands, siehe Abschnitt 2.1.1 und 2.2.1. Ebenso kann die Form und Beschaffenheit des Stuhls, wie in Abschnitt 2.2.3 beschrieben, wichtige Erkenntnisse über den Zustand von Patient:innen liefern. In der Regel werden die für die Ernährungsberatung relevanten Daten zum Verzehrverhalten, der Körperkomposition, der körperlichen Aktivität sowie des Stuhls in der direkten Interaktion zwischen Ernährungsberater:innen und Patient:innen erhoben. Die Qualität der Daten ist daher stark von der kognitiven Leistungsfähigkeit und der subjektiven Interpretation der Patient:innen abhängig. Besonders die Auskunft über Form und Beschaffenheit des eigenen Stuhls ist für viele Menschen mit Scham behaftet und erschwert die Erhebung von Daten. Alternative Erhebungsmethoden, z. B. die Fotomethode, mit der Patient:innen selbstständig Daten zur Form und Beschaffenheit ihres Stuhles erheben können, bringen auch Nachteile und Limitationen mit sich, siehe Abschnitt 2.2.3.

Durch die Hinzunahme der Daten aus der Betrachtung des Stuhls, der Körperkomposition sowie der körperlichen Aktivität, kann die Ernährungsberatung zielgerichteter und reaktiver auf individuelle Bedarfe von Patient:innen eingehen und hat damit ein größeres Potenzial, die Entstehung und den Verlauf des Frailty-Syndroms positiv zu beeinflussen. Sowohl die Qualität als auch die Quantität dieser Daten, insbesondere wenn diese auf analogen und retrospektiven Methoden zur Erhebung

beruhen, hängt jedoch stark von den Patient:innen und deren personellen Ressourcen ab. Weiterhin ist die oft notwendige, durch die Ernährungsberater:innen durchgeführte Digitalisierung analog vorliegender Daten, für die weiterführende Analyse, eine zusätzliche Fehlerquelle und verursacht zeitlich Aufwände seitens der Ernährungsberater:innen.

Es stellt sich somit die Frage, ob und wie der Prozess der Ernährungsberatung für vom Frailty-Syndrom betroffene Patient:innen unterstützt werden kann. Technik und Digitalisierung haben das Potenzial nicht nur die Qualität und Quantität der Daten zu verbessern, sondern gleichzeitig Patient:innen und Ernährungsberater:innen zu entlasten. Die hierzu durchgeführten Entwicklungen, Prototypen und Studien sind in Kapitel 4 angeführt. Die technischen Grundlagen für diese Entwicklungen sind im folgenden Kapitel 3 zusammengefasst.

Kapitel 3

Stand der Technik

Trotz der relativ kurzen Zeitspanne, in der das geriatrische Frailty-Syndrom erforscht wird, konnte schon eine Vielzahl von Faktoren ermittelt werden, welche sowohl auf die Entstehung als auch den Verlauf des Syndroms Einfluss nehmen können. Weiterhin konnte gezeigt werden, dass insbesondere der Faktor Ernährung eine zentrale Rolle spielt, siehe Abschnitt 2.1.2. Da die Ernährung sowohl im Kontext der Prävention als auch zur Intervention als ein beeinflussbarer Faktor gilt, z. B. durch Ernährungsberatung bzw. durch eine therapeutische Diät, fokussiert dieses Kapitel Technologien, welche zur Erfassung entsprechender Daten eingesetzt werden können. Neben dem Verzehrverhalten werden in diesem Kontext auch die Faktoren (körperliche) Aktivität und Körperkomposition betrachtet, da sich speziell diese drei Faktoren gegenseitig beeinflussen, siehe Abschnitt 2.1.

Die Erfassung von Daten, bezüglich der soeben genannten Faktoren, ist jedoch mit herkömmlichen (analogen) Methoden zur Datenerhebung nur begrenzt umsetzbar, sodass die für die Ernährungsberatung zur Verfügung stehende Datenmenge (Quantität) begrenzt ist. Zudem unterliegen herkömmliche Methoden, wie in den Abschnitten 2.2.2 und 2.2.3 beschrieben, oft weiteren Einschränkungen, z. B. durch die Abhängigkeit von einem Mindestmaß an kognitiver Leistungsfähigkeit, welche sich negativ auf die Daten (Qualität) auswirken können, siehe Anhang Tabelle A.1 und A.2. Wie schon im Fazit des vorherigen Kapitels beschrieben, bieten hier Technik und Digitalisierung eine Perspektive, um sowohl die Qualität als auch die Quantität der Daten zu verbessern.

Hierzu werden in den nächsten Abschnitten die wichtigsten technischen Entwicklungen angeführt. Dabei wird zunächst auf die digitale Datenerfassung eingegangen, welche perspektivisch dazu eingesetzt werden kann; teilweise auch schon wird; die genannten Faktoren (semi-)automatisiert, oder sogar ambient und digital zu protokollieren, siehe Abschnitt 3.1. Eine höhere Quantität und Qualität von Daten kann jedoch nur ein Zwischenschritt bei der Unterstützung der Ernährungsberatung für die Zielgruppe dieser Arbeit sein. Große Datenmengen ermöglichen zwar perspektivisch eine bessere Erfassung des Zustandes von Patient:innen, würden aber auch einen immensen Aufwand seitens Auswertung und Interpretation für Ernährungsberater:innen mit sich bringen. Eine solche Herangehensweise kann zwar sinnvoll sein, z. B. im Bereich der Forschung, jedoch nicht für das Ziel dieser Arbeit.

Hier kommt der Bereich der maschinellen Datenverarbeitung zum Tragen, welcher schon jetzt in Form von sogenannten Nahrungsmitteldatenbanken eingesetzt wird, siehe Abschnitt 2.2.2. In den letzten Jahren hat hier jedoch besonders, neben der klassischen Bildverarbeitung, der Forschungsbereich KI enorm an Bedeutung und Potenzial gewonnen, siehe Abschnitt 3.2.2.

Die generelle Eignung, der in den nächsten Abschnitten angeführten Methoden und Technologien sowie die Relevanz des Themas, wird durch die im Abschnitt 3.3 aufgeführten verwandten Arbeiten unterstrichen. Anschließend werden die wichtigsten Punkte der Kapitel zusammengefasst und in Form eines Fazits bewertet, siehe Abschnitt 3.4.

3.1. Datenerfassung

Die digitale Datenerfassung bezieht sich im Kontext dieser Arbeit auf den Prozess, analoge Informationen mithilfe von Computer- und Informationssystemen zu erfassen und digital zu speichern. Kern solcher Systeme sind i. d. R. Sensoren, welche es ermöglichen, Informationen aus unserer Umwelt und über uns selber zu erfassen. Hierzu wandeln Sensoren reale Größen, z. B. Druck, Position, Temperatur, Beschleunigung oder die Intensität einer elektromagnetischen Welle (Licht), mithilfe von entsprechenden Messprinzipien in (zumeist analoge) Messsignale um. Diese Signale werden i. d. R. an ein System weitergeleitet, um verarbeitet oder visualisiert zu werden [104]. So können Sensoren in einer Smartwatch zur Messung

von Schritten und Bewegungen oder in einer Augmented-Reality-Brille zur Erfassung der Umgebung (Verfolgung der Augen) eingesetzt werden [105]. Durch die technologischen Fortschritte im Bereich der Sensorik, vor allem im Hinblick auf Miniaturisierung und Optimierung von Herstellungsverfahren, sind immer leistungsfähigere Sensoren in immer leistungsfähigeren mobilen Endgeräten integriert. Derartige mobile Endgeräte fallen oft in die Gruppe der Wearable Technologien, kurz Wearables. Wearables beziehen sich auf am Körper getragene Technologieprodukte, z. B. Smartwatches, Aktivitätstracker oder Augmented-Reality-Brillen. Sensoren spielen für Wearables eine wichtige Rolle, da neue und performantere Sensoren oft auch neue Anwendungsfälle ermöglichen [105].

Wearables sind ein wichtiger Baustein im Kontext der Digitalisierung, da sie es ermöglichen Daten effizient zu erfassen, zu speichern und zu vernetzen. Insbesondere die Vernetzung von Wearables untereinander, aber auch mit anderen Geräten wie z. B. den Körperkompositionswaagen, führt zu immer mehr und höherdimensionalen Daten und Möglichkeiten. Eine derartige (und intelligente) Vernetzung wird als Internet der Dinge (engl. Internet of Things) (IoT) bezeichnet und erlaubt es, Daten aus verschiedenen Quellen zusammenzuführen [106]. Derartig vernetzte Systeme haben, insbesondere wenn sie kontinuierlich eingesetzt werden, ein enormes Potenzial für viele Bereiche, insbesondere jedoch für den Bereich der präventiven sowie kurativen personalisierten Gesundheit.

3.1.1. Digitalkameras

Die Entwicklung hochauflösender Digitalkameras, z. B. als integrierte Komponente von mobilen Endgeräten, hat dazu geführt, dass diese schon seit Jahren im Kontext der Erfassung des Verzehrverhaltens eingesetzt werden, siehe Abschnitt 2.3. Aus diesem Grund werden Digitalkameras in dieser Arbeit als integrierte Komponente mobiler Endgeräte verstanden. Mobile Endgeräte erfreuen sich nicht nur einer hohen Beliebtheit in jüngeren Bevölkerungsschichten, sie werden auch immer häufiger von der Zielgruppe dieser Arbeit verwendet. Diese Entwicklung wurde insbesondere durch die COVID-19 Pandemie beschleunigt und hat damit sowohl die Akzeptanz als auch die Verfügbarkeit dieser Geräte gesteigert [107].

Das grundlegende Messprinzip einer Digitalkamera, integriert oder als eigenes Gerät, ist es, Licht einzufangen und über den fotoelektrischen Effekt in elektrische

Signale umzuwandeln. Hierzu bestehen Kameras aus einer Vielzahl von Komponenten, wie z. B. Linsen, Spiegeln und Filtern, sodass die richtigen Spektren des Lichtes an die gewünschten Stellen auf dem sogenannten Bildsensor gelangen. Der Bildsensor ist damit die Kernkomponente und besteht aus einer Vielzahl (Millionen) von fotoelektrischen Elementen. Diese Elemente sind in einer gitterartigen Struktur angelegt. Jedes Element erzeugt ein eigenes Signal, welches zu einem Punkt im Raum einen Pixel im korrespondierenden digitalen Bild erzeugt [108]. Die als Belichtung bezeichnete Bestrahlung des Bildsensors kann mithilfe eines Rolling- oder eines Global-Shutters realisiert werden. Bei einem Rolling-Shutter wird der Bildsensor in Teilen belichtet, i. d. R. zeilen- oder spaltenweise. Alternativ kann die Belichtung des gesamten Bildsensors durch einen Global-Shutter erfolgen [109].

Das resultierende Bild kann, wenn es von der integrierten Kamera eines Smartphones oder Tablets erzeugt wurde, direkt mithilfe einer mobilen Anwendung verarbeitet werden. Die unmittelbare Analyse von digitalen Bildern auf mobilen Endgeräten ist nicht nur durch die in Abschnitt 3.1 angeführten immer leistungsfähiger werdenden Prozessoren möglich, sondern auch durch die Anpassung von Software und Hardware aufeinander. Das grundlegende Prinzip beruht dabei auf der Verschiebung von häufig ausgeführten Operationen auf dedizierte Hardware zur parallelen und sequentiellen Ausführung. Eine solche Herangehensweise entlastet nicht nur die zentrale Recheneinheit, sondern kann auch zur Vervielfachung der Ausführungsfrequenz führen [110].

3.1.2. Tiefenerkennung

Aufgrund der Erfahrung und Abstraktionsfähigkeit sind Menschen in der Lage, aus einem zweidimensionalen Bild mehr Informationen zu ziehen, als eine Maschine dies direkt ableiten könnte. So können Menschen oft intuitiv Objekte in einer Szene räumlich einordnen, bzw. einer Tiefe zuordnen. Über diese Meta-Informationen verfügen Maschinen jedoch nicht, sodass hierzu entsprechende Verfahren (Hardware als auch Software) entwickelt wurden. Das Einsatzspektrum derartiger Verfahren zur dreidimensionalen Rekonstruktion von Oberflächen ist sehr breit. Von der Medizin (Computertomografie und Magnetresonanztomografie) über die Schiff-, Luft- und Raumfahrt (Radar und Sonar) bis hin zum Bauwesen (Lidar) gibt es unzählige Anwendungsfälle [111, 112]. Immer häufiger erlauben schon kompakte

Einzelgeräte (z. B. Smartphones und Tablet-Computer) die Erfassung der Tiefe, z. B. für das nachträgliche Bearbeiten von Bildern oder für den Einsatz von Augmented Reality (AR) [113]. Gängige Verfahren sind hier Stereoskopie, Structured-Light und Time-of-Flight.

3.1.2.1. Stereoskopie

Das grundsätzliche Prinzip der Stereoskopie ist von der Tiefenwahrnehmung des Menschen inspiriert. Der Mensch ermittelt die Tiefe einer Szene, unter anderem, aus den unterschiedlichen Perspektiven der beiden Augen, welche von unserem Gehirn verarbeitet werden. Insbesondere die Verschiebung von Objekten bzw. Punkten zwischen diesen beiden Perspektiven spielt hierbei eine Rolle und ermöglicht uns Tiefe besser wahrzunehmen [114].

Bei der auf Kameras basierenden Stereoskopie werden ebenfalls Tiefeninformationen über die Verarbeitung von zwei, oder mehr, unterschiedlichen Perspektiven bzw. Bildern gewonnen. Bei der Verwendung von zwei Kameras (linke Kamera CL und rechte Kamera CR), einer festen Brennweite F sowie einem festen Abstand (*Baseline* B) zwischen den Zentren der Kameras (CL_C, CR_C), kann die Tiefe z eines realen Punktes p im Raum, bzw. der Abstand von p zu B , berechnet werden, siehe Abbildung 3.1.

Wendet man den Strahlensatz auf die Abbildung 3.1 an, so erkennt man, dass sich das große Dreieck proportional zum kleinen Dreieck verhält, es muss also gelten [116]:

$$\frac{B}{z} = \frac{B - (x_L - x_R)}{z - F}. \quad (3.1)$$

Durch Umformung ergibt sich dann [116]:

$$z = \frac{FB}{x_L - x_R}. \quad (3.2)$$

Da $x_L - x_R$ auch als Disparität d bezeichnet wird, lässt sich Gleichung 3.2 weiter vereinfachen zu [116]:

$$z = \frac{FB}{d}. \quad (3.3)$$




Abbildung 3.1.: Grundlegendes Prinzip der Stereoskopie, in Anlehnung an [115]

Damit die Disparität berechnet werden kann, müssen jedoch erst die zueinander korrespondierenden Punkte p_L und p_R ermittelt werden. Die Berechnung dieser Korrespondenzen ist das Kernproblem der Stereoskopie. Eine Möglichkeit dieses Problem zu adressieren, ist die Anwendung von Verfahren zur Mustererkennung, z. B. Template-Matching. Die Verschiebung der Perspektive oder auch ähnlich oder schwach texturierte Oberflächen führen jedoch schnell zu Mehrdeutigkeiten. Zudem benötigen diese Verfahren eine hohe Rechenleistung [110]. Ein Standard zur Reduzierung dieses quadratischen Problems auf ein lineares Problem ist die Epipolargeometrie, siehe Abbildung 3.2.

Sind die intrinsischen Parameter des eingesetzten Kamerasystems bekannt, so kann mithilfe einer Geraden durch die Punkte CL_C und CR_C sowie einer Geraden durch CL_C und p eine Ebene aufgespannt werden. Die Schnittpunkte der Geraden durch CL_C und CR_C werden als Epipole epo_L und epo_R bezeichnet und die Ebene als Epipolarebene ep_l_p , welche beide Kameraebenen schneidet. Dieser Schnitt wird als Epipolarlinie el_R von p_R bezeichnet. Die Projektion von p auf CR kann sich demnach nur auf el_R befinden. Kleinere Ungenauigkeiten, z. B. durch unpräzise Berechnungen oder Fertigungstoleranzen, können jedoch dazu führen, dass die Projektion des Punktes leicht von der Epipolarlinie abweicht. Trotz derartiger und

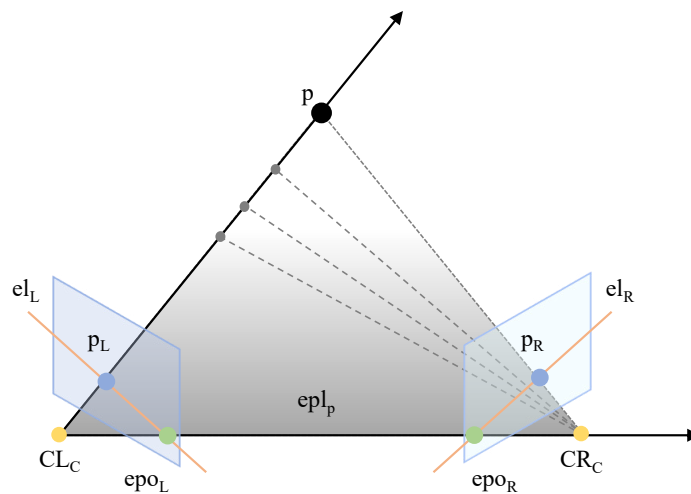


Abbildung 3.2.: Grundlegendes Prinzip der Epipolargeometrie, in Anlehnung an [115]

vieler weiterer Optimierungsalgorithmen benötigt die Berechnung der Disparität texturierte Oberflächen, damit die zueinander korrespondierenden Punkte ermittelt werden können. Als passives Verfahren, ohne eigene Lichtquelle, ist die Stereoskopie damit auch stark von der Beleuchtungssituation abhängig. Zudem führen die unterschiedlichen Perspektiven der Kameras dazu, dass eine Kamera ein Objekt bzw. einen Bereich erfassen kann und die andere Kamera nicht, da dieses Objekt bzw. dieser Bereich verdeckt wird. Dieses sogenannte *Shadowing* führt dazu, dass für diese Punkte die Tiefe nicht mithilfe des soeben vorgestellten Verfahrens berechnet werden können [115].

3.1.2.2. Structured-Light

Die grundlegende Idee des Structured-Light Prinzips ist die Projektion von bekannten geometrischen Mustern auf eine Szene, um dann auf Basis von Verzerrungen Tiefeninformationen zu berechnen [117]. Man unterscheidet hierbei vor allem zwischen Verfahren für dynamische und für statische Szenen. Bei dynamischen Szenen werden oft komplexere Muster, z. B. Muster mit einzelnen Farben, Farbverläufen oder gitterartigen Strukturen verwendet, um möglichst viele Informationen mit einer Aufnahme zu erfassen. Für statische Szenen liefern Muster, die sich über die Zeit verändern, z. B. binäre Muster oder Muster mit einer Phasenverschiebung,

die besseren Ergebnisse [117]. Das einfachste Muster kann durch einen Laser in Form eines Punktes oder einer Linie auf die Szene projiziert werden [115], siehe Abbildung 3.3.

Unabhängig von der Wahl des Verfahrens, bzw. des Musters, wird dieses von einem bildgebenden Sensor, i. d. R. einer Kamera, aufgenommen. Basierend auf den Entfernungen und Formen von Objekten in der Szene, wird das ursprüngliche Muster verzerrt. Auch Distanzen zu flachen Oberflächen ohne hervorstehende Konturen können mit dem Verfahren erfasst werden, z. B. durch ein Nachlassen der Intensität des Musters an dieser Stelle. Je geringer jedoch die Intensität, desto stärker wird dieses aktive Verfahren durch andere Lichtquellen beeinflussbar [118]. Ein großer Vorteil des Verfahrens ist jedoch, vor allem wenn infrarote Lichtquellen für die Muster verwendet werden, dass es sich mit auf Stereoskopie basierenden Verfahren zur Tiefenerkennung kombinieren lässt, wie es z. B. bei der Intel RealSense D435 der Fall ist.




Abbildung 3.3.: Grundlegendes Prinzip der Structured-Light Methode, in Anlehnung an [117]

3.1.2.3. Time-of-Flight

Das Time-of-Flight (TOF)-Prinzip beruht auf der Messung der Zeit, die ein ausgesendetes Signal benötigt, um zu einem Objekt und wieder zurückzugelangen.

Da die Geschwindigkeit des Lichtes bekannt ist, kann so die Distanz zu einem erfassten Punkt berechnet werden.

Je nach Einsatzgebiet werden unterschiedliche Emitter und Signale verwendet. In der Regel sind dies jedoch (Infrarot-)Lichtquellen wie Laser oder LEDs [119]. Damit handelt es sich um ein aktives bildgebendes Verfahren und benötigt keine externe Lichtquelle [115]. Als Signale werden entweder Impulse oder Sinusmodulationen verwendet. Bei den modulierten Signalen muss die theoretische maximale Reichweite d_{max} , also der Eindeutigkeitsbereich, berücksichtigt werden. Dieser lässt sich mithilfe der Lichtgeschwindigkeit c und der Frequenz des Emitters f berechnen [119]:

$$d_{max} = \frac{c}{2 \times f} \quad (3.4)$$

Verschiebt sich ein Objekt über die durch d_{max} gegebene Grenze, wird die reale Distanz als sehr viel geringere Distanz gemessen, da es zu einer Phasenverschiebung gekommen ist. Dieses Phänomen wird als *phase wrapping* bezeichnet und kann durch das sogenannte *phase unwrapping* adressiert werden [119].

Die signifikanten Vorteile des Verfahrens sind seine große Reichweite und hohe Abtastraten. Ein Nachteil des Verfahrens ist, dass das emittierte Signal auch reflektiert und detektiert werden muss. Die Detektion kann durch Interferenzen mit anderen externen Lichtquellen beeinträchtigt werden. Spiegelnde oder absorbierende Oberflächen und Ecken können die Reflexion beeinflussen und zu unerwünschten Effekten und schlechten Ergebnissen führen [119].

3.1.2.4. Darstellung

Unabhängig davon, welches der oben genannten Verfahren eingesetzt wird, können die gewonnenen Tiefeninformationen auf unterschiedliche Art und Weise repräsentiert werden. Insbesondere für die Visualisierung von Tiefeninformationen einer Szene werden häufig Tiefenbilder und Punktwolken eingesetzt, siehe Abbildung 3.4.

Tiefenbilder: Visualisiert werden kann die Tiefe, bzw. die Entfernung zur Kameraebene, über zweidimensionale Tiefenbilder. Tiefenbilder kodieren die Entfernung berechneter Punkte einer Szene mithilfe einer Farbskala. Dabei korreliert die Entfernung mit dem Verlauf der Farbskala. Die Farbinformationen über die Szene selber werden hier jedoch nicht angezeigt [115].


Punktwolken: Mit den Informationen aus den Tiefenbildern und dem verwendeten Kamerasetup lassen sich die Tiefeninformationen zu dreidimensionalen Koordinaten umrechnen. Werden diese Punkte in ein dreidimensionales Koordinatensystem gezeichnet, entstehen Ansammlungen von Punkten, die als Punktwolken bezeichnet werden [115].

Sowohl Tiefenbilder als auch Punktwolken können in einer kompatiblen Software direkt visualisiert werden. Da die Tiefeninformation bei Punktwolken direkt räumlich dargestellt wird, können diese auch Farbinformationen enthalten. Dabei muss berücksichtigt werden, dass auch eingefärbte Punkte bzw. Punktwolken keine dreidimensionalen Flächen darstellen, auch wenn dies durch die Zuweisung einer fixen Punktgröße zur Kolorierung den Anschein erweckt. Weiterhin gilt, dass die Rohdaten i. d. R. unvollständig sind. Wie auch bei der klassischen zweidimensionalen Bildverarbeitung, kommen hier zur Nachbearbeitung häufig Filter zum Einsatz (z. B. Temporale-Filter oder Kanten-Filter) ¹.

3.1.3. Aktivitätstracker


Neben den Kameras, welche dazu eingesetzt werden können z. B. das Verzehrverhalten oder die menschlichen Fäzes zu erfassen, können die im Abschnitt 3.1 angeführten Aktivitätstracker dazu eingesetzt werden, das physische Aktivitätsniveau zu erfassen. Aktivitätstracker können als Weiterentwicklung der Pedometer betrachtet werden. Das Ziel der ersten Pedometer war es, mithilfe von mechanischer Sensorik, Schritte zu zählen, um damit Rückschlüsse über die allgemeine körperliche Aktivität ziehen zu können. Aktuelle Aktivitätstracker verwenden

¹<https://www.intelrealsense.com/wp-content/uploads/2019/07/Intel-RealSense-Depth-PostProcess.pdf>, letzter Zugriff: 20.01.2023



(a) Beispielhafte Szene, die von der Intel RealSense D435 aufgenommen wurde

(b) Punktwolke, die aus den gewonnenen Tiefeninformationen erstellt wurde



(c) Ungefiltertes Tiefenbild der Szene

(d) Gefiltertes Tiefenbild

Abbildung 3.4.: Darstellung einer Szene, die mit einer Intel RealSense D435 aufgenommen wurde sowie des korrespondierenden Tiefenbildes und der korrespondierenden Punktwolke.

i. d. R. verschiedene Sensoren, um diese Funktionalität abzudecken und zu erweitern. Ziel dabei ist es, mithilfe von weiteren Sensordaten, z. B. Position, Umgebung oder Vitaldaten, weiterführende Analysen durchführen zu können [120]:

Bewegung: Mithilfe von Bewegungssensorik, z. B. realisiert über ein Akzelerometer und ein Gyroskop, können Beschleunigung und Lage erfasst werden, um daraus neben den Schritten auch Distanzen und Geschwindigkeiten abzuleiten zu können [121].

Position: Mithilfe des GPS kann die genaue Position eines Gerätes erfasst werden. Diese Sensorik kann ebenfalls dazu verwendet werden, Schritte, Distanzen und Geschwindigkeiten zu ermitteln. Weiterhin kann die Position auch dazu beitragen, lokale Informationen, wie Wetter und Höhenlage, mit einzubinden [121].

Umgebung: Einige Aktivitätstracker verfügen auch über Sensoren zur Erfassung von Temperatur, Luftdruck und Luftfeuchtigkeit. Diese Daten können dazu eingesetzt werden verschiedene aktivitätsbezogene Parameter genauer bewerten zu können [121].

Vitaldaten: Weiterhin erfassen erste Aktivitätstracker nicht nur die Herzfrequenz, sondern auch die Sauerstoffsättigung und Informationen zum Schlaf, welche ebenfalls dazu eingesetzt werden können, aktivitätsbezogene Parameter, z. B. Trainingsintensität oder Regenerationsdauer, abzuschätzen [121].

Zur Analyse und Visualisierung werden die resultierenden Daten i. d. R. an eine zugehörige Software übertragen. Hierbei handelt es sich, insbesondere im Konsumerbereich, um Online-Plattformen, welche Daten persistieren und anschließend an mobile Anwendungen weiterleiten. Seltener werden Daten direkt an mobile Anwendungen übertragen. Durch die Verknüpfung verschiedener Quellen, z. B. Aktivitätstracker und Körperkompositionswaagen, lassen sich individuelle Leistungsprofile erstellen, die es Nutzer:innen ermöglichen, die Entwicklung der eigenen Leistungsfähigkeit über einen längeren Zeitraum hinweg detailliert zu verfolgen [122].

Die Entwicklung von Aktivitätstrackern für den Konsumerbereich hat zwar zu schnellen technologischen Fortschritten und bezahlbaren sowie leistungsstarken Geräten geführt, bringt jedoch durch den „*One-Size-Fits-All*“-Entwicklungsansatz

vieler Anbieter auch Nachteile mit sich. So wird die oben beschriebene Verknüpfung und Analyse von Daten in der Regel mithilfe von IoT-Diensten der Anbieter erreicht und nur selten direkt auf den mobilen Endgeräten der Nutzer:innen [106]. Zwar sind die Sensoren in den Aktivitätstrackern häufig baugleich oder ähnlich, die eingesetzten Algorithmen unterscheiden sich jedoch meistens und gehören häufig zu den Firmengeheimnissen. Zudem können sich diese Algorithmen ohne Vorankündigung ändern [123]. Die zugehörige IT-Infrastruktur befindet sich oft außerhalb des Geltungsbereiches des europäischen Datenschutzes. Weiterhin stehen sich oft auch Usability und Leistungsfähigkeit als Ziele entgegen. Messwerte mit hoher Qualität und Quantität erfordern häufig umfangreichere Technik, z. B. größere Batterien/Akkus, größere Speicher und umfangreichere Sensorik. Derartige Anforderungen führen jedoch zu weniger preiswerten und komfortablen Aktivitätstrackern und damit zu Verminderung der Benutzerfreundlichkeit [124].

Insbesondere die Zielgruppe dieser Arbeit, bzw. die übergeordnete Zielgruppe der hochaltrigen Personen, hat spezielle Anforderungen an die Usability von Aktivitätstrackern. Studien zeigen, dass hochaltrige Personen grundsätzlich eine positive Einstellung gegenüber der Nutzung kommerziell erhältlicher Aktivitätstracker haben. Weiterhin konnte gezeigt werden, dass Aktivitätstracker dazu eingesetzt werden können, die individuelle Motivation für ein Selbst-Monitoring zu steigern [125, 126, 127, 128]. Dies wird auch durch eine Studie, welche im Kontext von Adipositas bei hochaltrigen Menschen durchgeführt wurde, bestätigt. In dieser konnte mithilfe von Aktivitätstrackern die individuelle Motivation und die körperliche Aktivität gesteigert sowie Blutdruck und Gewicht reduziert werden [129]. Andere Studien [125, 126, 127, 128] zeigen jedoch auch, dass die Bedarfe der Zielgruppe nicht optimal adressiert werden, sodass verschiedene Punkte negativ aufgefallen sind:

- Zahlreiche nicht eingesetzte Funktionen,
- mangelhafte technische Unterstützung,
- Unklarheit über Status des Systems,
- zeitliche Aufwendungen und
- finanzielle Aufwendungen.

Eine möglichst hohe Barrierefreiheit (Verpackung, Einrichtung, Verständnis der Funktionen), Benutzerfreundlichkeit sowie Benutzererfahrung kann nur erreicht

werden, wenn die altersbedingten Funktionseinschränkungen hochaltriger Personen berücksichtigt werden. In Anlehnung an [121], sollten hierzu (nicht ausschließlich) die folgenden Punkte adressiert werden:

- Optik wie bei herkömmlicher Armbanduhr
- Anzeige der Zeit wie bei einer herkömmlichen Armbanduhr
- sollte wasserdicht sein
- Armband sollte komfortabel sein
- Verwendung ansprechender Materialien
- einfache Einrichtung des Aktivitätstrackers
- detaillierte und einfache Anleitungen für die Einrichtung, die Nutzung und die Funktionsweise
- Ziele sollten an die der hochaltrigen Zielgruppe anpassbar sein
- Meldungen zum Fortschritt sollten sinnvoll, ansprechend und rechtzeitig erfolgen
- Aktivitätstracker sollten ein Display haben
- Daten sollten dazu verwendet werden auch aktuellen Fortschritt bis zum Erreichen des festgelegten Ziels anzuzeigen
- Erfassung weiterer biometrischer Daten (z. B. Blutzucker und Herzfrequenz)
- Möglichkeit zur Anzeige nicht-gesundheitsbezogener Daten

Weiterhin existieren Studien, die zeigen, dass das Tracking der körperlichen Aktivität mithilfe von Aktivitätstrackern für hochaltrige Personen besondere Herausforderungen mit sich bringt. Insbesondere geringe Gehgeschwindigkeiten und Gehhilfen führen zu signifikanten Abweichungen bei der Erfassung von Schritten bzw. von zurückgelegten Distanzen. Als mögliche Lösungen für diese Problematik wird dazu geraten, zusätzliche Sensoren an der Hüfte oder auch am Fußgelenk zu tragen [120, 130, 121].

3.1.4. Körperkompositionswaagen

Körperkompositionswaagen (engl. Body Composition Scales) (BCSs) oder intelligente Waagen (engl. Smart Scales) haben, wie auch die Aktivitätstracker, von den Fortschritten der Sensorik profitiert und sich zu komplexen Messsystemen entwickelt, welche neben dem Körpergewicht weitere Informationen erheben. Hierbei steht die Messung der verschiedenen Körperkompartimente, mithilfe des in Abschnitt 2.2.1 angeführten Prinzips der BIA, im Vordergrund. Ebenfalls wie bei den Aktivitätstrackern, oder auch bei der Obergruppe der Wearables, lassen sich BCSs mittels IoT-Diensten vernetzen. So gelangen diese Daten ebenfalls auf die in Abschnitt 3.1.3 beschriebenen Online-Plattformen und erreichen in vielen Fällen erst dann die mobilen Endgeräte bzw. mobilen Anwendungen der Nutzer:innen. Insgesamt wächst der Anteil der BCSs und erste Studien konnten zeigen, dass diese dazu beitragen können, sowohl die Anzahl von Messungen als auch einen antizipierten Gewichtsverlust zu steigern [131, 132].

Anders als die in Abschnitt 2.2.1 beschriebene BIA-Messung, erfolgt die Messung mit einer BCS aus dem Konsumerbereich nicht in Ruhelage, sondern stehend. Bis auf einige wenige Ausnahmen erfolgt die Messung nur über die Füße und nicht über Füße und Arme. Diese Art der Messung wird auch als Fuß-zu-Fuß (engl. Foot to Foot) (FtF)-BIA bezeichnet. Ein weiterer Unterschied ist, dass für die Messung kein Fachpersonal benötigt wird, welches Einwegelektroden mittels Gel aufkleben muss. Optisch unterscheiden sich viele BCSs nicht von herkömmlichen digitalen Körperwaagen. Auch bei den BCSs ist die Eingabe von Informationen über die zu erfassende Person (Alter, Geschlecht, Größe) in eine Software notwendig, damit eine Auswertung der FtF-BIA Messwerte erfolgen kann.

Wie auch bei den Aktivitätstrackern, bringt die schnelle Entwicklung von smarten Sensorsystemen für den Konsumerbereich, neben den Vorteilen, auch einige Nachteile mit sich. Zu den in Abschnitt 3.1.3 genannten Nachteilen bezüglich dezentraler Haltung und Analyse von Daten, sind nur wenige Studien über die Genauigkeit von BCSs bekannt. Eine dieser Studien wurde 2021 von Frija-Masson et al. [72] veröffentlicht und umfasst drei BCSs aus dem Konsumerbereich. In dieser Studie wurden die Body Partner (Tefal) von 53, die DietPack (Terraillon) von 52 und die Body Cardio (Withings) von 48 Proband:innen mit einer Altersspanne von 37-62 Jahren genutzt. Die Ergebnisse zeigen, dass das Körpergewicht von allen Waagen mit einer für viele Anwendungsfälle ausreichenden Genauigkeit erfasst werden

konnte. Die Fett- und die fettfreie Körpermasse wurden jedoch nur mit großen Ungenauigkeiten erfasst, siehe Tabelle 3.1.

Tabelle 3.1.: Übersicht über die Ergebnisse von Frija-Masson et al. [72].

Name (Hersteller)	Körpergewicht Fehler (Median)	Fettmasse Fehler (Median)	Muskelmasse Fehler (Median)
Body Partner (Tefal)	0,25 kg	-2,20 kg	4,50 kg
DietPack (Terraillon)	0,00 kg	-4,40 kg	-6,60 kg
Body Cardio (Withings)	0,25 kg	-3,70 kg	4,00 kg

Das grundlegende Prinzip der FtF-BIA, ohne Fokus auf spezielle Produkte, wurde 2015 umfangreich von Bousbiat et al. untersucht. Diese Arbeit führt an, dass die Messung in hohem Maße von den folgenden Faktoren abhängig ist [133]:

- Größe der Füße (Länge, Breite),
- Feuchtigkeit (Dusche, Schweiß),
- Position der Füße sowie
- Anspannung der Muskeln in den Beinen.

3.2. Datenverarbeitung

Durch die Entwicklung neuartiger und immer leistungsfähigerer Messsysteme, wie sie in den vorherigen Abschnitten dieses Kapitels angeführt wurden, ergibt sich das Potenzial große Mengen an Daten zu erfassen. Derartige Datenmengen, auch als *Big-Data* bezeichnet, müssen für die meisten Anwendungsfälle aufbereitet werden. Dies gilt auch, oder sogar insbesondere, für den Kontext dieser Arbeit. Die alleinige Bereitstellung großer Datenmengen, welche zwar digital verfügbar wären, aber um ein Vielfaches größer als aktuell in der Ernährungsberatung üblich, würden zu einem immensen Aufwand bzgl. der Datenverarbeitung auf Seiten des Fachpersonals führen. Eine derartige Herangehensweise wird somit nicht als zielführend betrachtet. Die direkte Verarbeitung der erhobenen Daten muss somit ein fester Baustein eines Systems zur Unterstützung der Ernährungsberatung von hochaltrigen und vom Frailty-Syndrom betroffenen Personen sein, um das Potenzial der Daten nutzbar zu machen. Aus diesem Grund fokussieren sich die

folgenden Abschnitte auf Verfahren zur Verarbeitung von Daten bildgebender Systeme, welche zur Erfassung des Verzehrverhaltens sowie der Fäzes eingesetzt werden können. Die Verarbeitung anderer Sensordaten wird in dieser Arbeit nicht explizit aufgeführt, da die Verarbeitung dieser Daten, wie in Abschnitt 3.1.3 und 3.1.4 bereits angeführt, häufig automatisch von den Algorithmen der jeweiligen Hersteller durchgeführt wird und Rohdaten ebenfalls nicht verfügbar sind.

3.2.1. Bildverarbeitung

Die Bildverarbeitung verfolgt das Ziel, Informationen aus einem Bild zu extrahieren, welche über die Einzelinformationen der Pixel hinausgehen. Das Anwendungsspektrum reicht dabei vom Zählen von Werkstücken [134], über die Unterscheidung verschiedener Arten von Körpergeweben in Computertomographie (engl. Computed Tomography) (CT)-Aufnahmen [135], bis hin zur Erfassung der Umwelt im Kontext des autonomen Fahrens [136].

Für die eben genannten, und für viele weitere Anwendungsfälle, ist oft eine Vielzahl von Schritten zur Bearbeitung der entsprechenden Bilder notwendig. Diese Schritte können in fünf Kategorien aufgeteilt werden: Bilderfassung, Vorverarbeitung, Segmentierung, Merkmalsextraktion und Klassifikation [137].

Die Bilderfassung wird dabei durch die eingesetzten Kamerasysteme abgedeckt. Die Vorverarbeitung von Bildern ist stark vom Anwendungsfall abhängig. Klassischerweise werden hier Filter eingesetzt, z. B. um Rauschen zu entfernen (Median-Filter) oder Defekte zu beseitigen (Morphologische-Operatoren). Die Merkmalsextraktion von Kanten, Varianzen oder Verteilungen von Farben kann ebenfalls über Filter realisiert werden und z. B. zur Segmentierung eingesetzt werden.

Auch die Klassifikation von Objekten ist mit Filtern möglich (Template-Matching). Jedoch bringt die Klassifikation von Objekten mithilfe von klassischen filterbasierten Algorithmen Nachteile mit sich. Durch den statischen Aufbau eines Filters sind diese Verfahren nicht robust gegenüber Effekten wie Rotation oder Skalierung. Die hierfür notwendige Eigenschaft, die Generalisierbarkeit von Problemen, wird durch den Forschungsbereich der KI adressiert. Insbesondere die letzten drei Schritte haben in den letzten Jahren stark von den Fortschritten der KI-Forschung profitiert [137].

3.2.2. Künstliche Intelligenz

Insbesondere in den letzten Jahren hat sich der Forschungsbereich KI rasant weiter entwickelt. Viele dieser Entwicklungen begegnen uns täglich, z. B. in Form von Sprachassistenten (Google Assistant, Siri oder Alexa), Chatbots (ChatGPT), Assistenzsystemen für autonomes Fahren oder indirekt in Form von personalisierten Produktvorschlägen im Online-Handel (Recommender Systeme) [138, 139, 140]. Zahlreiche Studien und Entwicklungen zeigen weiterhin, dass insbesondere die medizinische Versorgung von den Entwicklungen im Bereich Sensorik und KI profitieren wird [141, 142].

Unterschieden wird zwischen der *schwachen KI* und der *starken KI* [143]. Unter *schwacher KI* werden Verfahren zusammengefasst, welche in der Lage sind konkrete Probleme zu lösen, z. B. aus den oben genannten Bereichen. Durch eine Vielzahl technologischer Fortschritte, sind verschiedene Verfahren schon jetzt in der Lage, die menschlichen Fähigkeiten, auch die von Expert:innen, in verschiedenen Fachgebieten zu übertreffen. Die *starke KI* hingegen soll in der Lage sein Probleme aus vorher nicht bekannten Fachgebieten, oder auch Situationen, lösen zu können. Eine derartige KI wäre in der Lage, selbstständig und effizient auf Basis der aktuellen Problemstellung zu lernen [143]. Im Folgenden wird der Begriff KI synonym für Verfahren aus dem Bereich der *schwachen KI* verwendet. Weiterhin wird zwischen den Verfahren aus den Bereichen Maschinelles Lernen (ML) und Deep Learning (DL) unterschieden.

Der Forschungsbereich ML umfasst eine Vielzahl von Algorithmen, um Systeme mit Daten zu trainieren und damit Modelle zu erhalten. Diese Modelle erlauben es den Algorithmen eigenständige Entscheidungen oder Prognosen über vorher unbekannte Daten treffen zu können. Dabei wird in drei Hauptkategorien von Algorithmen unterschieden: überwachte, unüberwachte und bestärkende Lernverfahren. Beim überwachten Lernen besteht der sogenannte Trainingsdatensatz aus Eingabe- und Ausgabedatenpaaren, sodass während des Trainings ermittelt werden kann, ob das zu trainierende System die richtigen Ausgaben zur entsprechenden Eingabe vorhersagen kann. Man spricht auch von gelabelten Datensätzen. Überwachtes Lernen wird z. B. für Algorithmen aus den Bereichen Klassifikation und Regression eingesetzt. Unüberwachte Verfahren hingegen benötigen keine gelabelten Daten, da sie anhand der Eingabedaten und deren Merkmalen lernen. Bei der Cluster-Analyse werden die Eingaben auf Ähnlichkeiten untersucht und anhand dieser

verschiedenen Clustern zugeordnet [144, 145]. Das bestärkende Lernen trainiert einen auf Software basierenden Agenten in einer simulierten Umgebung Entscheidungen zu treffen, um eine maximale Anzahl an Belohnungen zu erhalten. Diese Art von Algorithmen wird oftmals für komplexe Steuerungsprobleme eingesetzt [146, 147].

Diese Arbeit fokussiert sich auf ML-Verfahren, die mit gelabelten Datensätzen trainiert werden und damit zur Klasse der überwachten Verfahren gehören. Beispiele für zwei derartige Gruppen von Verfahren sind die Support Vector Machines (SVMs) sowie die Künstlichen Neuronalen Netzwerke (KNNs).

3.2.2.1. Support Vector Machines

Wie schon angeführt, gehören Support Vector Machines (SVMs) zu den ML-Verfahren, die mit gelabelten Daten trainiert werden können. Der grundlegende Anwendungsbereich von SVMs ist, Modelle für binäre Entscheidungsprobleme zu trainieren. Das Modell wird durch eine sogenannte Hyperebene repräsentiert, welche die Klassen eines Trainingsdatensatzes im n -dimensionalen Raum möglichst ideal voneinander abgrenzt [148].

Dabei werden zwei grundlegende Herangehensweisen unterschieden, um die Hyperebene zu berechnen. Die harten Grenzen (engl. hard-margins) und die weichen Grenzen (engl. soft-margins). Bei den harten Grenzen wird bei der Berechnung der Hyperebene der Grenzbereich parallel zur Hyperebene maximiert. In diesem Bereich darf kein Datenpunkt liegen. Je breiter dieser Bereich ist, desto robuster ist eine SVM gegenüber Ausreißern. Liegen die Daten dicht beieinander oder existieren Ausreißer in den Trainingsdaten, können harte Grenzen zu schlechten Ergebnissen führen. Um dieses Problem zu adressieren, können die weichen Grenzen eingesetzt werden. Hierbei ist es erlaubt, dass einige wenige Punkte in den Randbereichen der Hyperebene liegen, wenn dadurch die Breite des Randes vergrößert werden kann, um eine höhere Genauigkeit bei der Klassifikation zu erreichen [148].

Ist eine SVM trainiert, bzw. konnte eine entsprechende Hyperebene berechnet werden, kann die SVM auf neue Daten reagieren und eine Klassifikationsprognose abgeben. Hierzu wird die sogenannte Abstandsfunktion verwendet. Sie berechnet den Abstand des Eingangsvektors zur Hyperebene [149].

Viele Entscheidungsprobleme basieren jedoch auf nicht direkt linear separierbaren Daten. Eine Möglichkeit dieses Problem zu adressieren ist der Einsatz sogenannter Kernels. Kernels modifizieren die Abstandsfunktion derart, dass die Dimensionen der Eigenschaftsvektoren unterschiedlich gewichtet werden. Verhält sich nur eine Dimension des Eigenschaftsvektors nicht-linear, z. B. quadratisch oder kubisch, so kann diese mit einem entsprechenden Kernel in der Abstandsfunktion ausgeglichen werden. Dieser sogenannte Kernel-Trick kann dabei auf alle Dimensionen eines Eigenschaftsvektors angewendet werden. Beispiele für übliche Kernel sind der Polynom-, der Sigmoid- und der Radial Basis Function (RBF)-Kernel [149].

One-vs-One: Trotz der im vorherigen Abschnitt angeführten Strategien für die Optimierung von SVMs, können mit den bisher angeführten Mitteln ausschließlich binäre Entscheidungsprobleme gelöst werden. Um dennoch Entscheidungsprobleme bzw. Klassifikationen mit multiplen Klassen lösen zu können, kann die *One-vs-One* Methode eingesetzt werden. Bei dieser Methode werden Entscheidungsprobleme mit multiplen Klassen in binäre Entscheidungsprobleme aufgeteilt. Damit muss für jede mögliche Kombination von Klassen ein eigenes Modell trainiert werden, sodass für n Klassen:

$$\frac{n(n-1)}{2} \tag{3.5}$$

SVMs trainiert werden müssen. Ausgegeben wird bei diesem Verfahren die Klasse, für die die meisten Modelle gestimmt haben [150].

One-vs-Rest: Eine ähnliche Strategie verfolgt die *One-vs-Rest* Methode. Bei dieser Methode werden multiple Klassen ebenfalls in binäre Entscheidungsprobleme aufgeteilt. Hier entstehen jedoch bei n Klassen n SVMs, da der Ansatz jede Klasse einmal mit allen anderen vergleicht. Je nach Verteilung der Eigenschaften kann es daher schwierig sein, mit der *One-vs-Rest* Methode ein repräsentatives Modell für die Daten zu erzeugen [150].

Für beiden Herangehensweisen ist es notwendig, dass ein gewisses Maß an statistischem und domänenbasiertem Wissen bzgl. der Daten und des zu adressierenden Anwendungsfalls existiert. Dieses Wissen ist notwendig, um aus hochdimensionalen Roh-Daten relevante Eigenschaften (engl. *Features*) zu extrahieren und so den Trainingsdatensatz zu erstellen. Eine solche Dimensionsreduktion führt nicht

nur zu einem reduzierten Rechenaufwand, sondern kann auch die Klassifikationsergebnisse signifikant verbessern. Ein weiterer Vorteil der SVMs ist, dass nach einer Klassifikation ermittelt werden kann, auf Basis welcher *Features* die entsprechende Klasse gewählt wurde. Je nach Datenmenge und -komplexität, kann Feature-Engineering jedoch sehr zeitaufwändig sein. Zudem besteht die Gefahr, dass komplexe *Features* übersehen werden. Es existieren jedoch auch ML-Verfahren, welche die direkte Eingabe von hochdimensionalen Daten ermöglichen und *Features* eigenständig berechnen, wie Verfahren aus dem Bereich der KNNs.

3.2.2.2. Künstliche Neuronale Netzwerke

Die Entwicklung von KNNs geht auf das sogenannte *McCulloch-Pitts-Neuron* zurück [151]. Später stellte Frank Rosenblatt das *Perzeptron*-Modell vor. Indem er die Eingänge eines jeden Neurons mit Gewichten (w) versah, erweiterte er das *McCulloch-Pitts-Neuron*, sodass die Ausgaben (o_j) nun nicht nur ausschließlich von den Eingaben, sondern auch von ihren Gewichten abhängig waren [152]:

$$o_j = \begin{cases} 1 & \sum_i w_{ij}x_i > \theta \\ 0 & \text{sonst} \end{cases} \quad (3.6)$$

Der Aufbau neuronaler Netze, die *Netz-Topologie* oder *Netz-Architektur*, umfasst die Anzahl an Schichten, die Anzahl von Neuronen pro Schicht und die Art und Weise, wie die einzelnen Neuronen in diesen Schichten miteinander verbunden sind. Grundlegende Architekturen sind [153]:

Vorwärts gerichtete neuronale Netze: Als vorwärts gerichtetes neuronales Netz (engl. Feedforward Neural Network) (FNN) werden Netze bezeichnet, bei denen die Ausgaben einer jeden Schicht nur an die nächste Schicht weitergegeben werden.

Rekurrente neuronale Netze: Neuronen in rekurrenten neuronalen Netzwerken (engl. Recurrent Neural Networks) (RNNs) haben nicht nur Verbindungen in die nächste Schicht, sondern haben auch Verbindungen in beliebige vorangegangene Schichten.

Tiefe neuronale Netze: Als tiefes neuronales Netzwerk (engl. Deep Neural Network) (DNN) wird ein Künstliches Neuronales Netzwerk (KNN) bezeichnet, wenn es aus mehr als drei Schichten besteht. Es also mehr als eine verdeckte Schicht gibt.

Eine Gemeinsamkeit von KNNs ist, dass Feature-Engineering nicht zwangsweise benötigt wird, da KNNs selbstständig lernen können, welche Eigenschaften für eine bestimmte Klasse ausschlaggebend sind. Damit ein Netz angelernt werden kann, ist zunächst ein gelabelter Datensatz notwendig, da die meisten KNNs zur Klasse der überwachten Lernverfahren gehören. Mithilfe eines gelabelten Datensatzes können die Gewichte eines Netzes über ein Lernverfahren angepasst werden, welche initial oft mit zufälligen Werten aus einem vorher festgelegten Intervall versehen werden. *Netz-Topologie* und Gewichte repräsentieren dann das Modell, welches für Prognosen bzw. Klassifikation eingesetzt werden kann [153].

3.2.2.3. Tiefe neuronale Netzwerke

Es hat sich gezeigt, dass sich im Kontext der Bilderkennung, Objekterkennung sowie Objektsegmentierung insbesondere DNNs als sehr leistungsstark erwiesen haben. Ein häufig für das Training von DNNs angewendetes Lernverfahren ist *Backpropagation*, welches insbesondere für mehrschichtige Netze entwickelt wurde. Für derartige Verfahren müssen spezielle Aktivierungsfunktionen für die Ausgabe der einzelnen künstlichen Neuronen verwendet werden, siehe Abbildung 3.5.

Diese Funktionen sind, im Gegensatz zur binären Impulsantworten, stetig und lassen sich ableiten. Über die Ableitung der Fehlerfunktion lassen sich die für das *Backpropagation*-Verfahren notwendigen Fehlergradienten berechnen. Diese werden dann rückwärts (engl. back) durch das Netz propagiert (engl. propagate). Anhand der Abweichung können so die Gewichte eines KNNs angepasst werden, um es schrittweise an den gelabelten Datensatz anzupassen [143].

3.2.2.4. Convolutional Neural Networks

Betrachtet man den aktuellen Stand der Kameratechnik in mobilen Endgeräten, so sind hier schon jetzt Bilder mit bis zu 200 Megapixeln möglich, wobei jeder Pixel aus den drei separaten Farbinformationen, üblicherweise rot, grün und blau

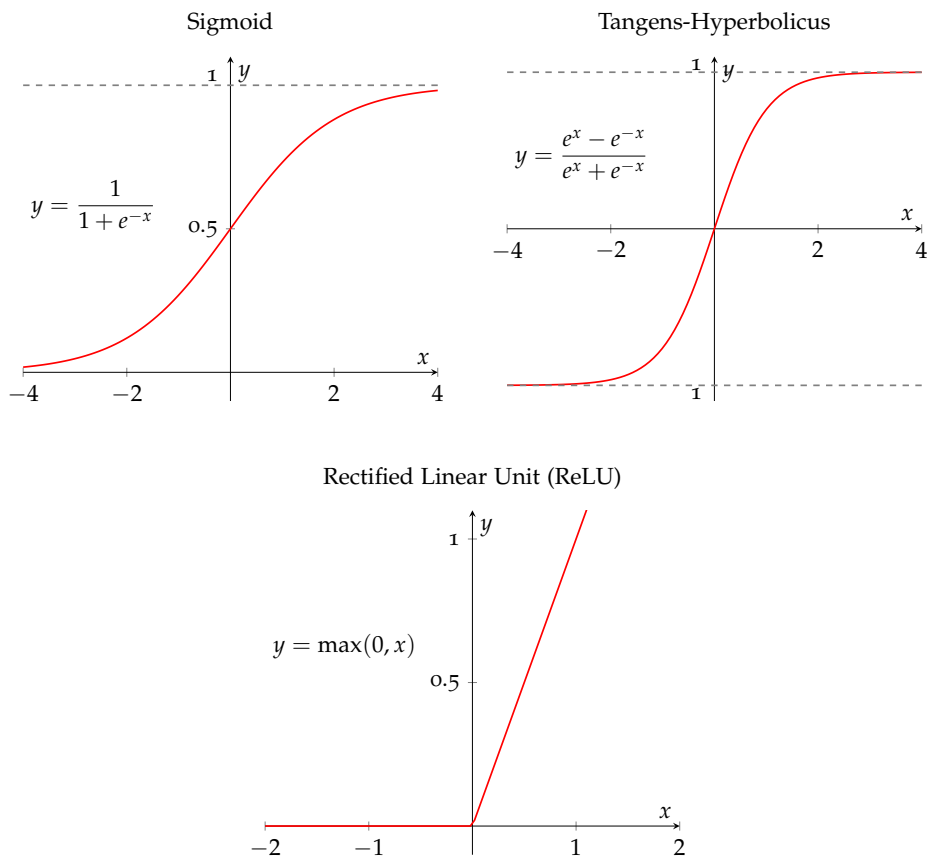


Abbildung 3.5.: Übersicht über die drei Aktivierungsfunktionen: Sigmoid, Tangens-Hyperbolicus und Rectified Linear Unit (ReLU)

(engl. Red, Green and Blue) (RGB), besteht, sodass ein Eingabevektor mit 6×10^8 Einträgen entstehen würde. Bei einer vollständig verbundenen Eingabeschicht mit nur 1×10^3 Neuronen würde dies zu einer Matrix mit 6×10^{11} Parametern führen. Überträgt man diese Werte auf ein DNN mit einer Vielzahl von Schichten, ergeben sich Größenordnungen, die sich mit dem aktuellen Stand der Technik nicht in angemessenen Zeiträumen verarbeiten lassen. Diese Art von Problemen fällt dabei unter den Begriff *Fluch der Dimensionen* [154]. Eine Möglichkeit diese Komplexität zu verringern ist die Reduktion der Dimensionalität des Eingabevektors, z. B. über *Downsampling*. *Downsampling* ist jedoch ein verlustbehaftetes Verfahren und kann nur begrenzt eingesetzt werden. Genau hier setzen die Convolutional Neural Networks (CNNs) an [143].

CNNs verwenden hierzu die aus der klassischen Bildverarbeitung bekannte Faltung (engl. convolution). Mithilfe der Faltung werden Filter-Kernel, mit einer üblichen Größe von 3×3 oder 5×5 Pixeln, auf ein Eingangsbild angewendet, um entsprechende *Features* zu erhalten. Diese *Features* werden dann in einer *Feature-Map* gespeichert. Üblicherweise werden mehrere Filter-Kernel verwendet und es entstehen zunächst in Summe mehr Daten, als durch das Eingangsbild direkt hätten verarbeitet werden müssen. Diese Schicht wird als *Convolutional-Layer* bezeichnet, siehe Abbildung 3.6 [143].

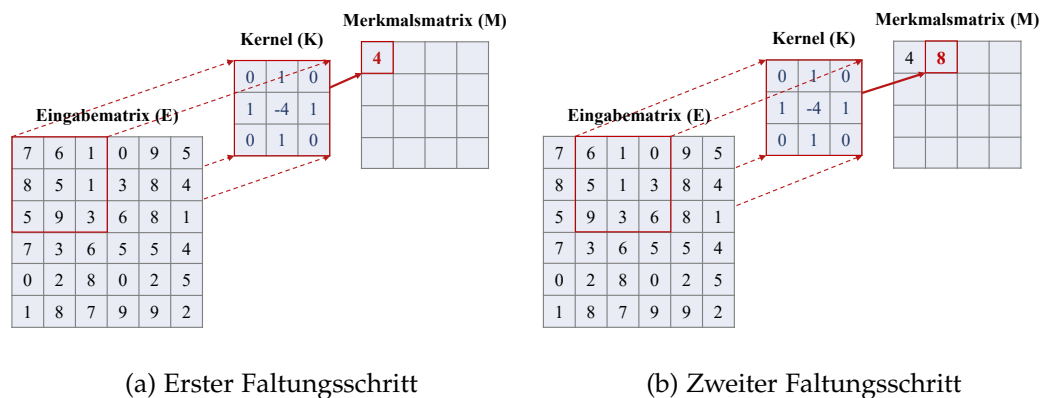


Abbildung 3.6.: Zwei beispielhafte Faltungen eines Eingangsbildes mit einem 3×3 Filter. Die Schrittweite beträgt hier einen Pixel.

Die Schrittweite des Filter-Kernels bei der Faltung ist eine Möglichkeit, um die Größe von *Feature-Maps* zu verringern, jedoch können so signifikante Informationen verloren gehen. Eine bessere Möglichkeit zur Reduktion der Dimensionalität wird

durch die sogenannte *Sammel- oder Bündelungsschicht* (engl. *Pooling-Layer*) erreicht, z. B. mit einem *Maximum-Filter*. Der *Maximum-Filter* erfasst nur die höchsten Werte in einer *Feature-Map*, unter der Annahme, dass diese auch die signifikantesten Merkmale widerspiegeln, wie Farben, Formen und Muster aus den Bildern, siehe Abbildung 3.7.




Abbildung 3.7.: *Convolutional-Layer* mit zwei Kernen und einem anschließendem *Pooling-Layer* mit einem 2×2 *Maximum-Filter*.

Convolutional- und *Pooling-Layer* können dabei beliebig hintereinander ausgeführt werden. Je weiter die Schichten dabei am Ende der Kette liegen, desto abstrakter können die resultierenden *Feature-Maps* werden. Die *Feature-Map* des letzten *Pooling-Layers* wird dann in einen Vektor überführt. Dieser Vektor kann dann als Eingabe für ein nachfolgendes KNN verwendet werden. Dieses KNN kann über eine beliebige Struktur verfügen, gehört jedoch i. d. R. zur Klasse der DNNs. Das Ergebnis der Klassifikation wird häufig über eine Soft-Max-Funktion realisiert. Diese Funktion gibt die Klasse aus, für die das CNN die höchste Aktivierung bzw. Wahrscheinlichkeit ausgibt. Trainiert werden CNNs mit gelabelten Datensätzen [143].

Basierend auf den skizzierten Strategien werden CNNs in den verschiedensten Bereichen erfolgreich zu Bilderkennung eingesetzt. Umfangreicher wird die Aufgabe der Klassifikation, wenn das Ziel nicht die Bilderkennung, sondern die Objekterkennung oder die Segmentierung ist. Die große Herausforderung bei der Objekterkennung liegt dabei nicht in der eigentlichen Erkennung der Objekte, sondern vor allem in der Lokalisierung dieser Objekte, bevor diese erkannt wurden. Beispiele für CNN-Entwicklungen im Kontext von Objekterkennung sind: Regionen mit CNN-Merkmalen (engl. *Regions with CNN features*) (R-CNN) [155], Fast R-CNN

[156], Faster R-CNN [157] sowie Single Shot Multibox Detector (SSD) [158] und You Only Look Once (YOLO) [159].

Für die Bewertung der Performanz von KI-Algorithmen gibt es eine Vielzahl von Metriken, welche je nach Anwendungsfall und Zielsetzung variieren können. Im Bereich der Objekterkennung werden häufig die folgenden Metriken eingesetzt [143]:

Genauigkeit: Ist definiert als der Anteil von korrekten Vorhersagen zu allen Vorhersagen. Wenn nicht anders angezeigt, wird in dieser Arbeit, mit Genauigkeit eines Klassifikators, die sogenannte TOP_1 -Genauigkeit angegeben. Bei der TOP_1 -Genauigkeit wird ein Objekt nur dann als richtig klassifiziert, wenn das Modell für dieses Objekt die höchste Wahrscheinlichkeit ausgibt. Analog dazu sind die TOP_3 - und TOP_5 -Genauigkeiten zu verstehen. Bei diesen gehen auch Objekte mit in die Berechnung der Genauigkeit der Klassifikation ein, wenn diese unter den höchsten drei bzw. höchsten fünf Wahrscheinlichkeiten liegen.

Präzision: Ist definiert als der Anteil der richtigen Vorhersagen zu allen Vorhersagen einer Klasse.

Intersection over Union (IoU): Wird verwendet, um die Genauigkeit der Lokalisation von Objekten zu beschreiben:

$$IoU = \frac{Area\ of\ Intersection}{Ground\ Truth\ Area + Predicted\ Box\ Area - Area\ of\ Intersection} \quad (3.7)$$

$$IoU = \frac{Area\ of\ Intersection}{Union} \quad (3.8)$$

mean Average Precision (mAP): Beschreibt die durchschnittliche Präzision der Objekterkennung über alle Klassen. Wenn nicht anders beschrieben, werden für die Berechnung der mAP-Werte in dieser Arbeit nur Klassifikationsergebnisse mit einer $IoU \geq 0.5$ berücksichtigt $mAP^{0.5}$.

R-CNNs: Die ursprüngliche Idee hinter R-CNNs geht auf die Arbeit von Girshick et al. zurück, welche in erster Version im November 2013 veröffentlicht wurde. Der R-CNN-Ansatz berechnet zunächst etwa 2000 Regions Of Interest (ROIs),

in denen Objekte vermutet werden. Girstick et al. wenden hierzu den *Selective-Search*-Algorithmus an, welcher gleichartige Bereiche im Eingabebild zu ROIs zusammenfasst [160].

Im nächsten Schritt werden *Feature-Maps* für jede ROI berechnet. Hierzu wird ein CNN eingesetzt. Die nachfolgende Klassifikation wird mit genau einer linearen SVM pro Klasse realisiert. Da dieser Algorithmus zwar innovativ, aber auch sehr langsam ist, wurde mit *Fast R-CNN* schon im April 2015 die erste konsequente Weiterentwicklung und im Juni 2015 mit *Faster R-CNN* die zweite Weiterentwicklung veröffentlicht [155, 156, 157].

SSDs: Die Arbeit von Liu et al., veröffentlicht im September 2016, beschreibt ein Verfahren, um Lokalisierung und Klassifizierung von Objekten in einem DNN durchzuführen. Trotz der Entwicklung von *Fast R-CNN* und *Faster R-CNN*, war es das Ziel von Liu et al. eine Möglichkeit zu finden, um die Klassifikation performanter zu realisieren.

Die grundlegende Idee hierbei ist, die ROIs der zu erkennenden Objekte während der Berechnung der *Features* durchzuführen. Hierzu wird eine bestimmte Anzahl von ROIs, mit unterschiedlichen Aspektverhältnissen und Größen, für jede *Feature-Map* vordefiniert. So ist das Netz in der Lage während der Berechnung der *Feature-Map* Vorhersagen über das Vorhandensein von Objekten innerhalb jeder ROI zu berechnen [158]. SSD gibt dabei jedoch nicht vor, wie diese klassifiziert werden sollen. Hier existieren verschiedene Ansätze. Ein auf der SSD-Methode basierendes und häufig eingesetztes Verfahren ist *MobileNetV2*, welches von Sandler et al. im März 2018 veröffentlicht wurde [161].

YOLO: Der YOLO-Algorithmus von Redmon et al., veröffentlicht im Juni 2015, gehört wie auch SSD zur Klasse der einstufigen Algorithmen zur Objekterkennung. Für YOLO müssen Bilder, sowohl für das Training als auch für die Klassifikation, einheitlich formatiert werden. Die so erzeugten Eingangsbilder werden dann in ein quadratisches Raster ($S \times S$) aufgeteilt. Jede Zelle in diesem Raster kann einen eigenen Satz unterschiedlicher ROIs, im Kontext von YOLO auch als Bounding Boxes (BBs) bezeichnet, besitzen. Für jede BB wird die Konfidenz bzw. die Vorhersage, engl. *Prediction (Pr)*, des Modells über das Vorhandensein eines Objektes $Pr(Object)$ in eben dieser BB berechnet. Redmon et al. setzen mit YOLO dabei die Konfidenz

auf 1, wenn ein Objekt vorhanden ist und auf 0, wenn ein Objekt nicht vorhanden ist. Weiterhin wird die Konfidenz mit der IoU gewichtet. Damit ergibt sich für jede BB einer jeden Zelle [159]:

$$Pr(Object) * IoU_{pred}^{truth} \quad (3.9)$$

Weiterhin wird für jede Zelle und jede mögliche Klasse die Wahrscheinlichkeit der Zugehörigkeit berechnet. Damit lässt sich folgende Formel formulieren, um die klassenspezifische Konfidenz für jede BB zu erhalten [159]:

$$Pr(Class_i|Object) * Pr(Object) * IoU_{pred}^{truth} = Pr(Class_i) * IoU_{pred}^{truth} \quad (3.10)$$

Sowohl diese Schritte, als auch die eigentliche Klassifikation, werden bei YOLO in einem Durchgang, in einem CNN, berechnet. Damit erreicht YOLO signifikant höhere Klassifikationsfrequenzen (Bildraten), als Verfahren, die auf dem R-CNN-Prinzip beruhen. Die unterschiedlichen mAP-Werte für zwei Standard-Datensätze für die Objekterkennung sind in Abbildung 3.8 dargestellt.

3.3. Verwandte Arbeiten

Sowohl die in Abschnitt Datenerhebung als auch die in Abschnitt Datenverarbeitung beschriebenen Technologien wurden schon früh in verschiedenen Konstellationen dazu eingesetzt Systeme für die Erfassung von gesundheitsbezogenen Daten zu entwickeln. Die im Folgenden aufgeführten Arbeiten fokussieren sich dabei auf die Unterstützung der Erhebung des Verzehrverhaltens mittels mobiler Endgeräte. Zunächst werden hierzu erste Forschungsarbeiten aufgeführt, welche diese Problemstellung mit KI-Methoden adressieren, ohne dies auf eine spezielle Zielgruppe anzuwenden. Danach wurden erste Arbeiten veröffentlicht, die sich auf die Zielgruppe der hochaltrigen Personen beziehen. Diese werden im Folgenden chronologisch aufgeführt. Speziell auf Arbeiten zur Einbindung von *Wearables* wird in diesem Abschnitt nicht eingegangen, da diese schon in den Abschnitten 3.1.3 und 3.1.4 angeführt wurden und die Weiterentwicklung ebendieser nicht Ziel dieser Arbeit ist.

Puri et al. beschreiben 2009 die Entwicklung einer mobilen Anwendung zur Erfassung des Verzehrverhaltens mittels KI. Das Food Intake Visual and Voice Recognizer (FIVR)-System verwendet hierfür Sprache und multiple Bilder einer Mahlzeit.

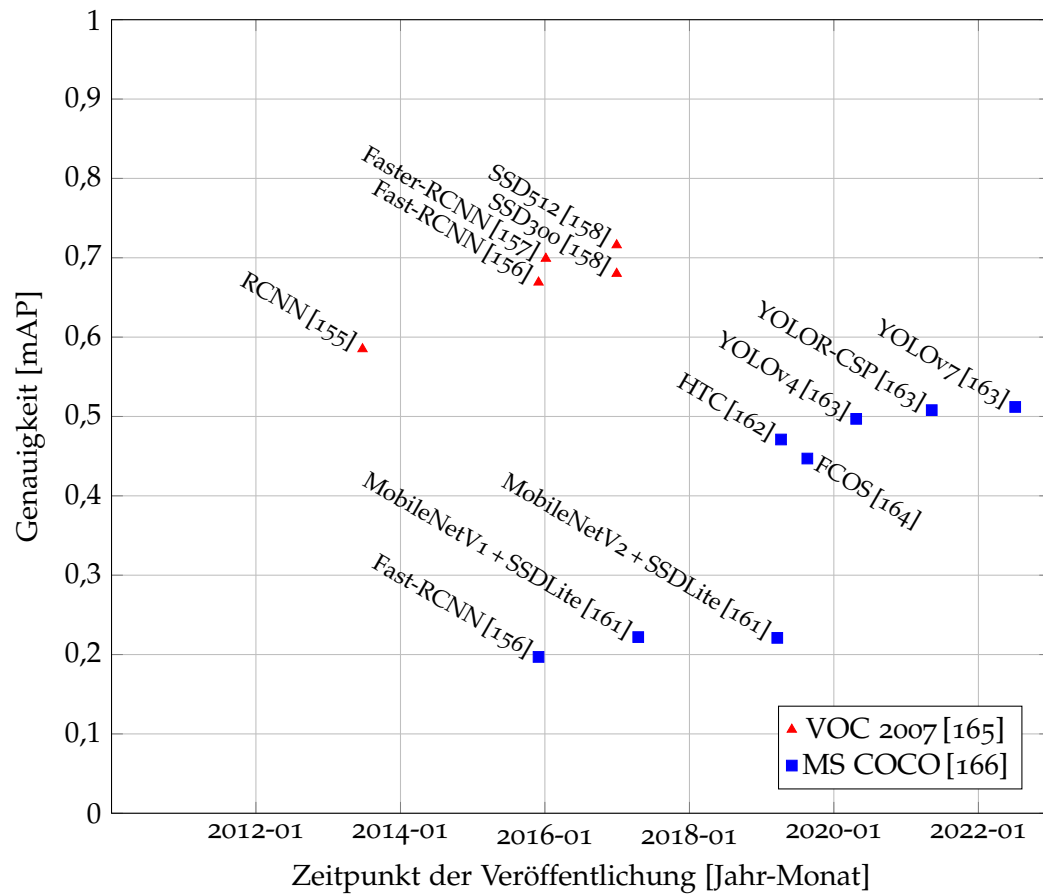


Abbildung 3.8.: Übersicht über die mAP unterschiedlicher Algorithmen für die Objekterkennung zweier Standard-Datensätze.

Beides wird dann an ein externes System übertragen. Bevor die Bilder aufgenommen werden können, muss das System mittels verschiedener Schachbrettmuster kalibriert werden, um sowohl Farbe als auch Entfernung zu kalibrieren. Die Klassifikation, welche ebenfalls extern durchgeführt wird, erfolgt mittels SVMs, welche für jedes mögliche Paar von Nahrungsmitteln separat trainiert wurde. Für die Schätzung des Volumens, auch extern, erfolgt zunächst die Schätzung der Position der Kamera, da hier verschiedene Aufnahmen aus verschiedenen Winkeln benötigt werden. Danach werden die notwendigen Tiefeninformationen ermittelt. Durch das Zusammenführen von Tiefeninformationen und Klassifikation ermöglicht das System auch die Segmentierung von Objekten. Auf Basis der segmentierten Objekte erfolgt die Berechnung der Volumina. Laut Angabe von Puri et al. liegt die Genauigkeit ihres Systems bei der Klassifikation für sechs Objekte bei etwa 90 % und der durchschnittliche Fehler bei der Berechnung des Volumens bei $5,75 \pm 3,75$ % [167].

Oliveira et al. beschreiben 2014 ebenfalls ein System zur Erfassung des Verzehrverhaltens mit mobilen Endgeräten und KI. Entwickelt wurde dieser Ansatz dabei im Kontext der Ernährungsberatung für Personen, die von Adipositas betroffen sind. Wie auch das System von Puri et al., erfolgt die Klassifikation durch SVMs. Ausgeführt wird diese jedoch nicht auf einem externen System, sondern auf einem mobilen Endgerät. Im ersten Schritt müssen Nutzer:innen die Mahlzeit mit der integrierten Kamera des mobilen Endgerätes aufnehmen. Danach müssen die Mittelpunkt der verschiedenen Komponenten einer Mahlzeit von den Nutzer:innen festgelegt werden. Über einen Algorithmus, *Region-Growing* von [168], werden diese Punkte bis zu den vermeintlichen Grenzen der zugehörigen Objekte vergrößert. Anschließend werden verschiedene *Features* dieser Regionen ermittelt. Diese *Features* bilden den Eingabevektor für die Klassifikation mittels SVMs [169].

Kawanao et al. verfolgen mit ihrer Arbeit von 2015 eine ähnliche Strategie wie Oliveira et al. und beschreiben ebenfalls ein System, welches mittels *Features* und SVMs Objekte klassifiziert. Diese Objekte müssen dafür von den Nutzer:innen zunächst im Bild lokalisiert werden. Hierzu legen diese ein viereckiges Fenster, eine ROI, um jedes zu klassifizierende Objekt. Im Bereich der ROIs ermittelt das System zugehörige *Features*, aus denen die Eingabevektoren für die SVMs generiert werden. Das Volumen wird nicht vom System automatisch berechnet und muss wie die ROIs von den Nutzer:innen eingegeben werden [170].

Shang et al. haben 2011 ein System zur Schätzung von Lebensmittelmengen entwickelt. Das Lasermodul projiziert ein Muster auf eine Oberfläche, das von der Kamera des Smartphones aufgezeichnet wird. Anhand der Verzerrungen im Muster werden Tiefenbilder für die Volumenschätzung erzeugt. Der Vorteil dieser Methode ist die vollständige Erfassung des Objekts und das daraus resultierende vollständig geschlossene 3D-Modell, das für die Schätzung des Objektvolumens verwendet wird. Hierfür wird allerdings ein mit dem Smartphone kompatibles Lasermodul benötigt. Darüber hinaus müssen insgesamt sechs Laserscans rund um das Objekt durchgeführt werden, um eine Messung zu erhalten. Dies muss zweimal erfolgen, wenn man das Volumen der verzehrten Lebensmittelmengen messen möchte [171].

Wenyan Jia et al. schätzen das Volumen von Lebensmitteln ebenfalls mittels Smartphone. Hier wird ein mathematisches Modell eines Referenzobjekts erstellt. Zusammen mit einem zweidimensionalen Bild von Lebensmitteln wird ein 3D-Objekt erzeugt. Referenzobjekte können geometrische Grundfiguren sein, z. B. Kugel oder Quader. Diese Methode hängt damit stark vom Referenzobjekt ab. Für die Volumenschätzung werden in diesem Ansatz einzelne Objekte auf einfachen Platten verwendet [172].

Die Arbeit von Waltner et al. von 2015 adressiert das Verzehrverhalten im Kontext kardiovaskulärer Erkrankungen. Hierzu klassifiziert das System Nahrungsmittel direkt, sobald die Kamera des mobilen Endgerätes auf diese gerichtet wird. Weiterhin werden den Nutzer:innen Informationen über das Nahrungsmittel, z. B. Mikro- und Makronährstoffe, mitgeteilt. Neben den Nährwerten gibt das System auch Informationen über die gesundheitlichen Auswirkungen der jeweiligen Nahrungsmittel an und schlägt alternative Nahrungsmittel vor. Für die Klassifikation verwendet das System den *Random Forest*-Algorithmus [173]. Die Autoren geben für ihr System *MANGO-12* auf einem mobilen Endgerät mit 12 Klassen eine *TOP-1*-Genauigkeit von 80,30 % an, eine *TOP-2* Genauigkeit von 92,28 % und eine *TOP-3*-Genauigkeit von 97,20 %. Für ihr System *MANGO-35* mit 35 Klassen, bei dem die Klassifikation auf einem externen System durchgeführt wird, geben Waltner et al. eine *TOP1*-Genauigkeit von 67,25 %, eine *TOP2* Genauigkeit von 85,97 % und eine *TOP3*-Genauigkeit von 91,97 % an. Das Training des Systems basiert dabei auf einem eigens erstellten Datensatz, welcher ausschließlich aus Früchten und Gemüse besteht [174].

In der Arbeit von Zhang et al. von 2015 wird ein System beschrieben, welches sowohl die Erhebung als auch die Klassifikation von Daten direkt auf einem mobilen Endgerät mittels SVMs ermöglicht. Dieses wurde mit einem eigens erstellten Datensatz trainiert und basieren auf verschiedenen *Features*. Insgesamt unterstützt das System 15 unterschiedliche Nahrungsmittel, für die die Autoren eine Genauigkeit für die Klassifikation von 85 % angeben. Weiterhin zählen Zhang et al. mit ihrem System die Pixel der einzelnen erkannten Objekte, um darüber das jeweilige Volumen zu schätzen. Konkrete Angaben über die Performanz der Volumenschätzung machen Zhang et al. nicht [175].

Ein Jahr später veröffentlichten Hakobyan et al. in ihrer Arbeit ein System zur Unterstützung älterer Personen bei der Erfassung ihres Verzehrverhaltens. Dabei fokussieren sich die Autoren auf Personen, die von einer altersbedingten Degeneration der Makular betroffen sind. Die mobile Anwendung beruht dabei nicht auf KI, sondern auf einer auf die Zielgruppe angepassten Darstellung über Piktogramme. Basierend auf den Ernährungsempfehlungen für die Zielgruppe und dem aktuellen Verzehrverhalten, werden individualisierte Ernährungsempfehlungen auf einem externen System generiert und durch die Anwendung an die Nutzer:innen weitergegeben. Insgesamt wurden zwei Studien durchgeführt. Eine Vorstudie über einen Zeitraum von sieben aufeinander folgenden Tagen mit insgesamt neun Proband:innen (6 weiblich, 3 männlich, mittleres Alter 77 Jahre) und eine Studie über sechs Wochen mit sechs Proband:innen aus der Vorstudie (4 weiblich, 2 männlich, mittleres Alter 77 Jahre). Hakobyan et al. geben an, dass die explorativen Ergebnisse der Studien auf einen signifikanten Einfluss von Nützlichkeit und Usability auf die Akzeptanz hinweisen. Weiterhin unterstützt die Anwendung nicht nur bei der Protokollierung des Verzehrverhaltens, sondern trägt auch zu einer gesünderen Ernährung bei [176].

Die Arbeit von Ahmad et al. von 2016 beschreibt die Entwicklung einer mobilen Anwendung für die Erfassung von Ernährungsgewohnheiten, die als *Mobile Food Record*(mFR) bezeichnet wird. Wie auch bei dem System von Puri et al. werden die von den Nutzer:innen aufgenommenen Daten an ein externes System geschickt und dort klassifiziert, segmentiert und quantifiziert. Die Ergebnisse werden dann zurück an die mobile Anwendung geschickt. Eine Besonderheit des Systems ist, dass die Nutzer:innen die Möglichkeit haben dem System Feedback zu geben, sodass dieses fortlaufend verbessert werden kann [177].

2017 veröffentlichten Salim et al. ihre Arbeit und stellten damit das Ernährungstagebuch *Nutrihealth* für mobile Endgeräte vor. *Nutrihealth* ist für ältere Menschen entwickelt worden, um diese bei der Erfassung ihres Verzehrverhaltens zu unterstützen und auf Basis dieses Verzehrverhaltens Vorschläge zu generieren, die zu einem gesünderen Verzehrverhalten führen. Eine Studie mit neun Teilnehmer:innen (Alter zwischen 50 – 59 Jahren) über drei Tage ergab, dass die Proband:innen Mahlzeiten durch die Anwendung sorgfältiger auswählten. Eine automatische Erkennung von Nahrungsmitteln, Getränken oder Nahrungsergänzungsmitteln wird durch diese Anwendung nicht unterstützt [178].

Eine weitere mobile Anwendung mit der Bezeichnung *Salus* wurde 2019 von Orso et al. vorgestellt. Auch diese mobile Anwendung wurde entwickelt, um ältere Menschen bei der Protokollierung ihres Verzehrverhaltens zu unterstützen. Dabei fokussieren Orso et al. sich, wie auch Salim et al. [178], auf einen nutzerzentrierten Designansatz. In einer ersten Vorstudie ließen die Autoren 12 Proband:innen (6 weiblich, 6 männlich, mittleres Alter 69,7 Jahre $SD = 4.5$) verschiedene Ernährungstagebücher für den breiten Konsumermarkt (Yazio, Lifesum) aus ihrer jeweiligen Sicht bewerten. In einer zweiten Studie wurden die verschiedenen Bedarfe der Zielgruppe mithilfe von 8 Proband:innen erfasst (5 weiblich, 3 männlich, mittleres Alter 68,8 $SD = 3,9$). Auf Basis der Ergebnisse der ersten beiden Studien wurde *Salus* entwickelt. Die Usability von *Salus* wurde in einer dritten Studie erfasst. Diese Studie lief über einen Zeitraum von einer Woche mit insgesamt 14 Proband:innen (7 weiblich, 7 männlich, mittleres Alter 67,3 Jahre $SD = 4,48$). Die Funktionalität von *Salus* ist auf drei Elemente aufgeteilt: Eine Übersicht über alle Kategorien von Nahrungsmitteln, eine Übersicht über vorausgewählte Kategorien, in der die Nutzer:innen auch die Menge eingeben können, und ein Element, indem die Nutzer:innen ihr Körpergewicht eingeben können. Insbesondere die letzte Studie hat gezeigt, dass sich die Nutzer:innen ein möglichst breites Spektrum an verfügbaren Nahrungsmitteln wünschen. Weiterhin hat die Studie ergeben, dass die Zielgruppe die Usability für gut befunden hat [179].

Bezüglich der Unterstützung bei der Erfassung der Fäzes, bzw. der Stuhlform, gibt es weniger zahlreiche Veröffentlichungen. Eine aktuelle und relevante Arbeit wurde 2020 von Park et al. veröffentlicht und beschreibt ein System zur automatisierten Messung von Stuhlformen. Neben der Klassifikation des Stuhls misst das System auch die Dauer der Defäkation und die Menge des Urins [180].

2011 veröffentlichten Al-Razgan et al. eine Zusammenfassung von Forschungsarbeiten über die Gestaltung von auf Touch-basierenden Schnittstellen für ältere Menschen. Dabei adressieren Al-Razgan et al. die mit dem Alter einhergehenden (senso-)motorischen und kognitiven Einschränkungen. Hierzu fasst die Arbeit die recherchierten Informationen in einem Katalog mit drei Hauptkategorien zusammen: Look & Feel, Funktionalität und Interaktion [181]:

Look & Feel:

- Größere mobile Endgeräte mit größeren dreidimensional wirkenden Tasten für die Touch-Eingabe,
- separate Tasten für Zahlen und Buchstaben,
- guter Abstand zwischen Tasten und
- größere Schrift für Texte und beschriftete Icons.
- Zudem sollten die wichtigsten Funktionen direkt über eine beschriftete Schaltfläche und nicht über die Menüführung erreichbar sein.

Funktionalität:

- Das Adressbuch sollte, neben Nummern und Bildern, auch einen Schnellzugriff auf andere Funktionalitäten beinhalten, z. B. 1 für Kalender.
- Die wichtigsten Navigationselemente sollten auf allen „Seiten“ gleich platziert sein und kritische Funktionen sollten niemals verschwinden. Wichtige Funktionen sollten oben auf dem Bildschirm platziert werden, um versehentliche Berührungen zu vermeiden.
- Zusätzlich wünschen sich ältere Personen spezielle Tasten für die folgenden Aktionen:
 - Eine Taste, um zum Ausgangszustand zurückzukehren,
 - eine Sperrtaste, um versehentliches Wählen zu verhindern,
 - eine Paniktaste für Notfälle
 - und eine Taste, um einen Anrufer/eine Anruferin bzw. die zugehörige Nummer auf die Sperrliste zu setzen.

- Weiterhin sollte bei der Entwicklung sorgfältig auf die Benennung von Programmen und Befehlen geachtet werden und es dürfen weder zu viele noch zu wenig Funktionen für ein spezielles Interface für ältere Menschen vorgesehen werden.

Interaktion:

- einfaches rein- und heraus-zoomen
- tippen mit akustischer Bestätigung für ältere Menschen mit eingeschränktem Sehvermögen
- ältere Menschen bevorzugen Sprachanrufe, Zeitlupenübergänge sowie Schaltflächen, aber keine Drag-and-Drop Aktionen
- die Schnittstelle sollte auch klar zum Ausdruck bringen, wo sich der Benutzer im Dialog befindet und welche „Aufgaben“ aktiv sind
- ausziehbare Tastaturen werden als störend empfunden
- wenn die Berührung beim Ziehen verloren geht, sollte das Objekt dort bleiben, wo es verlassen wurde
- das gleiche Objekt sollte nicht mit Aktionen überladen werden, die durch Antippen und Ziehen ausgeführt werden
- Bei Nichtnutzung sollte der Bildschirm sich nicht ausschalten, um Verwirrung zu vermeiden.

3.4. Zusammenfassung und Fazit

Die Anzahl von Wearables, sowie die Anzahl anderer Geräte zur Erfassung von Daten mit Bezug zur persönlichen Gesundheit, wächst ständig. Dies gilt insbesondere für Produkte aus dem Konsumerbereich. Gleichzeitig verfügen diese Produkte jedoch über immer mehr und leistungsfähigere Sensorik zu geringen Kosten. Auch die Verfügbarkeit resultierender Daten wächst, z. B. durch IoT-Technologien, wie Cloud-Dienste.

Gleichzeitig entwickeln sich auch die Hardware und Software für die Analyse und Auswertung der soeben genannten Daten schnell weiter. Die Kombination von immer leistungsfähiger werdenden Algorithmen, siehe Abschnitt 3.2.2, und Hardware

erlaubt es schon jetzt selbst komplexe Auswertungen und Analysen direkt auf den mobilen Endgeräten der Nutzer:innen durchzuführen, siehe Abschnitt 3.3.

Damit ergibt sich ein wachsendes Spektrum von Perspektiven für neuartige, aber auch für erweiterbare Anwendungsfälle, wie in Abschnitt 3.3 Verwandte Arbeiten angeführt. Das Fazit aus dem Kapitel 2.3 Medizinischer Hintergrund, dass Technik und Digitalisierung das Potenzial haben, die Ernährungsberatung für hochaltrige und vom Frailty-Syndrom betroffene Personen zu unterstützen, kann damit aus Sicht dieses Kapitels unterstrichen werden. Jedoch muss berücksichtigt werden, dass der psychische als auch physische Zustand von Personen, die vom Frailty-Syndrom betroffen sind, besondere Bedarfe mit sich bringen kann, welche sich durchaus signifikant von den Bedarfen einer robusten hochaltrigen Zielgruppe unterscheiden können. Bei der Entwicklung von Aktivitätstrackern und Körperkompositionswagen sowie der zugehörigen Software für den Konsumerbereich werden diese Bedarfe häufig nicht berücksichtigt, sodass Usability und Akzeptanz nicht ideal auf diese Zielgruppe abgestimmt sind. Dies wird sowohl durch die Arbeit von Al-Razgan et al. [181], welche im vorherigen Abschnitt angeführt wurde, als auch durch die zahlreichen Unsicherheiten und Probleme von hochaltrigen Personen mit Aktivitätstracker (engl. Activity Tracker)s (ATs) unterstrichen, siehe Abschnitt 3.1.3. Bezüglich des FtF-BIA-Prinzips existieren zwar Untersuchungen, wie präzise dieses für ältere Personen funktioniert, jedoch sind zum aktuellen Zeitpunkt keine Veröffentlichungen zur Usability von BCSs für die Zielgruppe dieser Arbeit bekannt.

Ein wichtiger nächster Schritt ist damit zunächst die Frage zu klären, ob es für die Zielgruppe der hochaltrigen und vom Frailty-Syndrom betroffenen Personen grundsätzlich Produkte gibt, welche zwar für den Konsumerbereich entwickelt wurden, aber dennoch die Anforderungen der Zielgruppe erfüllen, um von dieser eingesetzt werden zu können. Auch wenn professionelle und damit perspektivisch genauere ATs existieren, so sind auch diese nicht immer auf die Bedarfe der Zielgruppe dieser Arbeit angepasst. Weiterhin gibt es Personen innerhalb der Zielgruppe, bei denen die Erkennung von Schritten durch z. B. eine Gehhilfe schwierig ist. Gerade jedoch das multifaktorielle Frailty-Syndrom führt zu einer Zielgruppe mit einem breiten Spektrum an Einschränkungen, sodass insgesamt nicht davon ausgegangen werden kann, dass eine ökologisch und ökonomisch sinnvolle „One-Size-Fits-All“-Lösung existiert. Zudem gilt für die BCSs zwar, dass die Messung der Körperkompartimente über das FtF-BIA Prinzip signifikante Schwankungen auf-

weist, jedoch ist auch hier die besondere Herausforderung die Usability sowie die Akzeptanz für die Zielgruppe dieser Arbeit. Alternativen zur digitalen Erfassung der Körperkompartimente mittels FtF-BIA aus dem Konsumerbereich sind zum aktuellen Zeitpunkt nicht bekannt.

Diese Argumentation gilt nicht nur für die ATs und BCSs, sondern speziell auch für die Erfassung des Verzehrverhaltens. Wie auch die ATs und BCSs entwickeln sich digitale Ernährungstagebücher für den Konsumerbereich stetig weiter und entsprechende mobile Anwendungen erfreuen sich einer großen Beliebtheit. Hier konnte jedoch schon durch verschiedene Arbeiten gezeigt werden, dass sich diese digitalen Ernährungstagebücher nicht für die Zielgruppe der hochaltrigen Personen eignen [179, 178], sodass hier evaluiert werden müsste, in welchem Umfang die Bedarfe der robusten hochaltrigen Personen mit den Bedarfen der vom Frailty-Syndrom betroffenen Personen übereinstimmen.

Kapitel 4

Eigene Ansätze

Wie in Kapitel 2 beschrieben, ist eine gesunde und ausgewogene Ernährung ein elementares, präventives und kuratives Mittel im Kontext des Frailty-Syndroms. Oft wird Ernährungsberatung eingesetzt, um eine solche gesunde und ausgewogene Ernährung zu erreichen. Da die Erhebung von notwendigen Daten für die Ernährungsberatung in der Regel analog durchgeführt wird, kann diese auch den Nachteilen einer retrospektiven sowie analogen Erhebung unterliegen. Dies gilt nicht nur für die Erhebung von Getränken, Nahrungsmitteln und Nahrungsergänzungsmitteln (im Folgenden auch als Verzehrverhalten bezeichnet), sondern auch für die oft ebenfalls relevanten Daten bezüglich körperlicher Aktivität, Körperkomposition und Stuhl, siehe Abschnitt 2.3, A.1 und A.2.

Die steigende Anzahl von mobilen Anwendungen für das Protokollieren des Verzehrverhaltens und des Stuhlgangs zeigt, dass eine digitale Erfassung dieser Daten generell möglich ist. Dies gilt auch für das breite Spektrum an Sensoren für die digitale Erfassung von körperlichen Aktivitäten und Körperkompositionsdaten. Für derartige Anwendungen und Sensorik gilt in der Regel jedoch, dass diese nicht für die Zielgruppe dieser Arbeit entwickelt wurden. Daher müssen diese entweder für die Zielgruppe neu entwickelt oder mithilfe dieser auf ihre Usability, in Bezug auf den Anwendungsfall, überprüft werden [15].

4.1. Digitales Ernährungstagebuch und Sensorik

Ziel dieses Abschnittes ist es zu untersuchen, ob und in welchem Maße die für die Ernährungsberatung von hochaltrigen Personen relevanten Daten mithilfe von mobilen Anwendungen und Sensorik digital erhoben werden können. Neben der Fokussierung auf die Erfassung des Verzehrverhaltens, wird auch die Erfassung von körperlichen Aktivitäten und Körperkompositionsdaten untersucht. Durch die Verknüpfung des medizinischen Hintergrunds und des aktuellen Stands der Technik hat sich folgende Forschungsfrage eröffnet:

„Auf welche Art und Weise lassen sich Technologie und Digitalisierung nutzen, um hochaltrige Personen, die vom Frailty-Syndrom betroffen sind, eine selbstständige Erfassung relevanter Informationen für die Ernährungsberatung zu ermöglichen?“

Ebenfalls sollte ermittelt werden, ob es dieser Zielgruppe grundsätzlich möglich ist, körperliche Aktivität und Körperkompositionsdaten, mit entsprechender technischer Unterstützung (Sensorik), selbstständig und digital zu dokumentieren. Eine große Herausforderung war, dass die Zielgruppe dieser Arbeit nur wenig oder gar keine Erfahrungen mit mobilen Anwendungen, Sensoren oder ähnlichen Technologien hatte und dementsprechend unsicher im Umgang mit diesen war.

Zu diesem Zweck wurde ein digitales Ernährungstagebuch entwickelt, welches speziell auf die Bedürfnisse der Zielgruppe angepasst wurde. Außerdem wurde entsprechende Sensorik für die Erfassung von körperlicher Aktivität und Körperkompositionsdaten aus existierenden Produkten ausgewählt.

Sowohl das digitale Ernährungstagebuch als auch die Sensorik wurden in einer ersten Feldstudie mit der Zielgruppe evaluiert und entsprechende Daten über die Usability erhoben, siehe Abschnitt 4.1.4. Aufbauend auf den Ergebnissen der ersten Studie wurde das digitale Ernährungstagebuch weiterentwickelt, um eine verbesserte Usability zu erreichen, da diese einen direkten Einfluss auf die Qualität der Daten hat [182]. Diese zweite Version des digitalen Ernährungstagebuchs wurde dann erneut in einer Feldstudie mit der Zielgruppe evaluiert, siehe Abschnitt 4.1.8. Das methodische Vorgehen wird im Nachfolgenden erläutert.

4.1.1. Methoden

Die Anforderungen für die Entwicklung des DND Version 1 (DNDv1) und für die Auswahl der Sensorik, wurden in enger Zusammenarbeit zwischen Expert:innen aus den Fachbereichen Ernährungsberatung, Geriatrie und Softwareentwicklung iterativ erarbeitet. Hierzu wurden unterschiedliche Personas sowie auf diesen Personas aufbauende Problem- und Lösungsszenarien erarbeitet, siehe Anhang Abschnitt A.1.

Die Problemszenarien beschreiben den aktuellen Stand der Ernährungsberatung für die Zielgruppe dieser Arbeit aus Sicht der Praxis und wurden darum maßgeblich von den Ernährungsberater:innen erstellt. Diese wurden dann mit den Softwareentwickler:innen diskutiert und weiterentwickelt, um ein gemeinsames Verständnis zu entwickeln, wie die Herausforderungen im Kontext der Ernährungsberatung für vom Frailty-Syndrom betroffene Personen mithilfe von Technik und Digitalisierung adressiert werden können.

Auf Basis der Problemszenarien wurden von den Entwicklern Lösungsszenarien entwickelt. Diese beschreiben, wie die Prozesse der Ernährungsberatung mithilfe von Technik und Digitalisierung unterstützt werden könnten, um die Probleme aus den Problemszenarien zu adressieren. So konnten aus den Unterschieden zwischen den Problem- und den Lösungsszenarien die entsprechenden Anforderungen extrahiert werden.

Die Szenarien und die extrahierten Anforderungen haben die in Abschnitt 2.3 beschriebenen Nachteile der retrospektiven und analogen Erfassung von Daten bestätigt. Die Lösungsszenarien haben aufgezeigt, dass eine mobile und speziell auf die Bedarfe der Zielgruppe angepasste Anwendung für die selbstständige Erhebung des Verzehrverhaltens das Potenzial haben, viele dieser Nachteile zu adressieren. Mit einem solchen mobilen und digitalen Ernährungstagebuch wären Frailty-Patient:innen in der Lage, ihr Verzehrverhalten unmittelbar nach einer Mahlzeit über mehrere Tage zu dokumentieren, sodass perspektivisch neben der Qualität auch die Quantität der Daten gesteigert werden könnte. Gleichzeitig werden die Ernährungsberater:innen entlastet, da die zeitintensive und fehleranfällige Erfassung des Verzehrverhaltens mit analogen Fragebögen und anschließender manueller Digitalisierung entfallen könnte [15].

Aus den Szenarien und dem intensiven Austausch mit den Expert:innen hat sich weiterhin herausgestellt, dass für eine erfolgreiche therapeutische Ernährungsberatung, neben dem Trink- und Verzehrverhalten, auch weitere Daten wichtig sind. Hierzu gehören vor allem die Körperkompositionsdaten sowie Daten zu körperlichen Aktivität der Patient:innen, siehe Abschnitt 2.2.1. Weiterhin wurden speziell die verminderten individuellen Reserven sowie die in der Regel geringere Technikaffinität der Zielgruppe, von den Expert:innen wiederholt unterstrichen. Tägliches Laden von Smartwatches und Aktivitätstrackern sowie Touch-Displays mit kleiner Schrift haben eine geringe Akzeptanz in der Zielgruppe. Die abgeleiteten Anforderungen zielten somit auf eine möglichst ambiente Sensorik ab, welche mit einem minimalen Aufwand von der Zielgruppe eingesetzt werden kann. Aufgrund des breiten Spektrums existierender Sensorik, wurden keine eigenen Messsysteme entwickelt, sondern mit den Expert:innen jeweils potenziell geeignete Sensorik für die Erfassung der körperlichen Aktivität und der Körperkompositionsdaten ausgewählt, siehe Abschnitt 4.1.3.

Zudem wurden die Empfehlungen von Al-Razgan et al. bezüglich *Look & Feel*, *Funktionalität* und *Interaktion* bei allen Entwicklungen sowie bei der Auswahl der Sensorik berücksichtigt, siehe Abschnitt 3.3.

4.1.2. Implementierung DNDv1

Wie bereits erwähnt, wurde die erste Version des digitalen Ernährungstagebuchs DNDv1 mit der Prämisse entwickelt, dass die Erfassung des Verzehrverhaltens so intuitiv wie möglich zu gestalten ist. Die weitestgehend lineare Struktur zur Navigation, wie sie in Abbildung 4.1 dargestellt ist, wurde dabei von der Praxis der Ernährungsberater:innen und den analogen Protokollen zur Erfassung des Verzehrverhaltens abgeleitet. Auch die Ernährungsberater:innen starten die Erfassung mit dem Frühstück und gehen dann durch die einzelnen Mahlzeiten des Tages und fassen das weitere Verzehrverhalten unter den Zwischenmahlzeiten zusammen. Darüber hinaus erlaubt das DNDv1 die Auswahl eines spezifischen Tages für das prospektive sowie das retrospektive Protokollieren des Verzehrverhaltens wie auch die nachträgliche Überprüfung und Änderung von Einträgen.

Bei der iterativen Implementierung des digitalen Ernährungstagebuchs, und vor allem seiner grafischen Benutzeroberfläche, wurden Faktoren wie die Verwendung

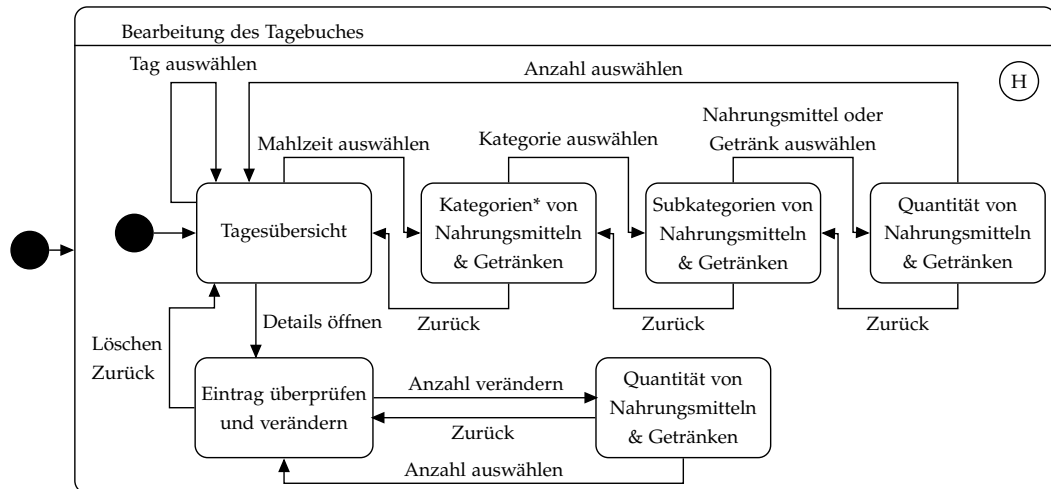


Abbildung 4.1.: Navigationsstruktur des DNDv1 als UML-Zustandsdiagramm mit allen möglichen Navigationsschritten, bzw. Zuständen, bei der Erfassung des Verzehrverhaltens.

einfacher Sprache und die zusätzliche Visualisierung von Inhalten durch Piktogramme berücksichtigt. Ein regelmäßiger Austausch zwischen den Expert:innen, wurde etabliert, um die der Implementierung zugrunde liegenden Anforderungen nicht zu verfehlen und weiteres Feedback von den Expert:innen in die Entwicklung einfließen zu lassen.

Während der Nutzung des digitalen Ernährungstagebuchs werden alle Nutzerinteraktionen im Hintergrund automatisch protokolliert. Dabei werden neben dem Element, mit dem Nutzer:innen interagieren, auch die Nutzer:innen ID und die aktuelle Systemzeit gespeichert, sodass die Navigationspfade der Nutzer:innen retrospektiv nachgestellt werden können. Diese Informationen können dazu verwendet werden, ein besseres Verständnis für aufgetretene Probleme oder generelle Unsicherheiten bei der Nutzung der Anwendung zu gewinnen. Diese zusätzliche Protokollierung wurde in die Anwendung integriert, da Feedback von Nutzer:innen, in diesem Fall Studienteilnehmer:innen, weder vollständig noch objektiv sein kann. Ein Feedback ist unter anderem von verschiedenen persönlichen und situativen Faktoren abhängig [183].

Das DNDv1 wurde so konzipiert, dass es auf einem mobilen Gerät installiert werden kann. Beim Einschalten des Geräts wird das DNDv1 automatisch gestartet

und im Vordergrund angezeigt. Sollte das Gerät aufgrund eines leeren Akkus oder durch ein versehentliches Ausschalten neu gestartet werden müssen, startet das DNDv1 automatisch beim Systemstart und zeigt die aktuelle Tagesübersicht an.

Da das DND Version 2 (DNDv2) eine konsequente Weiterentwicklung des DNDv1 ist, und bei der Weiterentwicklungen keine grundlegenden Änderungen vorgenommen wurden, wurde darauf verzichtet an dieser Stelle eine in großen Teilen redundante Beschreibung des DNDv1 anzuführen. Eine umfangreiche Beschreibung der Funktionalität des DNDv1 ist im Abschnitt 4.1.7 Implementierung DNDv2 ab Seite 77 zu finden.

4.1.3. Sensorik

Wie bereits im Abschnitt 3.1 erwähnt, gibt es eine Vielzahl an Aktivitätstrackern für den Konsumermarkt. Aus diesem Grund wurde der verwendete Aktivitätstracker (engl. Activity Tracker) (AT) und die Körperkompositionswaage (engl. Body Composition Scale) (BCS) nicht selbst entwickelt, sondern aus der breiten Palette existierender Produkte ausgewählt. Für die Messung der Daten zur Körperzusammensetzung wurde die intelligente Körperwaage Withings® Body Cardio ausgewählt. Sie wurde aufgrund ihrer flachen Bauweise, der großen Standfläche und des großen beleuchteten Bildschirms ausgewählt. Weiterhin verfügt die Waage über eine mehrmonatige (abhängig von der Nutzung) Laufzeit, siehe Abbildung 4.2a.

Zur Messung der körperlichen Aktivität wurde die Withings® Activité Pop aufgrund ihrer Handhabung, der optischen Ähnlichkeit zu herkömmlichen Armbanduhrn sowie einer langen Batterielaufzeit (etwa 6 Monate) verwendet. Zudem ist das Gerät bis zu einer Tiefe von 50 m wasserdicht, sodass sie von der Zielgruppe 24 Stunden am Tag getragen werden kann. Ein An- und Ablegen des AT kann somit entfallen, siehe Abbildung 4.2b.

4.1.4. Studiensetting DNDv1

Auch wenn sowohl bei der Entwicklung des digitalen Ernährungstagebuchs als auch bei der Auswahl der Sensorik auf Expert:innenwissen zurückgegriffen wurde, musste evaluiert werden, ob und in welchem Umfang die Bedarfe der Zielgruppe der hochaltrigen und vom Frailty-Syndrom betroffenen Personen abgedeckt



(a) Withings® Body Cardio

(b) Withings® Activité Pop

Abbildung 4.2.: Übersicht über die Sensorik

wurden. Zu diesem Zweck wurde 2018 eine monozentrische Querschnittsstudie durchgeführt. Dem entsprechenden Antrag bei der medizinischen Ethikkommission (2016-103) wurde am 11.10.2017 stattgegeben.

Rekrutierung: Die Rekrutierung von Studienteilnehmer:innen und die Erhebung der Daten erfolgte dabei auf der geriatrischen Rehabilitationsstation des Rehabilitationszentrums Oldenburg. Potenzielle Studienteilnehmer:innen wurden über einen Informations-Flyer über die Inhalte der Studie in Kenntnis gesetzt. Bei Interesse erfolgte eine entsprechende Aufklärung über die Inhalte der Studie und das Einholen der Einwilligung zur Studienteilnahme durch Studienmitarbeiter:innen. Da es sich um eine Beobachtungsstudie handelte, wurde auf ein Randomisierungsverfahren verzichtet. Eine Teilnahmevergütung für die Studienteilnehmer:innen erfolgte nicht.

Teilnehmer:innen: Einschlusskriterien für die Teilnahme geriatrischer Patient:innen an der Studie war ein Mindestalter von 70 Jahren und eine stationäre Aufnahme in die geriatrische Rehabilitationseinrichtung. Ausschlusskriterien für die Studie war die fehlende Fähigkeit zur Einwilligung in die Studie.

Weitere Ausschlusskriterien waren eine unzureichende Fähigkeit, die Studieninhalte und die Durchführung zu verstehen oder die Teilnahme an anderen Studien.

Eine unzureichende Mobilität, z. B. durch Bettlägerigkeit, war ebenfalls ein Ausschlusskriterium, da diese nicht in der Lage gewesen wären, die Studie im vollen Umfang durchzuführen.

Das Frailty-Syndrom bzw. der Frailty-Phänotyp wurden nicht erfasst, da alle Komponenten auch generell für geriatrische Patient:innen geeignet sein sollten, sodass diese auch in der Prävention eingesetzt werden können. Weiterhin ist durch die Studie von Wojzischke et al., welche an der gleichen Einrichtung durchgeführt wurde, bekannt, dass sich zu 63,8 % fraile, zu 33,6 % pre-fraile und zu 2,5 % robuste Patient:innen in der Einrichtung befinden, basierend auf einer Befragung von insgesamt 122 geriatrischen Patient:innen [184].

Studienablauf: Die Aufgabe der Studienteilnehmer:innen bestand darin, eine Mahlzeit, das Mittagessen des aktuellen Tages, mithilfe des DNDv1 aufzuzeichnen. Hierzu bekamen die Studienteilnehmer:innen eine Einführung zur Anwendung des DNDv1. Diese Einführung beinhaltete die beispielhafte Eingabe einer kompletten Mahlzeit und umfasste etwa 25 Minuten. Durchgeführt wurde die Einführung auf einem 10-Zoll Tablet-Computer. Dieser Tablet-Computer sowie die Sensorik wurden den Studienteilnehmer:innen für die Durchführung der Studie zur Verfügung gestellt. Die Körperkompositionswaage sollte von den Studienteilnehmer:innen zur Messung ihres Körpergewichtes verwendet werden. Der Aktivitätstracker hingegen sollte während einer 90 Minuten dauernden physiotherapeutischen Maßnahme getragen werden.

Fragebögen und Erhebungen: Neben dem Alter und dem Geschlecht, wurden auch die Technikbereitschaft der Studienteilnehmer:innen sowie die Usability des DNDv1, des AT und der BCS aus Sicht der Studienteilnehmer:innen erhoben. Aufgrund der speziellen Zielgruppe der Studie wurde bei der Auswahl der Fragebögen auf eine möglichst kurze und einfache Methode zur Erhebung geachtet.

Die Technikbereitschaft der Teilnehmer:innen wurde mithilfe des Technology Commitment (TC) Fragebogens nach Neyer et al. erhoben [185]. Dieser Fragebogen umfasst insgesamt zwölf Fragen. Diese Fragen decken dabei die Bereiche Technologieakzeptanz, -kompetenz und -kontrolle ab und sind einmal positiv und einmal negativ formuliert. Beantwortet werden die Fragen über eine fünfstufige Skala, welche von „Stimmt überhaupt nicht“ bis „Stimmt voll und ganz“ reicht.

Positiv formulierte Fragen decken einen Wertebereich von 1 bis 5 ab und negativ formulierte Fragen müssen entsprechend umgerechnet werden und der Wert der Antwort wird von 6 abgezogen, sodass sich eine Spanne von 12 bis 60 Punkten ergibt. Dabei ist 12 der niedrigste TC-Wert und 60 der höchste TC-Wert [186, 185].

Die Benutzerfreundlichkeit des DNDv1, des AT und der BCS wurde jeweils einzeln mithilfe des System Usability Scale (SUS)-Fragebogens, in einer deutschen Übersetzung¹, erhoben [187]. Der SUS-Fragebogen umfasst insgesamt 10 Fragen. Wie beim TC-Fragebogen, sind die enthaltenen Fragen einmal positiv und einmal negativ formuliert und werden über eine fünfstufige Skala, welche von „Stimmt überhaupt nicht“ bis „Stimmt voll und ganz“ reicht, beantwortet. Für den SUS wird der Wert der Skala aller positiv formulierten Fragen minus 1 summiert. Für die negativ formulierten Fragen wird 5 minus dem Wert der Skala summiert. Damit ergibt sich ein möglicher Wertebereich von 0 bis 40, welcher mit dem Faktor 2,5 multipliziert wird, um einen Wertebereich von 0 bis 100 zu erhalten. Die schlechteste Bewertung wird somit durch 0 und die beste durch 100 beschrieben [187]. Diese Bewertung lässt sich auch mit entsprechenden Adjektiven oder Noten versehen [188, 189].

Während der Studie war kontinuierlich ein(e) Studienmitarbeiter:in anwesend, so dass die Teilnehmer:innen während der Nutzung des DNDv1, des AT und der BCS beobachtet werden konnten. Neben dem direkten Feedback der Teilnehmer:innen konnten so auch positive wie negative Beobachtungen dokumentiert werden. Alle während der Studie erhobenen Daten wurden über eine Kodierliste zusammengeführt und nach Abschluss der Erhebung anonymisiert.

4.1.5. Ergebnisse DNDv1

Insgesamt konnten in der 2018 im Rehazentrum Oldenburg durchgeführten, oben beschriebenen Studie, 12 Teilnehmer:innen (10 männlich, 2 weiblich, Durchschnittsalter $79,2 \pm 5,9$ Jahre) eingeschlossen werden, die die Studie vollständig durchgeführt haben. Die Ergebnisse der TC- und SUS-Fragebögen sind in Abbildung 4.3 in Relation zueinander aufgezeigt. Neben der mittleren bis starken positiven linearen Korrelation zwischen TC und SUS (0,6235) existieren in den erhobenen Daten

¹<https://blog.seibert-media.net/blog/2011/04/11/usability-analysen-system-usability-scale-sus/> (letzter Zugriff: 3.7.2022)

keine signifikanten linearen Korrelationen zwischen Alter und SUS (-0,1956) oder zwischen Alter und TC (-0,2214).




Abbildung 4.3.: Überblick über die SUS-Ergebnisse des DNDv1 (mittlerer SUS = $51,66 \pm 11,93$), des AT (mittlerer SUS = $82,50 \pm 5,54$) und des BCS (mittlerer SUS = $29,79 \pm 8,42$) in Abhängigkeit zu den jeweiligen TC-Ergebnissen.

Das über die Fragebögen hinaus erfasste Feedback, direkt durch die Studienteilnehmer:innen selber oder indirekt als Beobachtung durch die Studienmitarbeiter:innen, wurde in drei Kategorien aufgeteilt: Benutzeroberfläche, Inhalte und Funktionen.

Benutzeroberfläche: Das Feedback zur Benutzeroberfläche des DNDv1 konzentrierte sich auf die Navigationselemente. Diese waren für einige Studienteilnehmer:innen z. B. zu nahe beieinander oder waren zu klein. Weiterhin konnten einige Navigationselemente nicht intuitiv erkannt werden, so hat der

Plus-Button zum Starten der Eingabe hat mehrfach an das Apotheken-Kreuz erinnert und nicht an einen Startknopf für die Eingabe von Lebensmitteln und Getränken.

Inhalte: Insgesamt 13 Mal gab es Feedback über fehlende Lebensmittel, Getränke und auch Nahrungsergänzungsmittel. Am häufigsten wurden hier jedoch Saucen genannt, z. B. Ketchup, Mayonnaise, Krabbensauce, Senfsauce und Currysauce. Darüber hinaus wurden einige Lebensmittel und Getränke von den Studienteilnehmer:innen in anderen Kategorien als implementiert gesucht, von wieder anderen Studienteilnehmer:innen jedoch genau dort gefunden.

Funktionen: Ein(e) Studienteilnehmer:in merkte an, dass eine Suche für spezifische Getränke und Lebensmittel über ein Textfeld hilfreich gewesen wäre. Weiterhin gaben insgesamt sechs Studienteilnehmer:innen an, dass sie sich nicht sicher waren, ob ihre Eingaben erfolgreich dem Tagebuch hinzugefügt wurden, da sie ihre Eingaben nicht final bestätigen mussten.

Das Feedback für AT und BCS weicht stark voneinander ab. Bei dem AT wurde besonders das Design und dessen Nähe zu klassischen Armbanduhren positiv zurückgemeldet. Weiterhin wurde die Abwesenheit multipler Knöpfe sowie eines Touch-Bildschirms bei dem AT als positiv empfunden. Ein(e) Studienteilnehmer:in erkundigte sich nach der Studie, ob der AT auch zum Verkauf stehen würde. Anders hat sich dies bei der BCS verhalten. Aufgrund einer Funktion, welche das präzise Wiegen unterstützen sollte, musste der Einsatz der BCS bei einigen Studienteilnehmer:innen abgebrochen werden. Die besagte Funktion zeigt mit kleinen Pfeilen in den Ecken des Displays an, wie sich die Nutzer:innen idealerweise auf der Waage positionieren sollen. Die physischen Einschränkungen einiger Studienteilnehmer:innen in Verbindung mit der Notwendigkeit, dass diese hierzu nach unten schauen müssen, führten zu starken Stand-Instabilitäten bei einigen Studienteilnehmer:innen, sodass diese den Einsatz der BCS mehrmals abbrechen mussten.

4.1.6. Diskussion

Grundsätzlich zeigen die Ergebnisse der ersten Studie, dass ein Großteil der Zielgruppe mit einem entsprechenden System in der Lage ist, körperliche Aktivität, Körperkompositionsdaten sowie Verzehr- und Trinkverhalten selbstständig digital

zu erfassen. Insbesondere die Usability des AT zeigt, dass bereits Produkte im Konsumerbereich existieren, welche die Bedarfe der Zielgruppe dieser Arbeit in hohem Umfang erfüllen. Der SUS-Wert von 82,50 für den AT kann dabei vermutlich auf die geringe technische Komplexität in der Benutzung und der damit verbundenen einfachen (ambienten) Handhabbarkeit zurückgeführt werden. Mit einem mittleren SUS von 29,79 für die BCS konnte jedoch ebenfalls gezeigt werden, dass selbst das Wiegen für die Zielgruppe dieser Arbeit ein Hindernis darstellen kann. Vor allem dann, wenn die Hardware die Einschränkungen der Zielgruppe nicht berücksichtigt. In diesem Fall also ein möglichst stilles Stehen im Zentrum der Waage, um eine möglichst präzise Messung der Körpergewichts und der Körperkompositionsdaten zu ermöglichen. Mit einem mittleren SUS von 51,66 liegt DNDv1 zwischen beiden Werten. Neben der mittleren bis starken linearen Korrelation zwischen TC und SUS fällt die breitere Verteilung der SUS-Werte für DNDv1 auf. Die größere Varianz der SUS-Werte lässt sich vermutlich auf die komplexeren Anforderungen und individuellen Vorkenntnisse der Proband:innen zurückführen, siehe Abbildung 4.3.

Änderungen an der Sensorik, um eine weitere Optimierung der Usability zu erreichen, konnten im Kontext dieser Arbeit nicht durchgeführt werden. Anders verhält sich dies mit dem DNDv1. Hier wurden die Ergebnisse der Studie mit Expert:innen diskutiert und entsprechende Anforderungen für eine weiterentwickelte Version des DNDv1 festgelegt. Dies führte auch dazu, dass nicht alle Anmerkungen unmittelbar als Änderungen umgesetzt wurden. Nicht integriert wurde z. B. die textbasierte Suche für Nahrungsmittel und Getränke. Dies hätte die Nutzung der Bildschirmtastatur erforderlich gemacht und damit die Mindestanforderungen an die sensomotorischen Fähigkeiten potentieller Nutzer:innen vergrößert. Zudem wurde auf eine finale Bestätigung für das Hinzufügen von Nahrungsmitteln und Getränken verzichtet, da eine solche Funktion nach einer kurzen Eingewöhnungsphase mehr gestört als geholfen hätte. Das inhaltliche Feedback hinsichtlich fehlender Nahrungsmittel und Getränke wurde durch das Ergänzen dieser Elemente adressiert. Das Feedback bezüglich der Benutzeroberfläche wurde ebenfalls berücksichtigt. Hier wurden verschiedene Navigationselemente, z. B. Buttons für Mengenangaben und der Zurück-Button, neu positioniert, um deren Abstände zu maximieren und Schriften vergrößern zu können, um die Bedienung weiter zu vereinfachen.





Ein weiterer Punkt war ein variierendes intuitives Verständnis für die Positionierung von Nahrungsmitteln und Getränken in den zugehörigen Kategorien und Unterkategorien. Entsprechende Navigationspfade wurden zwar vom DNDv1 aufgezeichnet, diese lagen aber durch den Umfang der ersten Studie nicht in ausreichender Anzahl vor, sodass hier keine weiterführenden Auswertungen durchgeführt werden konnte. Diese Daten wurden jedoch mit denen der zweiten Studie zusammengeführt, um aussagekräftigere Auswertungen zu ermöglichen, siehe Abschnitt 4.1.9.

4.1.7. Implementierung DNDv2

Basierend auf den Anforderungen aus den Personas & Szenarien sowie dem Feedback aus der ersten Studie, wurde DNDv2 entwickelt, welches im Folgenden erläutert wird. Die grundlegende Struktur ist beibehalten worden, siehe Abschnitt 4.1. Nachdem die Nutzer:innen sich am DNDv2 mit Nutzernamen und Passwort angemeldet haben, wird die Tagesübersicht angezeigt. In der Tagesübersicht werden alle zuvor schon protokollierten Getränke, Nahrungsmittel und Nahrungsergänzungsmittel unter den entsprechenden Mahlzeiten angezeigt, siehe Abbildung 4.4a. Die möglichen Mahlzeiten umfassen dabei Frühstück, Mittagessen, Abendessen und Zwischenmahlzeiten. Unter Zwischenmahlzeiten wird jeglicher Verzehr außerhalb der drei Hauptmahlzeiten eingetragen.

Durch das Drücken des grünen „Plus“-Buttons können Nutzer:innen mit der Eingabe beginnen. Solange noch kein Eintrag für die jeweilige Mahlzeit vorgenommen wurde, erscheint im DNDv2 ein zusätzlicher Hinweis in einem pfeilförmigen Textfeld, siehe Abbildung 4.4a. Nachdem Drücken des grünen „Plus“-Buttons wird eine Übersicht über die verfügbaren Oberkategorien angezeigt. Neben den verschiedenen Kategorien für Getränke und Nahrungsmittel, werden dort auch die beiden zusätzlichen Kategorien „Nahrungsergänzungsmittel“ und „Häufig ausgewählt“ angezeigt, siehe Abbildung 4.4b.

Sowohl die Kategorie „Häufig ausgewählt“ als auch die Kategorie „Nahrungsergänzungsmittel“ gehen nicht als notwendige Änderung aus den Ergebnissen der ersten Studie hervor, wurden aber unter Berücksichtigung des Umfangs der zweiten Studie dennoch implementiert, siehe Abschnitt 4.1.8. Die Kategorie „Nahrungsergänzungsmittel“ wurde aufgenommen, da es in geriatrischen Rehabilitationszentren möglich

Gestern	Heute	Morgen
	Frühstück	
	Mittagessen	
	Abendessen	
	Zwischenmahlzeiten	

(a) Tagesübersicht für den aktuellen Tag mit nur einer Eintragung (Müsli)

[← Zurück](#) **Übersicht Nahrungsmittel**

 Getränke	 Gemüse	 Obst	 Brot & Müsli	 Beilagen & Gerichte
 Milchprodukte	 Fleisch, Fisch & Eier	 Suppen & Eintöpfe	 Süßigkeiten & Desserts	 Kuchen & Gebäck
 Soßen & Dressings	 Aufstrich & Süßungsmittel	 Nahrungsergänzung	 Fette & Öle	 Häufig ausgewählt

(b) Übersicht über alle Oberkategorien für alle Lebensmittel, Getränke und Nahrungsergänzungsmittel

Abbildung 4.4.: Eintragung einer Portion Müsli in das DNDv2 Teil I

ist, dass bei einer vorliegenden Mangelernährung Nahrungsergänzungsmittel als Teil der therapeutischen Diät eingesetzt werden. Die Kategorie „Häufig ausgewählt“ wurde implementiert, da sich in diesen Einrichtungen Speisepläne in der Regel zyklisch wiederholen.

Alle Oberkategorien können sowohl über das entsprechende Piktogramm als auch über die zugehörige textuelle Beschreibung geöffnet werden. Existieren Unterkategorien in diesen Oberkategorien, kann dieser Auswahlvorgang so lange wiederholt werden, bis das gewünschte Getränk, Lebensmittel oder auch Nahrungsergänzungsmittel erreicht wurde. Diese baumartige Struktur wird im Folgenden als Nahrungsmittel-, Getränke- und Nahrungsergänzungsmittelbaum (engl. Food, Beverages and Supplements Tree) (FoBaST) bezeichnet. Ein Blatt des Baumes, also ein Nahrungsmittel, Getränk oder Nahrungsergänzungsmittel wird als FoBaST-Element bezeichnet.

Nach der Auswahl eines FoBaST-Elements werden Nutzer:innen automatisch zur Auswahl der Menge weitergeleitet. Herkömmliche Ernährungstagebücher arbeiten häufig mit präzisen Mengenangaben, z. B. in Gramm oder Milliliter. In den Gesprächen mit den Ernährungsberater:innen hat sich herausgestellt, dass viele Patient:innen Probleme mit der Schätzung von Verzehrmenen auf Basis solcher Einheiten haben. Dies lässt sich jedoch mit einer entsprechenden Waage ermöglichen. Zudem ist die Wiegemethode als Goldstandard anerkannt. Diese Methode ist jedoch entsprechend umständlich und eine entsprechende Waage steht den Patient:innen nicht immer zur Verfügung. Aus diesen Gründen werden sogenannte haushaltsübliche Mengenangaben, wie „Tasse“ oder „Becher“ für einige Arten von Getränken verwendet. Als haushaltsübliche Mengenangaben wird für Brot und Aufschnitt z. B. „Scheiben“ verwendet. Für Obst, Gemüse oder auch Müsli wird „Handvoll“ als Mengenangabe genutzt, siehe Abbildung 4.5c.

Bis zur Auswahl der Menge können Nutzer:innen über einen „Zurück“-Button in der Hierarchie des Baumes zurücknavigieren. Wird jedoch eine der haushaltsüblichen Mengen ausgewählt, werden die Nutzer:innen automatisch zur Tagesübersicht weitergeleitet. In dieser Tagesübersicht ist nun auch das ausgewählte FoBaST-Element zur entsprechenden Mahlzeit hinzugefügt worden, siehe Abbildung 4.4a.

Wird ein FoBaST-Element in der Tagesübersicht von den Nutzer:innen gedrückt, so wird eine entsprechende Detailansicht, inklusive der entsprechenden Kalorien



(a) Unterkategorie „Brot & Müsli“



(b) Unterkategorie „Müsli“



(c) Mengenauswahl für „Gemischtes Müsli“

Abbildung 4.5.: Eintragung einer Portion Müsli in das DNDv2 Teil II

und Makronährstoffen auf Basis der ausgewählten Menge, angezeigt. In dieser Detailansicht ist es weiterhin möglich, die Mengenangabe nachträglich anzupassen oder den gesamten Eintrag zu löschen.

Nach dem Start des digitalen Ernährungstagebuchs wird immer der aktuelle Tag in der Übersicht angezeigt. Das DNDv1 erlaubt es den Nutzer:innen ihr Verzehrverhalten über mehrere Tage in der Zukunft als auch in der Vergangenheit zu dokumentieren.

4.1.8. Studiensetting DNDv2

In der ersten Studie konnte ermittelt werden, dass die Zielgruppe der hochaltrigen und vom Frailty-Syndrom betroffenen Personen grundsätzlich in der Lage ist ihr Verzehrverhalten selbstständig mithilfe eines digitalen Ernährungstagebuchs zu protokollieren. Zudem konnten die Daten der ersten Studie dafür genutzt werden, um eine optimierte Version des Ernährungstagebuchs, das DNDv2, zu entwickeln. Um auch diese optimierte Version zu evaluieren, wurde 2018 eine weitere monozentrische Querschnittsstudie durchgeführt. Dem entsprechenden Antrag bei der medizinischen Ethikkommission (2018-029) wurde am 28.03.2018 stattgegeben.

Da die in der ersten Studie evaluierte Sensorik keine Eigenentwicklung darstellt, konnte diese nicht auf Basis der gesammelten Daten weiter auf die Zielgruppe angepasst werden, sodass eine erneute Evaluation keinen nennenswerten Mehrwert erzeugt hätte.

Rekrutierung: Die Studienteilnehmer:innen wurden auf die gleiche Art und Weise rekrutiert wie in der ersten Studie, siehe Abschnitt 4.1.4.

Teilnehmer:innen: Die Studie wurde am selben Ort und mit den gleichen Ein- und Ausschlusskriterien durchgeführt, wie in der ersten Studie, siehe Abschnitt 4.1.4.

Studienablauf: Die Aufgabe der Studienteilnehmer:innen der zweiten Studie war es, alle verzehrten Nahrungsmittel, Getränke und Nahrungsergänzungsmittel an insgesamt drei Tagen mithilfe des DNDv2 zu protokollieren. Diese drei Tage sollten dabei aufeinander folgen und aus zwei Werktagen und einem Wochenendtag bestehen. Es sollten explizit Werk- und Wochenendtage protokolliert werden, da sich das Verzehrverhalten zwischen Werk- und Wochenendtagen unterscheiden kann [190].

Fragebögen und Erhebungen: Weiterhin wurde, wie auch in der ersten Studie, die Technikbereitschaft und die Usability aus Sicht der Studienteilnehmer:innen erhoben, siehe Abschnitt 4.1.4.

4.1.9. Ergebnisse DNDv2

Insgesamt konnten in der 2018 im Rehazentrum Oldenburg durchgeführten, oben beschriebenen Studie, 16 Teilnehmer:innen (10 männlich, 6 weiblich, Durchschnittsalter $79,3 \pm 3,9$ Jahre) eingeschlossen werden, die die Studie vollständig durchgeführt haben. Die Ergebnisse der TC- und SUS-Fragebögen sind in Abbildung 4.6 in Relation zueinander sowie zur ersten Studie aufgezeigt. Neben der mittleren bis starken positiven linearen Korrelation zwischen TC und SUS (0,5873) existieren auch in den Daten zur zweiten Studie keine signifikanten linearen Korrelationen zwischen Alter und SUS (-0,2883) sowie zwischen Alter und TC (-0,0715).

Durch das Nutzerfeedback und den resultierenden Ergänzungen des FoBaST wird dieser automatisch auch komplexer. Dabei wurden im DNDv1 alle FoBaST-Elemente nur genau einmal eingebunden, um die Größe des FoBaST nicht zu stark anwachsen zu lassen. Welcher FoBaST-Eintrag jedoch welcher Kategorie zuzuordnen ist, wurde von den Studienteilnehmer:innen unterschiedlich interpretiert. Mithilfe der Interaktionsprotokolldaten war es möglich, Navigationsfehler oder Unsicherheiten der Studienteilnehmer:innen indirekt zu erfassen. Für eine derartige Analyse war es jedoch notwendig, verschiedene Datensätze miteinander zu verknüpfen, um gültige Navigationspfade zu erstellen. Ein gültiger Navigationspfad wird auf genau ein FoBaST-Element abgebildet. Ein solcher Pfad beginnt mit der Nutzereingabe, bzw. mit dem Drücken des Plus-Buttons und endet mit der Auswahl der Menge, sodass sich ein Pfad pro eingegebenem FoBaST-Element ergibt. Durch

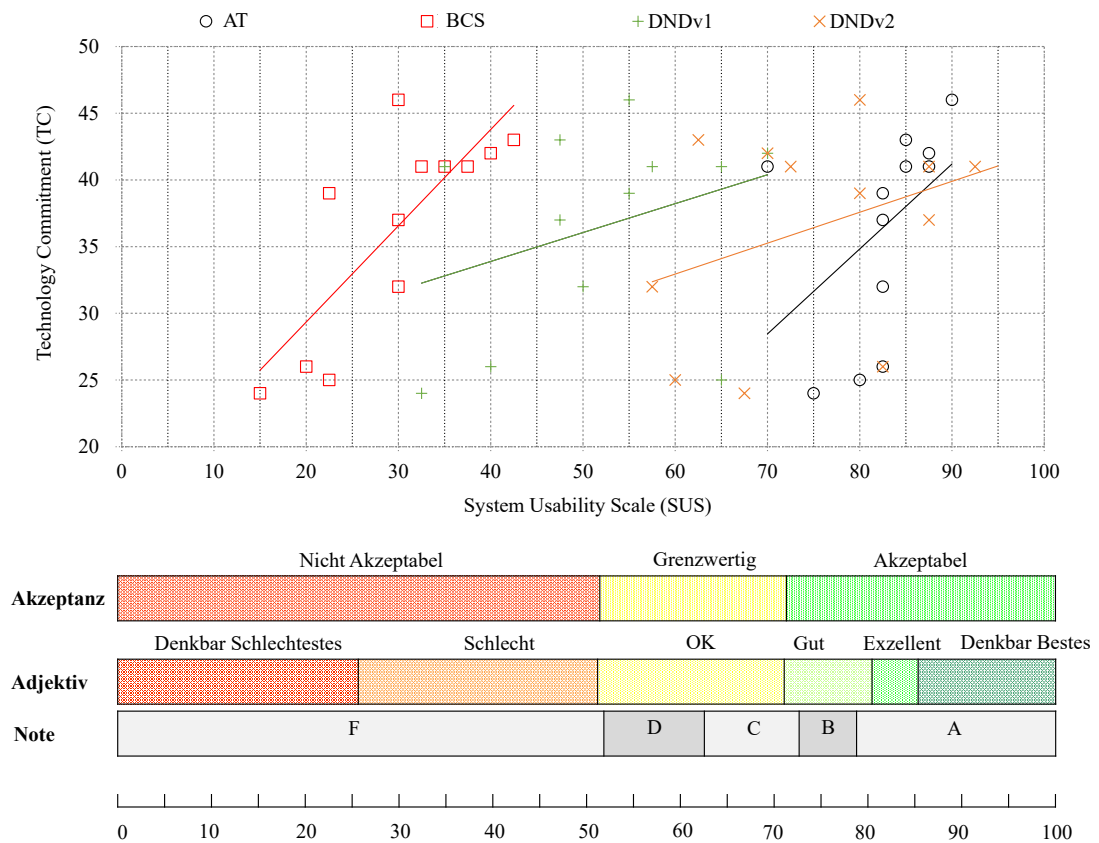


Abbildung 4.6.: Überblick über die SUS-Ergebnisse der ersten Studie (DNDv1, AT und BCS) im Vergleich mit den SUS-Ergebnissen des DNDv2 in der zweiten Studie (mittlerer SUS = 76,40 ± 11,90) in Abhängigkeit zu den jeweiligen TC-Ergebnissen.

das Aggregieren aller Pfade entsteht somit eine Zusammenfassung sämtlicher Pfade aller Studienteilnehmer:innen pro FoBaST-Element.

Mithilfe des aggregierten Navigationsbaumes lassen sich dann Fehlnavigationsschritte bestimmen und relative Unsicherheiten berechnen, basierend auf dem jeweiligen optimalen Pfad. Bei einer solchen Auswertung muss berücksichtigt werden, dass die Nutzung des digitalen Ernährungstagebuchs weder in Studie 1 noch in Studie 2 explizit auf die Aufgaben, welche in den Studien definiert wurden, beschränkt war. Dies konnte vor allem in den resultierenden Pfaden von DNDv2 aus der Studie 2 beobachtet werden. Hierzu nutzten die Studienteilnehmer:innen die Anwendung auch, um Mahlzeiten an Tagen zu dokumentieren, welche nicht zur Studie zählten. Weiterhin probierten einige Proband:innen die Anwendung aus, um zu erfahren, welche Nahrungsmittel, Getränke und Nahrungsergänzungsmittel generell verfügbar sind. Speziell letzteres Verhalten führt zu chaotischen Navigationspfaden mit vielen Fehlnavigationsschritten. Da derartige Pfade nicht eindeutig identifiziert werden können, wurden alle Pfade in die Auswertung einbezogen. Es hat sich jedoch gezeigt, dass sich dennoch Häufungen bei den summierten Fehlnavigationsschritten für einzelne FoBaST-Einträge ergeben. Beispiele für solche Einträge waren: Milch, Joghurt und Quark. Milch wurde sowohl unter der Kategorie „Getränke“ als auch in der Kategorie „Milchprodukte“ gesucht, siehe Abbildung 4.7. Joghurt und Quarkspeisen wurden sowohl unter „Milchprodukte“ als auch unter „Süßigkeiten und Desserts“ gesucht. FoBaST-Einträge mit nur vereinzelt aufgetretenen Fehlnavigationen wurden nicht berücksichtigt, siehe Abbildung 4.8. Entgegen der ursprünglichen Annahme, dass es für die Zielgruppe übersichtlicher und einfacher wäre, wenn FoBaST-Einträge genau einmal vorkämen, hat sich gezeigt, dass die Studienteilnehmer:innen ein unterschiedliches Verständnis bezüglich der Zuordnung von FoBaST-Einträgen haben und eine entsprechende Mehrfachzuordnung sinnvoll ist. Vor der Integration solcher Mehrfachzuordnungen wurden diese jedoch mit den Expert:innen zur zusätzlichen Validierung besprochen.

Weiterhin wurde mithilfe der Pfadanalyse berechnet, wie lange die Teilnehmer:innen an den verschiedenen Studientagen für die Eingabe einzelner FoBaST-Elemente benötigten, siehe Abbildung 4.9.




Abbildung 4.7.: Aggregierte Darstellung und Auswertung aller validen Pfade für das FoBaST-Element Milch 3,5 %. Hinweis: Fehlnavigationsschritte sind rot markiert und werden bei den Berechnungen doppelt gezählt, da Hin- als auch Rückweg relevant sind.

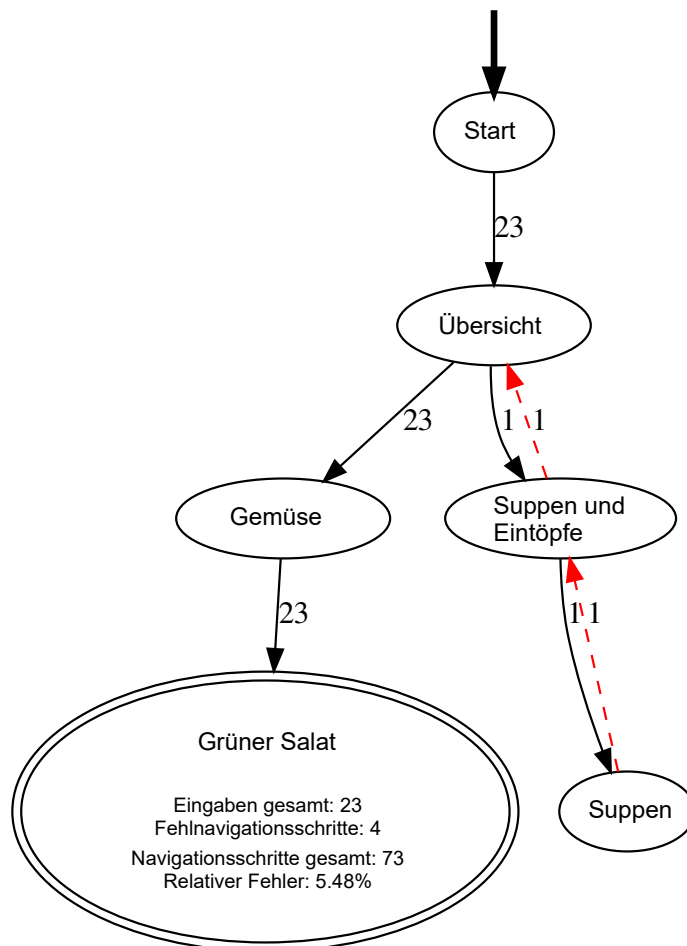


Abbildung 4.8.: Aggregierte Darstellung und Auswertung aller validen Pfade für das FoBaST-Element „Grüner Salat“. Hinweis: Fehlnavigationsschritte sind rot markiert und werden bei den Berechnungen doppelt gezählt, da Hin- als auch Rückweg relevant sind.

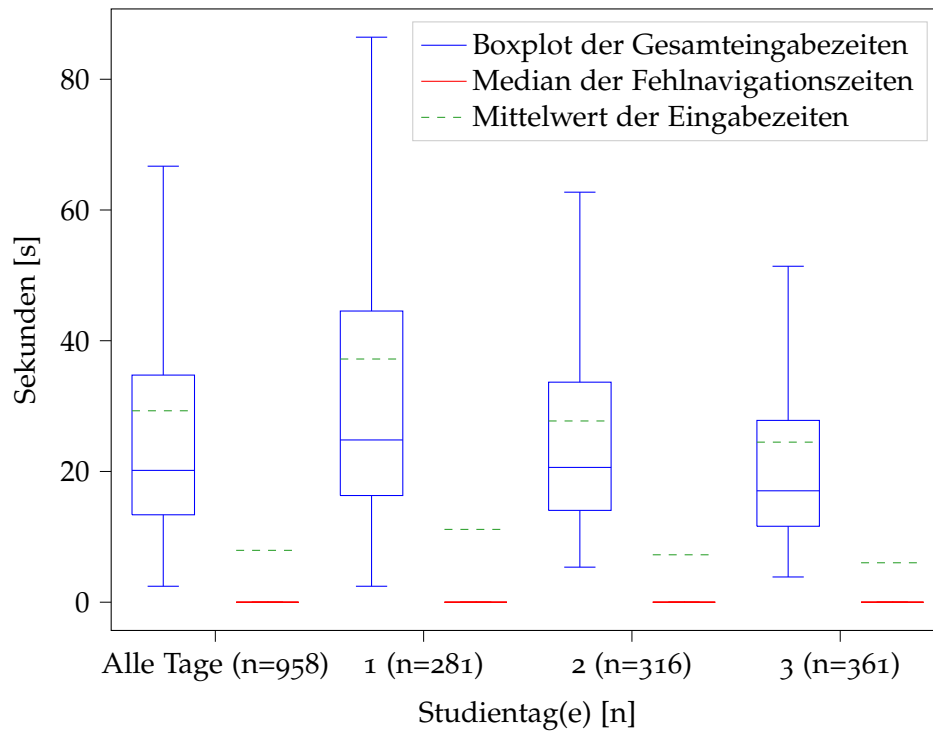


Abbildung 4.9.: Vergleich der von den Studienteilnehmer:innen benötigten Zeiten in Studie 2 für das Protokollieren eines Nahrungsmittels, Nahrungsergänzungsmittels oder Getränks. Die mittlere Eingabezeit (t_{mean}) sowie die mittlere Fehl Navigationszeit (t_{mis}) sind $29,28\text{ s}$ und $7,93\text{ s}$ für alle drei Tage, $37,20\text{ s}$ und $11,14\text{ s}$ für den ersten Tag, $27,73\text{ s}$ und $7,25\text{ s}$ für den zweiten Tag und $24,49\text{ s}$ und $6,03\text{ s}$ für den dritten Tag. Bemerkung: Die roten Linien, der Median der Fehl Navigationszeiten, ist 0 da über 50% der Pfade keine Fehl Navigationszeiten beinhalten.

4.1.10. Diskussion und Fazit

Fasst man die Ergebnisse der ersten und der zweiten Studie zusammen, so kann die initiale Fragestellung:

„Auf welche Art und Weise lassen sich Technologie und Digitalisierung nutzen, um hochaltrige Personen, die vom Frailty-Syndrom betroffen sind, eine selbstständige Erfassung relevanter Informationen für die Ernährungsberatung zu ermöglichen?“

damit beantwortet werden, dass eine automatisierte und ambiente Erfassung von relevanten Daten die Bedarfe der Zielgruppe, hinsichtlich der Usability, am umfangreichsten adressiert. Dies konnte speziell im Kontext der Erfassung der körperlichen Aktivität mittels AT (mittlerer SUS-Wert = 82,50) in der ersten Studie gezeigt werden, siehe Abschnitt 4.1.5. Aufgrund des Fokus der ersten Studie auf die Benutzerfreundlichkeit, muss an dieser Stelle darauf hingewiesen werden, dass neuere Studien beschreiben, dass die präzise Erkennung von Schritten eine Herausforderung bleibt, insbesondere bei niedrigen Geschwindigkeiten und/oder bei der Verwendung von Gehhilfen [120, 130]. Auch bei der sorgfältig von den Expert:innen ausgewählten BCS hat sich gezeigt, dass die verminderten physischen Fähigkeiten der hochaltrigen Zielgruppe eine Herausforderung für die Erfassung entsprechender Daten darstellt. Dies spiegelt sich auch in der deutlich niedrigeren Bewertung der Usability der BCS (mittlerer SUS-Wert = 29,79) wider, siehe Abschnitt 4.1.5. Hier ist jedoch zu berücksichtigen, dass sich ohne die Funktion für möglichst stabile Messwerte ein voraussichtlich gänzlich anderer SUS ergeben hätte.

Eine vollständig automatisierte und ambiente Erfassung des Verzehrverhaltens ist zwar aus rein technologischer Sicht möglich, jedoch aus ökonomischer Sicht in der Praxis (noch) nicht umsetzbar. Eine direkte Interaktion der Zielgruppe zur Eingabe von Daten, mithilfe eines entsprechenden Systems, ist somit (aktuell) nicht vermeidbar. Die Steigerung des mittleren SUS von 51,66 für DNDv1 auf 76,40 für DNDv2 zeigt, dass die angewandte Methode, die initialen Anforderungen iterativ in einer Expertengruppe zu erheben, zu einem von der Zielgruppe nutzbaren System geführt hat. Darüber hinaus aber auch, dass eine Evaluation mit der Zielgruppe auch hier wesentlich ist und, dass die durchgeführten Analysen und die daraus

abgeleiteten Änderungen und Erweiterungen am DNDv1 als folgerichtige Schritte für das Erreichen einer optimierten Usability angesehen werden können. Eine konsequente Weiterführung des DNDv2 wäre die kontinuierliche Optimierung des FoBaST mittels Pfadanalysen auf Basis längerfristiger Erhebungen. Je mehr Daten zur Verfügung stehen, desto besser kann der FoBaST an die Zielgruppe angepasst werden.

Zusammenfassend kann unterstrichen werden, dass die Bedürfnisse geriatrischer Patient:innen divers und komplex sind und auch sorgfältig mit Expert:innen entwickelte Systeme einer intensiven Evaluation bedürfen. Dennoch muss davon ausgegangen werden, dass es keine „One-Size-Fits-All“-Lösung für das gesamte Spektrum der Zielgruppe geben kann. Bei beiden Studien ist auch zu berücksichtigen, dass die Teilnehmer:innen DNDv1 und DNDv2 über einen sehr kurzen Zeitraum verwendet haben. Dennoch zeigt die Auswertung der Daten der zweiten Studie, bzgl. der durchschnittlichen Zeit für das Protokollieren des Verzehrverhaltens, einen Lerneffekt über die drei Studientage, siehe Abbildung 4.9. Dieses deutet darauf hin, dass den Teilnehmer:innen die Nutzung von DNDv2 mit der Zeit leichter fällt. Dies könnte sich auch auf die SUS-Ergebnisse ausgewirkt haben.

Der hohe durchschnittliche SUS-Wert des ATs lässt jedoch für DNDv2 vermuten, trotz der schon optimierten Usability, dass hier weiteres Optimierungspotenzial vorhanden ist. Vergleicht man DNDv2 und AT miteinander, so wird klar, dass das Anlegen und Tragen des ATs deutlich weniger aufwändig ist, als das manuelle Protokollieren des eigenen Verzehrverhaltens mittels DNDv2. Aus diesem Grund adressiert das folgende Kapitel eine weiterführende Fragestellung, um zu ermitteln, mit welchen technischen Mitteln es prinzipiell möglich ist, das Protokollieren des Verzehrverhaltens weiter zu optimieren.

4.2. Automatisierte Verzehrmengenerhebung

Trotz der guten Ergebnisse von DNDv2 bezüglich der SUS-Werte, siehe Abschnitt 4.1.9, erfordert der Einsatz des Tagebuchs dennoch zeitliche, kognitive und sensorische Mindestanforderungen. Ebendiese kognitiven und sensomotorischen Fähigkeiten sind innerhalb der vom Frailty-Syndrom betroffenen Zielgruppe oftmals vermindert, siehe Abschnitt 2.1. Diese Verminderung kann z. B. durch Anpassungen von DNDv2 adressiert und in Teilen kompensiert werden. Die sich deutlich positiv abhebenden Ergebnisse bezüglich der Benutzbarkeit des AT weisen darauf hin, dass eine möglichst automatisierte und ambiente Erfassung eine Möglichkeit ist, die Benutzbarkeit des digitalen Ernährungstagebuchs weiter zu optimieren. Somit lässt sich folgende Fragestellung formulieren:

„Mit welchen technischen Hilfsmitteln kann das Führen eines digitalen Ernährungstagebuchs für hochaltrige und vom Frailty-Syndrom betroffene Personen weiter vereinfacht werden?“

Wie im Abschnitt 4.1.10 angeführt, ist eine vollständig automatisierte und ambiente Erfassung des Verzehrverhaltens aktuell nur mit einem unverhältnismäßig hohen Einsatz von Technik und Personal möglich. Die sich rasant weiterentwickelnde Künstliche Intelligenz (KI), insbesondere der Teilbereich Objekterkennung, wäre eine jedoch naheliegende Möglichkeit, um bei der Erfassung des Verzehrverhaltens zu unterstützen, siehe Abschnitt 3.2.2. Aus diesem Grund zielt die hier formulierte Fragestellung auf die Entwicklung eines semi-automatisierten Ansatzes ab, welcher mittels KI-basierender Objekterkennung realisiert wurde. Der Fokus lag dabei nicht auf der Entwicklung einer neuartigen und performanteren KI-basierten Objekterkennung, sondern auf einer dem Anwendungsfall und der Zielgruppe angepassten Integration dieser Technologie. Damit soll die Benutzbarkeit weiter optimiert und die kognitive Belastung der Zielgruppe weiter reduziert werden.

4.2.1. Methoden

Die im weiteren Verlauf dieses Kapitels aufgeführten Entwicklungen unterlagen denselben Kriterien wie die Entwicklung von DNDv1 und DNDv2. Auch die

Ergebnisse, der in den Abschnitten 4.1.4 und 4.1.8 aufgeführten Studien, haben Einfluss auf die Anforderungen gehabt.

Bei der Realisierung einer möglichst intuitiv nutzbaren Integration eines auf Objekterkennung basierenden Ansatzes zur Unterstützung der Erhebung des Verzehrverhaltens ist zu berücksichtigen, dass die Anforderungen für diese Realisierung nicht ausschließlich aus der Zielgruppe heraus entstehen, sondern von der eingesetzten KI und deren Limitierungen abhängig sind. Die hier eingesetzte KI-basierte Objekterkennung führt zu zwei dieser Limitierungen, welche bei der Entwicklung des semi-automatisierten Eingabemodus berücksichtigt werden mussten:

Gleichartige Objekte: Wie der Mensch kann auch die KI Objekte nur dann voneinander unterscheiden, wenn sie auch unterschiedliche Merkmale aufweisen. Zwei schwarze Flüssigkeiten, z. B. Tee und Kaffee, können rein optisch in einer Tasse sowohl vom Menschen als auch von der KI ohne Kontext i. d. R. nicht voneinander unterschieden werden.

Verdeckte Objekte: Verdeckte Lebensmittel, wie z. B. Butter zwischen einem Brötchen und Aufschnitt, lassen sich rein optisch weder vom Menschen noch von einer KI-basierten Objekterkennung ermitteln.

Speziell verdeckte Objekte werden häufig als Bestandteil eines anderen Lebensmittels verstanden und entsprechend nicht separat angeführt. Diese machen jedoch häufig einen großen Unterschied für die Ernährungsberatung. Insbesondere Lebensmittel wie Butter und Zucker haben eine hohe Kaloriendichte und wirken sich damit auch auf die Bewertung des Verzehrverhaltens aus. In der Praxis wird diese Problematik durch entsprechende Nachfragen der Ernährungsberater:innen in persönlichen Interviews mit den Patient:innen ausgeglichen, siehe Abschnitt 2.2.2. Die in dieser Arbeit entwickelte KI-basierte Eingabemethode orientiert sich an diesen Interviews und formuliert ebenfalls Nachfragen. Diese tragen dazu bei, gleichartige Objekte zu differenzieren und verdeckte Lebensmittel zu ermitteln. Weiterhin reagiert das entwickelte System auf die Antworten, sodass eine gewisse Dynamik entsteht.

Damit kann die in dieser Arbeit eingesetzte KI nicht als Lösung zur vollständig automatisierten und ambienten Erfassung von Verzehr- und Trinkmengen verstanden werden, jedoch als potentes Werkzeug mit der Perspektive, die Erfassung signifikant zu unterstützen. Als Konsequenz wurden die Limitierungen

der KI sowohl bei dessen Training als auch bei dessen Integration über ein entsprechendes Interaktionsmodell berücksichtigt. Der aus diesen Anforderungen abgeleitete KI-basierte, interaktive, dynamische und interview-artige Eingabemodus (KIIdI-Eingabemodus), folgt zudem den Schlussfolgerungen aus den Abschnitten 3.4 und 4.1.10, dass es keine „*One-Size-Fits-All*“-Lösung für die selbstbestimmte und eigenständige Erfassung des eigenen Verzehrverhaltens gibt. Dementsprechend wurde der KIIdI-Eingabemodus nicht als eigenständige Anwendung konzipiert, sondern als Erweiterung des DNDv2. Das resultierende assisted DND Version 1 (aDNDv1) lässt somit sowohl assistierte als auch manuelle Eingaben zu.

aDNDv1 wurde mithilfe einer anonymisierten Nutzerstudie (18 Männer und 3 Frauen, Durchschnittsalter 27 Jahre) untersucht. Das geringe Durchschnittsalter begründet sich durch die zur Zeit der Studie vorherrschende COVID19-Pandemie. Die COVID19-Pandemie hat es erforderlich gemacht, dass die Studie remote und damit kontaktlos durchgeführt wurde. Damit konnte jedoch nur eine jüngere Zielgruppe erreicht werden. Diese Zielgruppe erlaubte es jedoch auch aDNDv1 mit anderen digitalen Ernährungstagebüchern zu vergleichen. Gemessen wurden neben der Benutzbarkeit auch die Erkennungsraten, die benötigte Zeit und die Anzahl an benötigten Interaktionen mit den verschiedenen Systemen [191].

Das in dieser Arbeit erläuterte assisted DND Version 2 (aDNDv2) ist eine konsequente Weiterentwicklung des bereits in [191] veröffentlichten aDNDv1. Im Vergleich zu aDNDv1 wurden an aDNDv2 zahlreiche Optimierungen vorgenommen, jedoch keine Änderungen am KIIdI-Eingabemodus selbst oder am zugrundeliegenden Interaktionsmodell. Weiterhin wurde auch aDNDv2 mithilfe einer anonymisierten Nutzerstudie untersucht, siehe Abschnitt 4.2.3. Sowohl diese Optimierungen als auch die Studie wurden dabei durch [192] umgesetzt.

4.2.2. Implementierung aDNDv2

Die Umsetzung der Anforderungen kann in zwei wesentliche Schritte aufgeteilt werden. Der erste Schritte beinhaltet die Konzeption der KI-Integration. Neben der Auswahl des Algorithmus muss in diesem Schritt auch festgelegt werden, welche Klassen bzw. Objekte der Algorithmus später detektieren können soll. Hierzu muss auch ein entsprechender Datensatz angelegt werden. Im zweiten Schritt wird diese KI in ein passendes Interaktionsmodell integriert, sodass sich der neue

Klidi-Eingabemodus mit einer möglichst intuitiven Navigationsstruktur in die bestehende DNDv2-Architektur einbettet.

4.2.2.1. Konzeption KI

Zur Realisierung einer Objekterkennung für die direkte Erkennung von Objekten in einer Szene, also live, wurde das Convolutional Neural Network (CNN) You Only Look Once (YOLO), genauer *Scaled-YOLOv4*, ausgewählt. Zum Zeitpunkt der Konzeption ermöglichte *Scaled-YOLOv4* ein vielversprechendes Verhältnis zwischen durchschnittlicher Präzision bei der Objekterkennung (mean Average Precision (mAP)) und Inferenz-Zeit, siehe Abschnitt 3.2.2.4.

Klassen und Datensatz: Die Klassen für den gelabelten Datensatz, für das Training von *Scaled-YOLOv4*, wurden mithilfe von Daten aus den Pfadanalysen aus den Studien zu DNDv1 und DNDv2 festgelegt, siehe Tabelle 4.1).

Tabelle 4.1.: Übersicht über die fünf am häufigsten ausgewählten FoBaST-Elemente in den beiden Studien zu DNDv1 und DNDv2.

FoBaST-Element	Summe Pfade	FoBaST-Element	Summe Pfade
<i>Frühstück</i>		<i>Mittagessen</i>	
Weizenbrötchen	87	Pudding	92
Butter	75	Soße	81
Käse (Scheiben)	69	Pellkartoffeln	74
Schinken	53	Wasser	58
Eier	45	Gemüse (gedünstet)	57
...
<i>Abendessen</i>		<i>Zwischenmahlzeiten</i>	
Butter	74	Wasser	57
Käse (Scheiben)	50	Kekse	29
Mischbrot	47	Apfelschorle	17
Vollkornbrot	35	Saft	14
Joghurt (Früchte, 3,5%)	25	Milchkaffee	13
...

Mit dieser Herangehensweise wurde der Anforderung der Expert:innen nachgekommen, dass bei selben Eingaben über beide Eingabemodi auch dieselben Tagebucheinträge erzeugt werden. Weiterhin wurde bei der Erstellung des Datensatzes das Problem der *Gleichartigkeit* berücksichtigt, indem gleichartige FoBaST-Elemente und FoBaST-Kategorien zu Gruppen zusammengefasst wurden, siehe Tabelle 4.2.

Tabelle 4.2.: Auszug aus der Zuordnung von FoBaST-Elementen sowie FoBaST-Kategorien zu Gruppen (Kategorien mit (*) markiert). Die vollständige Liste mit allen 41 Klassen und deren Zuordnungen kann der Tabelle A.3 im Anhang entnommen werden, mit der der FoBaST von DNDv2 zu 95 % abgedeckt wird.

Nr.	Klasse	FoBaST-Elemente
1	Apfel	Apfel
2	Banane	Banane
3	Hülsenfrüchte	Hülsenfrüchte
7	Backwaren	Brot*, Brötchen*, Croissant
15	Tassengetränke	Kaffee*, Milch*, Tee*, Saft, Schorle, Wasser
19	Glasgetränke	Kaffee*, Milch*, Tee*, Bier, Saft Schorle, Spirituosen, Wasser, Wein
...	...	

Der für diesen Anwendungsfall angelegte Datensatz besteht aus insgesamt 35729 Bildern für 41 Klassen. Neben *Open-Source*-Bildern von *flickr* und *pexel*, wurde auch das *Open Images Dataset* als Quelle für den Datensatz verwendet. Das *Open Images Dataset* verfügt dabei zusätzlich auch über Bounding Boxes (BBs), welche ebenfalls in Teilen übernommen werden konnten. Dadurch, dass das *Open Images Dataset* als *Open-Source* Datenbank für Bilder frei zugänglich ist und die Qualität der Daten und BBs somit keiner strikten Kontrolle unterliegt, mussten diese überprüft werden. Weiterhin wurden nicht alle Klassen von den genannten Quellen abgedeckt, sodass zusätzliche Bilder aufgenommen und manuell mit BBs und Labels versehen werden mussten. Weiterhin verfügen weder *flickr* noch *pexel* über BBs, welche folglich ebenfalls manuell ergänzt werden mussten, siehe Abbildung 4.10.

Erzeugung des Modells: Für die Objekterkennung wurde *Scaled-YOLOv4* eingesetzt, siehe Abschnitt 3.2.2.4. Ausgewählt wurde dieser Algorithmus aufgrund

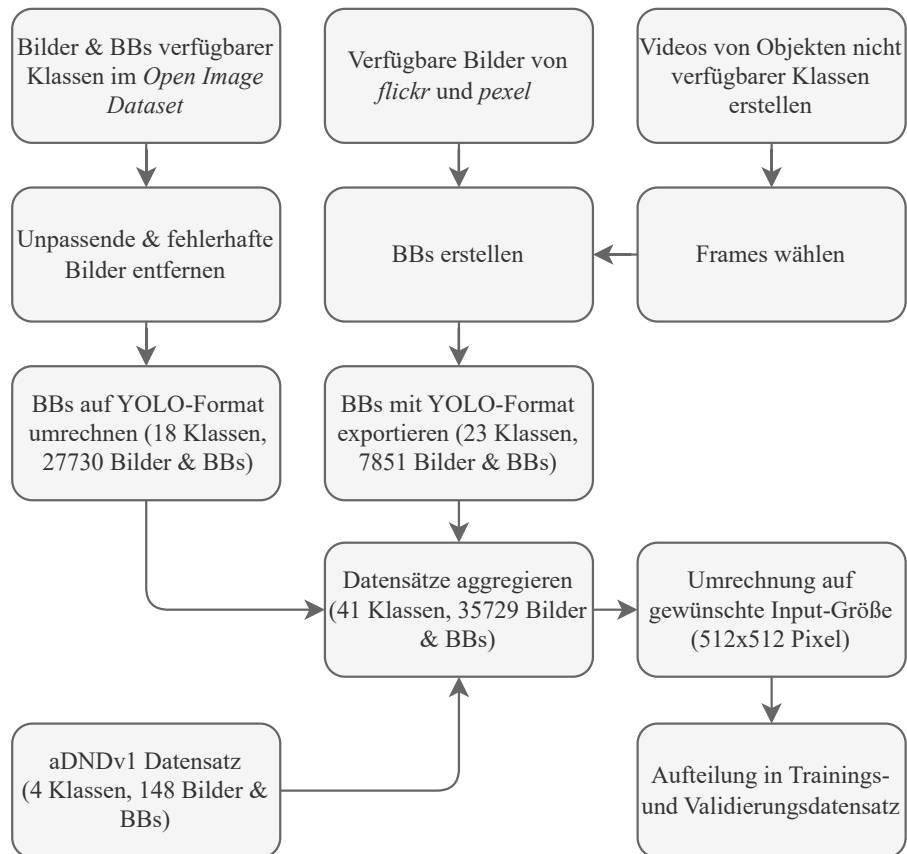


Abbildung 4.10.: Quellen, Erstellung, Quantität, Vorverarbeitung und Aggregation der Bilder und BBs für den Datensatz für das Training des Objekterkennungsalgorithmus. Die Anzahl an BBs ist dabei höher als die der Bilder, da sich in verschiedenen Bildern mehrere Objekte und damit mehrere BBs befinden können.

seiner hohen Genauigkeit (mAP) sowie seiner hohen Ausführungsfrequenz (Single Shot Multibox Detector (SSD)), um den Nutzer:innen direkt, während der Aufnahme der Szene, Feedback über die erkannten Klassen liefern zu können. Das Training, bzw. die Erzeugung des Modells, wurde auf einem KI-Server (*NVIDIA DGX-1-Server: 8×TeslaV100 32 GB GPU*) durchgeführt. Weiterhin wurde für das Training eine virtuelle und teilweise vorkonfigurierte Umgebung (*Docker-Container: pytorch:1.7.1-cuda11.0-cudnn8-runtime*) verwendet.

Pro Mahlzeit wurde zunächst ein Modell erzeugt, um zu untersuchen, wie stark sich der *Fluch der Dimensionen*, siehe Abschnitt 3.2.2.4, auf die mAP des Modells auswirkt. Zudem wurden diese Modelle zunächst mit wenigen Klassen trainiert und dann jeweils um fünf Klassen ergänzt. Dabei wurde die Häufigkeit aus den in Tabelle 4.1 angeführten Summen der validen Pfade abgeleitet. Es hat sich gezeigt, dass auch die maximale Anzahl von 45 Klassen in der Mahlzeit Frühstück zu keiner signifikanten Verschlechterung der Average Precision (AP) führt, siehe Abbildung 4.11.

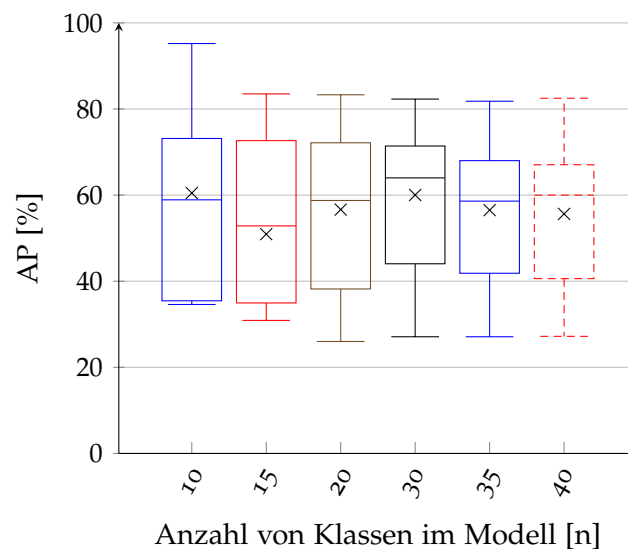


Abbildung 4.11.: Übersicht der AP-Verteilungen für eine aufsteigende Anzahl von Klassen für das KI-Modell zur Objekterkennung für das Frühstück. Der mAP-Wert des jeweiligen Modells ist durch ein „x“ markiert.

Mittagessen und Abendessen verhalten sich ähnlich, siehe Abbildung A.1 und A.2 im Anhang. Das Modell für die Zwischenmahlzeiten weist mit 65,86 einen höheren mAP auf, siehe Abbildung A.3 im Anhang. Weiterhin wurde ein Modell mit allen 41 Klassen trainiert, siehe Abbildung 4.12.




Abbildung 4.12.: Übersicht aller AP-Verteilungen für die Modelle zu jeder Mahlzeit sowie eines Modells für alle 41 Klassen. Der mAP-Wert des jeweiligen Modells ist durch ein „x“ markiert.

Auf Basis dieser Auswertungen wurde für jede Mahlzeit ein eigenes Modell verwendet. Weiterhin wurde, aufgrund der geringen Abweichungen zwischen wenigen und vielen Klassen, jeweils das Modell mit der größten Anzahl an Klassen verwendet. Die Auswahl des Modells geschieht durch die Betätigung des jeweiligen Plus-Buttons neben der zugehörigen Mahlzeit. Der Klidi-Eingabemodus, also die Art und Weise wie dieses Modell in aDNDv2 integriert wurde, wird im Folgenden erläutert.

4.2.2.2. Integration KI

Der Klidi-Eingabemodus und der manuelle Eingabemodus des aDNDv2 können über den Plus-Button der jeweiligen Mahlzeit in der Tagesübersicht gestartet

werden. Nach Berührung des Plus-Buttons erscheint hierzu ein Auswahlfeld. In diesem Auswahlfeld kann zwischen dem Klidi-Eingabemodus und dem manuellen Eingabemodus, welcher schon im Abschnitt 4.1.7 erläutert wurde, gewählt werden. Der Klidi-Eingabemodus ist in vier Schritte aufgeteilt, siehe Abbildung 4.13.


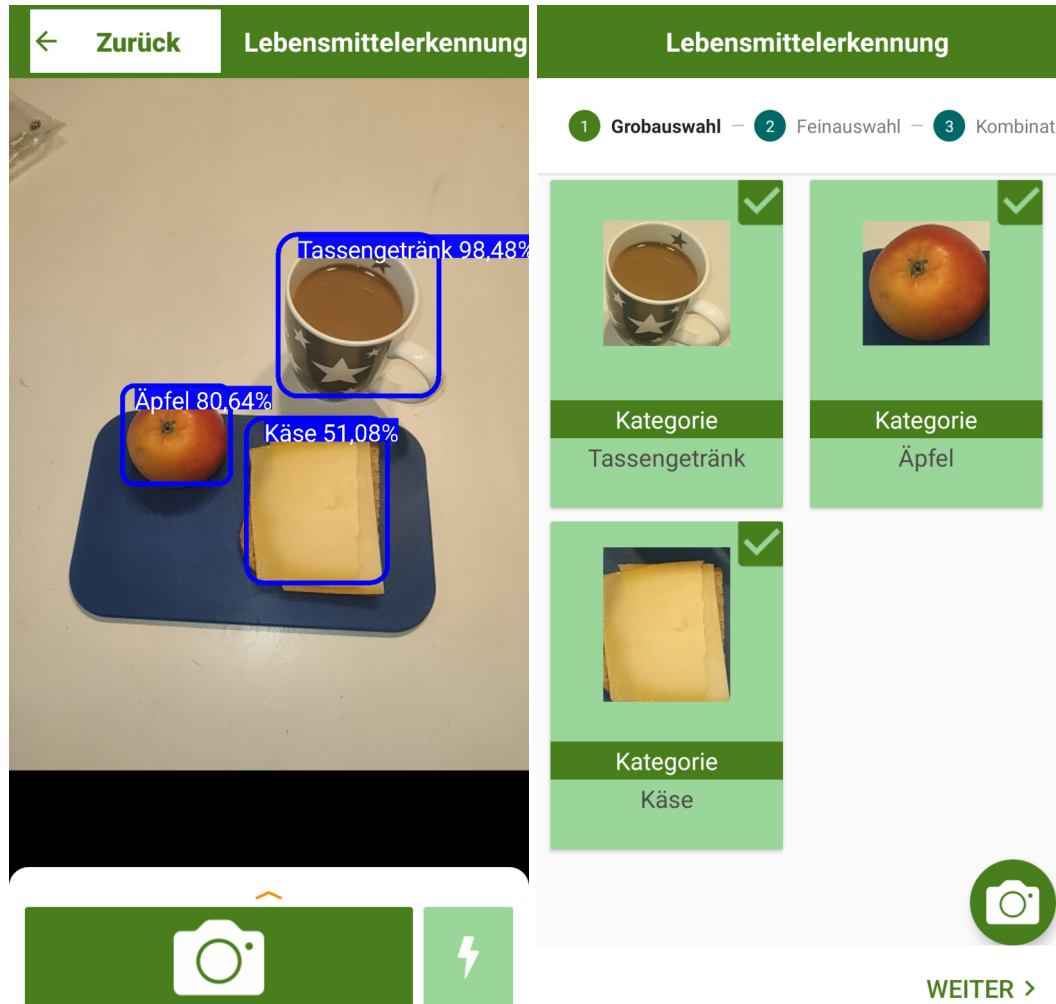


Abbildung 4.13.: Navigationsstruktur des aDNDv2 als UML-Zustandsdiagramm für die Eingabe einer Mahlzeit mithilfe des Klidi-Eingabemodus, in Anlehnung an [191].

Schritt 1: Direkt nach dem Start des Klidi-Eingabemodus wird die rückwärtige Kamera des mobilen Endgerätes aktiviert. Weiterhin wird der/die Nutzer:in dazu aufgefordert, die Kamera so auszurichten, dass diese auf die zu erfassende Szene gerichtet ist, siehe Abbildung 4.14a. Nachdem die in der Szene erkannten Klassen bestätigt wurden, werden diese in einer Liste angezeigt. Wie in Abbildung 4.14a zu erkennen ist, werden hier sowohl FoBaST-Elemente (z. B. Apfel und Käse) als auch FoBaST-Kategorien (z. B. Tassengetränke) direkt erkannt. Damit verhält sich die Objekterkennung, wie in der Konzeption vorgesehen.

Schritt 2: In dieser Liste ist es möglich einzelne Einträge zu deselektieren, aber auch die Objekterkennung zu wiederholen, um weitere Klassen zu ergänzen, siehe Abbildung 4.14b. In Schritt 2 fordert das System dazu auf, die erkannten Objektklassen, z. B. Heißgetränke, weiter zu spezifizieren und passende FoBaST-Elemente auszuwählen. Hierzu wird die entsprechende Kategorie im FoBaST geöffnet und es kann, wie bei der manuellen Methode, das verzehrte



(a) KI-basierte Objekterkennung mit Position und Wahrscheinlichkeit der Erkennung für jedes Objekt.

(b) Überprüfung erkannter Objekte und Möglichkeit zur Ergänzung von Objekten über erneute Erkennung (Kamera-symbol).

Abbildung 4.14.: Schritt 1: KI-basierte Objekterkennung & Überprüfung einer beispielhaften Mahlzeit.

Nahrungsmittel, Getränk oder Nahrungsergänzungsmittel ausgewählt und die Menge eingegeben werden. Bei direkt erkannten FoBaST-Elementen lässt sich die aus dem DNDv2 bekannte Übersicht mit den haushaltsüblichen Mengenangaben direkt öffnen und eine entsprechende Menge auswählen, siehe Abbildung 4.15.


Schritt 3: Nachdem die Eingaben des vorherigen Schrittes bestätigt wurden, werden die Eingaben analysiert. Als Ergebnis dieser Analyse wird in Schritt 3 eine Liste mit Nachfragen zu den entsprechenden FoBaST-Elementen angezeigt. Hier besteht nun die Möglichkeit, auf Basis dieser Nachfragen, weitere FoBaST-Elemente hinzuzufügen. Dieser Schritt wird übersprungen, sollten nur FoBaST-Elemente hinzugefügt worden sein, für die keine Kombination existiert, siehe Abbildung 4.16a.

Schritt 4: Zum Schluss wird eine Zusammenfassung aller hinzugefügten FoBaST-Einträge angezeigt. Hier ist es noch möglich Einträge zu ändern, zu löschen oder zu ergänzen, siehe Abbildung 4.16b. Durch die Bestätigung der Zusammenfassung wird die aktuelle Ansicht geschlossen und die Tagesübersicht geöffnet. In dieser sind nun alle FoBaST-Elemente unter der vorher ausgewählten Mahlzeit ergänzt worden.

Die finale Bestätigung wurde implementiert, um das Feedback der Studienteilnehmer:innen aus der Studie zum DNDv2 zu berücksichtigen, die eine solche Bestätigung für jedes einzelne FoBaST-Element gefordert hatten.

4.2.3. Studiensetting

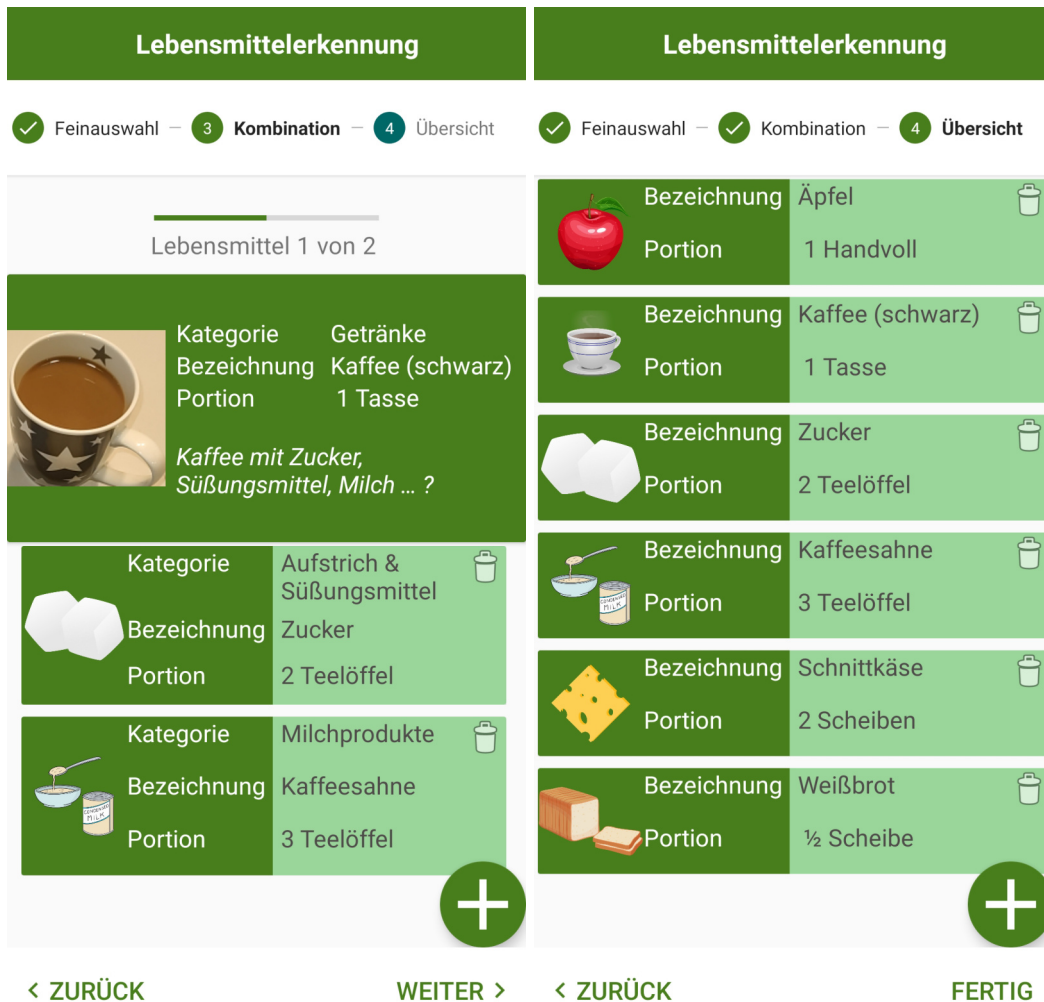
Das Ziel der durchgeführten Studie war es, die Benutzbarkeit der neuartigen Eingabemethode von aDNDv2 zu erfassen und mit zwei anderen digitalen Ernährungstagebüchern (*FatSecret*, *MyFitnessPal*) zu vergleichen. Die im Folgenden beschriebene Nutzerstudie zum aDNDv2 ist von der Rekrutierung der Teilnehmer:innen sowie den verwendeten Fragebögen und Erhebungen identisch mit dem Studiensetting zur Nutzerstudie zum aDNDv1. Der Studienablauf und die Aufgaben für die Studienteilnehmer:innen mussten jedoch angepasst werden, da die KI von aDNDv1 nur für die Erfassung des Frühstücks entwickelt wurde, die KI von aDNDv2 jedoch alle Mahlzeiten (Frühstück, Mittagessen, Abendessen und



(a) Aufforderung alle Objekte in Oberkategorien zu präzisieren und für alle Objekte eine Menge einzugeben.

(b) Sind alle Einträge vollständig, wird der (pulsierende) orange/rote Rahmen entfernt und der nächste Schritt kann durch den Weiter-Button gestartet werden.

Abbildung 4.15.: Schritt 2: Feinauswahl & Mengeneingabe für eine beispielhafte Mahlzeit.



(a) Schritt 3: Anzeige aller Getränke, Nahrungsmittel und Nahrungsergänzungsmittel, für die Kombinationen möglich sind.

(b) Schritt 4: Visualisierung aller Eingaben und Möglichkeit zu Anpassung dieser. Hinzugefügt werden können diese Eingaben dann über den Fertig-Button.

Abbildung 4.16.: Schritt 3: Kombinationen & Mengeneingabe sowie Schritt 4: Zusammenfassung einer beispielhaften Mahlzeit.

Zwischenmahlzeit) umfasst. Die Erhebung der Daten erfolgte in beiden Fällen anonym.

Rekrutierung: Aufgrund der 2021, zum Zeitpunkt der Planung und Durchführung der Studie, vorherrschenden COVID₁₉-Pandemie, war es nicht möglich, die vulnerable Zielgruppe der hochaltrigen und vom Frailty-Syndrom betroffenen Personen als Studienteilnehmer:innen für die Studie einzuschließen. Alternativ wurden über persönliche Netzwerke Personen kontaktlos über die Studie informiert. Bei einer Bekundung von Interesse zur Teilnahme, wurde die Teilnehmerinformation und die zugehörige Einverständniserklärung ebenfalls kontaktlos zugestellt bzw. eingeholt. Eine Teilnahmevergütung für die Studienteilnehmer:innen erfolgte nicht. Insgesamt sollten 30 Personen in die Studie eingeschlossen werden.

Teilnehmer:innen: Einschlusskriterien für die Teilnahme war der Zugriff auf ein auf Android basierendes mobiles Endgerät und die Fähigkeit, die für die Studie notwendigen Anwendungen auf diesem zu installieren. Ausschlusskriterien für die Studie war die fehlende Fähigkeit zur Einwilligung in die Studie. Weitere Ausschlusskriterien waren eine unzureichende Fähigkeit, die Studieninhalte und die Durchführung zu verstehen oder die Teilnahme an anderen Studien.

Studienablauf: Die Studienteilnehmer:innen wurden aufgefordert, die für die Durchführung der Studie notwendigen mobilen Anwendungen (*FatSecret*, *MyFitnessPal* und *aDNDv2*) auf ihrem mobilen Endgerät (Smartphone oder Tablet-Computer) zu installieren. Im Anschluss daran wurde den Studienteilnehmer:innen zufällig eine Mahlzeit (Frühstück, Mittagessen, Abendessen oder Zwischenmahlzeit) zugewiesen. Insgesamt sollte die ihnen zugewiesene Mahlzeit fünfmal mit den unterschiedlichen Eingabemethoden erfasst werden, siehe Tabelle 4.4. Die Reihenfolge konnte dabei von den Studienteilnehmer:innen frei gewählt werden.

MyFitnessPal wurde ausgewählt, da es zum Zeitpunkt der Studie zum *aDNDv1* das am häufigsten im *Google Play Store* heruntergeladene mobile Ernährungstagebuch war. Das mobile Ernährungstagebuch *FatSecret* wurde ausgewählt, da es zum Zeitpunkt der ersten Studie zu *aDNDv1* das einzige populäre mobile Ernährungstagebuch mit KI-Unterstützung war und damit sowohl über einen manuellen als auch semi-automatisierten Eingabemodus verfügte. Aufgrund der anhaltenden

Anwendung	Eingabemethode
aDNDv2	manuelle Eingabe
aDNDv2	semi-automatische Eingabe
FatSecret	manuelle Eingabe
FatSecret	semi-automatische Eingabe
MyFitnessPal	manuelle Eingabe

Tabelle 4.4.: Übersicht über die drei mobilen Ernährungstagebücher und die insgesamt fünf unterschiedlichen Eingabemethoden.

Popularität und einer besseren Vergleichbarkeit zwischen den Studien wurden *MyFitnessPal* und *FatSecret* erneut eingesetzt.

Fragebögen und Erhebungen: Erhoben wurde die Benutzerfreundlichkeit für die drei digitalen Ernährungstagebücher und deren insgesamt fünf Eingabemethoden. Hierzu wurden die Studienteilnehmer:innen aufgefordert, den SUS, siehe Abschnitt 4.1.4, nach jeder der fünf Eingabemethoden auszufüllen. Weiterhin wurden Videos von den Bildschirmen der mobilen Endgeräte der Studienteilnehmer:innen während der Verwendung der verschiedenen Eingabemöglichkeiten aufgezeichnet. Diese Aufnahmen wurden dazu eingesetzt, um Zeiten für die unterschiedlichen Eingabemethoden sowie die Erkennungsquoten für die KI-basierten Methoden zu ermitteln.

4.2.4. Ergebnisse

Insgesamt haben 30 Personen die Studie vollständig abgeschlossen. Es wurden 150 Bildschirmaufnahmen (Gesamtlänge von 3 Stunden und 25 Minuten) sowie 150 SUS-Fragebögen erhoben. Diese wurden pro Eingabemethode ausgewertet und mit den Ergebnissen der vorangegangenen Studie zum aDNDv1 [191] in Abbildung 4.17 gegenübergestellt.

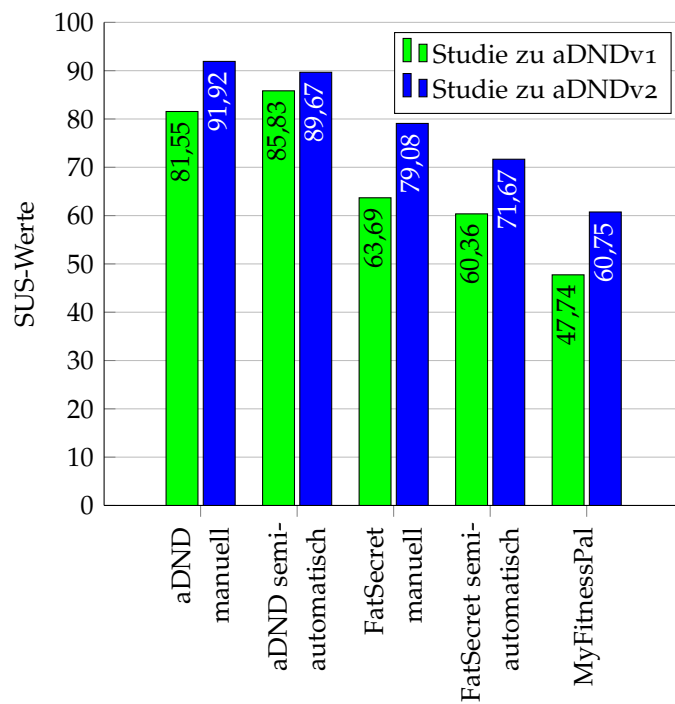


Abbildung 4.17.: Vergleich der SUS-Werte aus Studie zu aDNDv1 [193] sowie der SUS-Werte zu aus Studie zu aDNDv2.

Durch die Auswertung der Bildschirmaufnahmen wurden weitere Parameter ermittelt. Für die Mahlzeiten wurden insgesamt 94 (Mittelwert = 3,133 Einträge pro Person pro Mahlzeit) Nahrungsmittel, Getränke oder Nahrungsergänzungsmittel eingegeben. Weiterhin wurden die Zeiten und die Anzahl an Interaktionen, welche für das Protokollieren der jeweiligen Mahlzeiten mit den fünf Eingabemethoden benötigt wurden, auf Basis der Bildschirmaufnahmen ermittelt, siehe Abbildung 4.18 und 4.19.




Abbildung 4.18.: Übersicht über die Zeit, die von den Proband:innen benötigt wurde, um die ihnen jeweils zugewiesene Mahlzeit zu protokollieren.

Abbildung 4.20 visualisiert die Korrelation zwischen der Menge an Eintragungen und der benötigten Zeit. Hier ist zu erkennen, dass zwischen dem zeitlichen Aufwand und der manuellen Eingabemethode des aDNDv2 eine stärkere Korrelation besteht als zwischen der semi-automatischen Eingabemethode und dem zeitlichen Aufwand.




Abbildung 4.19.: Übersicht über die Anzahl an Interaktionen, die von den Proband:innen benötigt wurde, um die ihnen jeweils zugewiesene Mahlzeit zu protokollieren.

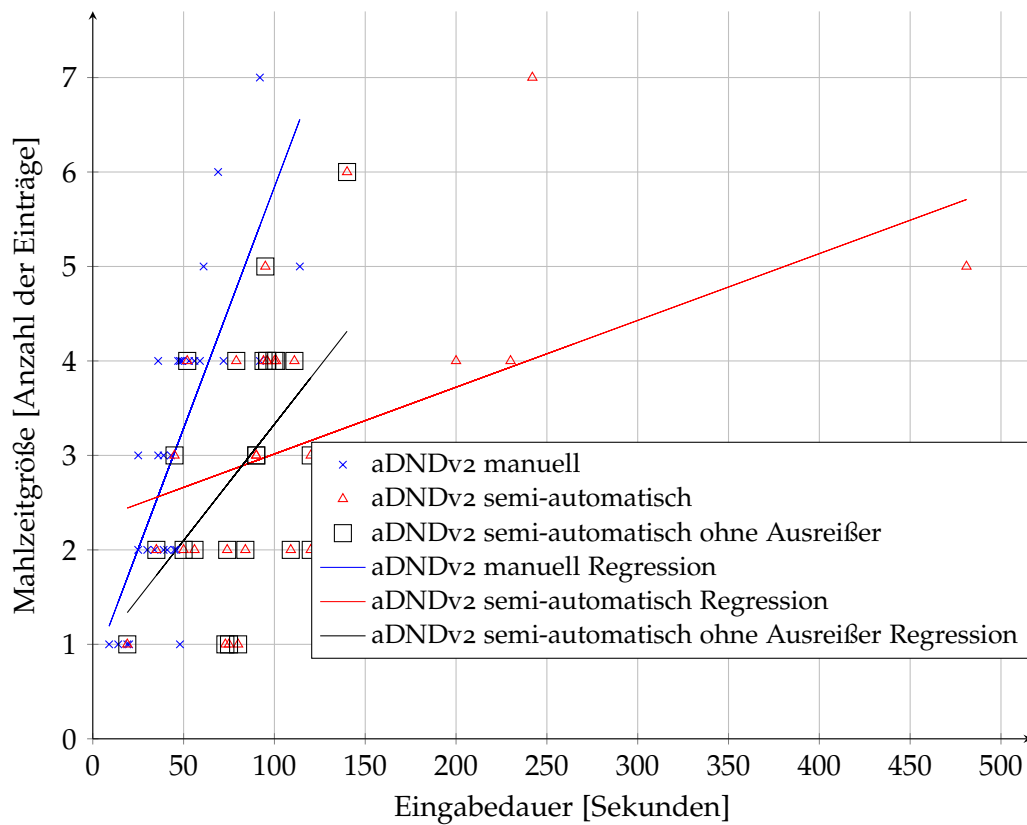


Abbildung 4.20.: Korrelation zwischen der Größe der Mahlzeit, im Sinne der Anzahl von Getränken, Lebensmitteln und Nahrungsergänzungsmitteln, und der für die Protokollierung benötigten Zeit.

Weiterführend wurden die Bildschirmaufnahmen dazu verwendet, die Erkennungsquoten für die protokollierten Nahrungsmittel, Getränke und Nahrungsergänzungsmittel zu berechnen, siehe Abbildung 4.21. Hierbei ist zu berücksichtigen, dass diese Auswertung nur für die semi-automatischen Eingabemethoden von aDNDv2 und *FatSecret* möglich ist, da nur diese Anwendungen mit KI-basierten Eingabemethoden ausgestattet sind.




Abbildung 4.21.: Vergleich der Erkennungsquoten des KlidI-Eingabemodus von aDNDv2 sowie von der KI-gestützten Eingabemethode von *FatSecret*. Aufgrund der trainierten Klassen lag für aDNDv2 das theoretische Maximum bei 68,42 %.

Weiteres Feedback, direkt durch die Studienteilnehmer:innen selber oder indirekt als Beobachtung durch die Studienmitarbeiter:innen, kann in drei Kategorien aufgeteilt werden: Benutzeroberfläche, Inhalte und Funktionen.

Benutzeroberfläche: Sowohl die manuelle als auch die semi-automatische Eingabemethode des aDNDv2 wurde von den Studienteilnehmer:innen gelobt. Als Kritikpunkt wurde angeführt, dass die manuelle Eingabemethode für jeden Eintrag neu gestartet werden muss. Das dies bei der semi-automatischen Methode nicht der Fall ist und hier die gesamte Mahlzeit erfasst werden kann, ohne, dass die Anwendung wieder zurück zur Tagesübersicht springt, wurde positiv erwähnt. Zustimmung fand auch die Darstellung der Nahrungsmittel, Getränke und Nahrungsergänzungsmittel in Form von Piktogrammen. Durch die Auswertung der Bildschirmaufnahmen hat sich gezeigt, dass das fehlende Feedback von *FatSecret* über erkannte oder eben nicht erkannte Nahrungs-

mittel, Getränke und Nahrungsergänzungsmittel zu einer Unsicherheit im Umgang mit der Anwendung führte.

Inhalte: Bemängelt wurde beim aDNDv2 der begrenzte Umfang von verfügbaren Nahrungsmitteln, Getränken und Nahrungsergänzungsmitteln. Es fehlten z. B. Frischkäse und Cherry-Tomaten. Weiterhin wurde beim aDNDv1 negativ angemerkt, dass die Möglichkeiten der Mengenangaben über die haushaltsüblichen Mengen zu eingeschränkt ist. Werden z. B. kleine Gurken vom System einzeln erkannt, kann eine korrekte Angabe der Menge über die Menge „Handvoll“ nicht erfolgen.

Funktionen: Positiv wurde angemerkt, dass die Objekterkennung in der Lage ist mehrere Lebensmittel gleichzeitig zu erkennen (aDNDv1). Auch die direkte Erkennung (live) wurde als positiv angemerkt (aDNDv1). Ein Kritikpunkt an der Funktionalität von aDNDv2 war, dass die Nachfragen von Kombinationen nicht vom Verhalten der Nutzer:innen gelernt haben und entsprechende Nachfragen immer wieder gestellt wurden. Weiterhin wurde beim aDNDv2 bemängelt, dass die KI-basierte Objekterkennung des aDNDv2 schneller sein müsste. Im Vergleich zu den Bildschirmaufnahmen aus der Studie zum aDNDv1 fällt hier auf, dass die Studienteilnehmer:innen die Anwendung hier deutlich häufiger außerhalb der Aufgabenstellung verwendet haben, um mit der Objekterkennung auch diverse andere Dinge zu erkennen.

4.2.5. Experimentelle Volumenerfassung

Neben der semi-automatisierten Klassifikation, der Objekterkennung, erfolgt die Angabe der Mengen, also die Quantifikation im Klidi-Eingabemodus manuell. Eine manuelle Eingabe der Mengen, insbesondere über eine grafische Oberfläche, basierend auf großen Schaltflächen und Piktogrammen, ist jedoch bezüglich Funktionalität und damit auch auf die Benutzbarkeit limitiert. Anpassungen, Weiterentwicklungen und Erweiterungen sind zwar immer möglich, jedoch ist es nicht möglich alle Anforderungen über eine derartige grafische Benutzeroberfläche zu adressieren. Nur wenige Ergänzungen bei den möglichen haushaltsüblichen Mengenangaben und den zugehörigen Faktoren würden, aufgrund der exponentiell wachsenden Anzahl an Schaltflächen, schnell zu einer sehr großen und unübersichtlichen oder nicht mehr darstellbaren Anzahl an Schaltflächen führen.

Derartige Anforderungen können somit nur in einem begrenzten Umfang realisiert werden, da sonst die Komplexität der Anforderungen zu stark ansteigt, siehe Abbildung 4.22.




Abbildung 4.22.: Eingabe der Mengen über semi-dynamische Faktoren, welche sich über Schaltflächen skalieren lassen. Entnommen aus einer Weiterentwicklung des aDNDv2.

Umfangreicher lassen sich diese Anforderungen durch einen automatisierten Ansatz erfüllen. Wie auch bei der Objekterkennung wird kein vollständig automatisierter Ansatz angestrebt, da auch hier davon ausgegangen werden muss, dass die Berechnung des Volumens nicht fehlerfrei bzw. nicht immer möglich sein wird. Weiterhin müssen auch bei der Erfassung des Volumens die speziellen Bedarfe der Zielgruppe berücksichtigt werden. Besonders zu berücksichtigen ist, dass die Mahlzeiten der Zielgruppe häufig nicht vollständig verzehrt werden. Damit steht entsprechend nicht die Erfassung der eigentlichen Mahlzeit im Vordergrund, sondern die Erfassung des verzehrten Anteils der Mahlzeit. Eine solche Messung lässt sich jedoch nur mithilfe von multiplen Messungen, zu Beginn und nach Abschluss der Mahlzeit, realisieren. Weiterhin müssen vor allem geringe Verzehrsmengen von hochaltrigen und vom Frailty-Syndrom betroffenen Personen berücksichtigt werden.

Ein externes prototypisches Setup (Intel® RealSense™ Kamera D435, aktive Stereoskopie, siehe Abschnitt 3.1.2.1) wurde aufgebaut, um zu untersuchen, ob und mit welcher Genauigkeit sich (homogene) Lebensmittel in geringen Mengen (Teelöffel-

Schritte) mit 3D-Kameras erfassen lassen. Dieses Setup und die nachfolgend angeführten Ergebnisse sind eine Zusammenfassung der schon in [193] veröffentlichten Arbeit. Hierzu wurde zunächst ein statischer Prototyp entwickelt und die Kamera entsprechend konfiguriert, siehe Abbildung 4.23 und Tabelle 4.5.




Abbildung 4.23.: Experimentelles Setup für die Berechnung von Volumina für die automatische Bestimmung von Verzehrsmengen mittels Intel® RealSense™ Kamera D435.

Nach Anwendung verschiedener Filter und statistischer Methoden zur Vor- und Nachbearbeitung der Punktwolken, wird die jeweils resultierende Punktwolke:

$$PC = \{p_1, p_2, \dots, p_n\} : p \in \mathbb{R}^3 \quad (4.1)$$

parallel verarbeitet, siehe Abbildung 4.24.

Die Punkte $p = \{x, y, z\}$ sind dabei jedoch nicht angeordnet wie in einem herkömmlichen zweidimensionalen Bild und müssen daher umgerechnet werden. Auch wenn die Tiefe z direkt verwendet werden könnte, wird auch dieser Wert umgerechnet. Die relativen Schwankungen der Entfernung, z. B. durch Rauschen, wirken sich geringer auf einen Fehler aus, wenn die Entfernung von der Ebene der Kamera umgerechnet wird. Dies wird über die Berechnung einer Ebene erreicht, auf der sich eine vermeintliche Mahlzeit befindet. Parallel zur Bestimmung der Ebene, benötigt jeder Punkt eine Fläche, damit ein zugehöriges Volumen ermittelt werden kann. Dies wird über die Delaunay-Triangulation erreicht. Mithilfe der

Tabelle 4.5.: Übersicht über die Konfiguration der Intel® RealSense™ Kamera D435, in Anlehnung an [193].

Stereo-Sensor		Farbsensor	
Preset	Default	Preset	Default
Auflösung [px]	1280 × 720	Auflösung [px]	1280 × 720
Bildrate [fps]	6	Bildrate [fps]	6
Tiefenauflösung	Z16	Farbtiefe	RGB8
Laser Power	Max	-	-
Auto Exposure	Enabled	Auto Exposure	Enabled
Depth Units [m]	0.001	-	-
Emitter	Enabled	-	-
Infrarot 1 & 2	Disabled	-	-

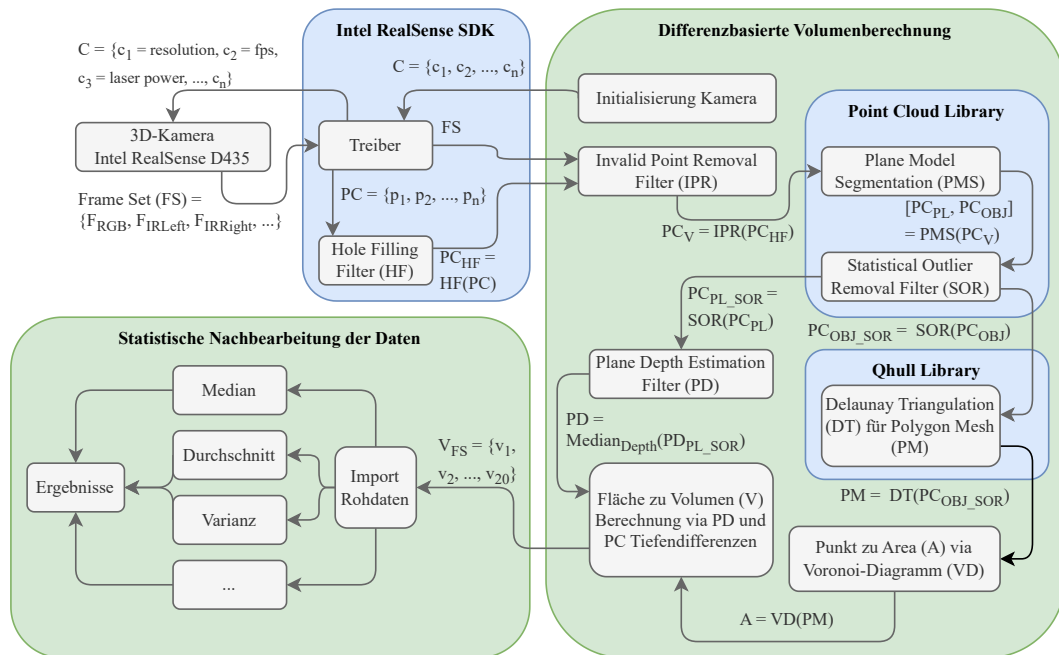


Abbildung 4.24.: Darstellung der Verarbeitung, Konfiguration der Kamera, Filterung und statistischen Verarbeitung der Punktwolke sowie die resultierende Berechnung des Volumens, in Anlehnung an [193].

Delaunay-Triangulation wird nun zwar eine Oberfläche beschrieben, welche in einzelne Dreiecke aufteilbar ist, jedoch nicht pro Punkt. Entsprechend ist ein weiterer Schritt notwendig, um eine Fläche pro Punkt Zuordnung zu ermöglichen. Hierzu wird das Voronoi-Diagramm verwendet, siehe Abbildung 4.25.

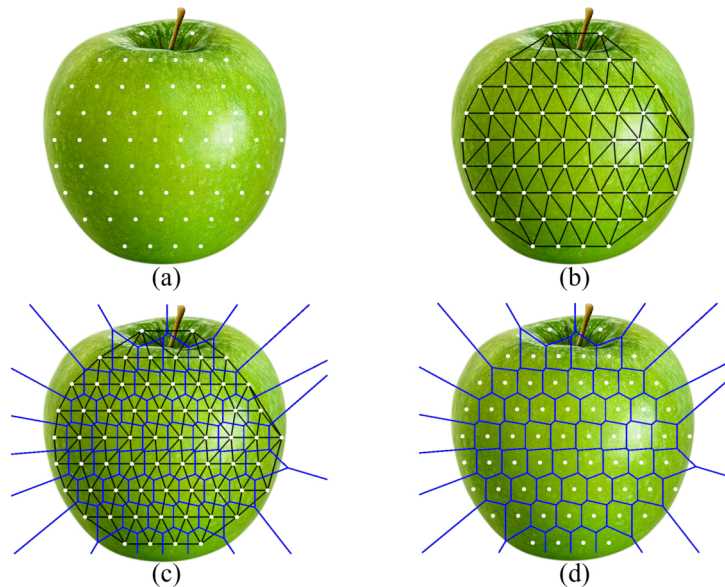


Abbildung 4.25.: Beispielhafte Darstellung der Verarbeitung der Punktwolke (a) über die Berechnung der Delaunay-Triangulation (b) zur Berechnung des Voronoi-Diagramms (c) und der resultierenden Flächen pro Punkt (d), in Anlehnung an [193].

Mithilfe dieser Fläche (pro Punkt) und einer Tiefe, kann für jeden Punkt $p_i(x, y, z) \in PC$ ein Volumen berechnet werden. Hierzu kann jedoch nicht die Tiefe z verwendet werden, welche für alle Punkte $p_i(x, y, z) \in PC$ direkt verfügbar wäre, da dieses z den Abstand zur Kamera und nicht zur berechneten Ebene beschreibt. Diese Ebene wird aus den Punkten der Punktwolke approximiert. Da der Abstand der Ebene zur Kamera bekannt ist, kann die Höhe eines jeden Punktes, welcher nicht auf dieser Ebene liegt, separat berechnet werden. Weiterhin kann bei der Berechnung der Voronoi-Flächen (VF) die Tiefe (z) weggelassen werden, sodass diese Flächen orthogonal zur Kamera stehen. Wird die Mahlzeit direkt von oben aufgenommen, so wie es im experimentellen Aufbau der Fall ist, stehen die Flächen damit ebenfalls orthogonal zur approximierten Ebene (unter Voraussetzung, dass diese kein Gefälle

aufweist). Die Höhe (H) eines Punktes (p_i) in Relation zur approximierten Ebene (E) ergibt sich dabei aus der Differenz der Tiefe der Ebene und der Tiefe von p_i . Damit können für jeden Punkt auf einem zu erfassenden Objekt zylindrische Teil-Objekte erzeugt werden, deren summierten Volumina das Volumen der Oberfläche eines Objektes bis zur approximierten Ebene (E) ergeben:

$$V_{Obj} = \sum_i VF(p_i) * H(E(PC), p_i) > \theta \quad (4.2)$$

Die verzehrte Menge kann dann durch die Subtraktion einer Aufnahme vor dem Verzehr der Mahlzeit sowie einer Aufnahme nach Abschluss des Verzehrvorgangs berechnet werden.

4.2.5.1. Laborexperimente und Ergebnisse

Die in [193] beschriebenen Experimente und deren Ergebnisse zeigen, dass für größere Volumina, z. B. bei der Überwachung des Verzehrs von 259,26 ml Schokoladenpudding in sechs Schritten, ein durchschnittlicher Fehler von 7,3 % mit einer Standardabweichung von 4,67 erreicht wurde. Verglichen wurden diese Ergebnisse mit idealisierten Schätzungen eines Teller-Protokolls, sodass immer der 25 % Schritt gewählt wurde, welcher am dichtesten an den realen Werten (gemessen mit einer Waage) lag. Hier lag der durchschnittliche Fehler bei 31,96 % mit einer Standardabweichung von 34,57. Speziell bei sehr geringen Mengen, bzw. bei einem Verzehr von unter 12,5 % von einer Mahlzeit, ergibt ein idealisiertes Teller-Protokoll 0 % und damit eine Abweichung von 100 %.

Eine weiterführende Analyse, ebenfalls unter Laborbedingungen mit idealisierten homogenen Nahrungsmitteln und gleichbleibender sowie vordefinierter Beleuchtung, hat gezeigt, dass auch das beschriebene System die größten Abweichungen bei kleineren Verzehrmenen aufweist. So muss bei Volumina von unter 50 ml mit einem Fehler von über 30 % gerechnet werden, welcher jedoch mit zunehmender verzehrter Menge fällt. Bei einem Volumen ab 200 ml muss mit einem Fehler von etwa 10 % und bei einem Volumen ab 300 ml mit einem Fehler von unter 5 % gerechnet werden.

4.2.6. Diskussion und Fazit

Die in diesem Abschnitt präsentierten Strategien sowie deren zugehörige Studien und Experimente zeigen, dass ebendiese Strategien mögliche Antworten auf die initial gestellte Fragestellung sind:

„Mit welchen technischen Hilfsmitteln kann das Führen eines digitalen Ernährungstagebuchs für hochaltrige und vom Frailty-Syndrom betroffene Personen weiter vereinfacht werden?“

Berücksichtigt werden muss, dass die beiden Studien zu aDNDv₁ und aDNDv₂, aufgrund der zum Zeitraum der Studien vorherrschenden COVID19-Pandemie, nicht mit der hochaltrigen und vom geriatrischen Frailty-Syndrom betroffenen Zielgruppe durchgeführt werden konnten. Die grundlegenden Erkenntnisse und Tendenzen lassen sich jedoch, aller Voraussicht nach, auf diese Zielgruppe übertragen.

So ist den Ergebnissen bzgl. der Benutzbarkeit von aDNDv₁ und aDNDv₂ (SUS-Werte von 81,55 und 85,83 für die manuelle Eingabe sowie 85,83 und 89,67 für die semi-automatisch Eingabe) zu entnehmen, dass diese signifikant über den Ergebnissen der herkömmlichen digitalen Ernährungstagebücher FatSecret und MyFitnessPal (SUS-Werte zwischen 47,74 bis 79,08) liegen, siehe Abbildung 4.17. Auch wenn gleichartige Studien mit Proband:innen aus der Zielgruppe zu anderen Ergebnissen in absoluten Zahlen führen würden, so ist davon auszugehen, dass die Tendenzen jedoch (mindestens) gleich stark ausgeprägt sind. Die kleineren Schriften und komplexeren Bedienungsstrukturen wären eventuell nicht nur problematisch für die hochaltrige Zielgruppe, sondern könnten unter Umständen sogar dazu führen, dass die Eingabe für diese gar nicht möglich ist.

Weiterhin ist hervorzuheben, dass der höchste SUS-Wert bei der Studie für aDNDv₁ bei der semi-automatischen Eingabe und bei der Studie für aDNDv₂ bei der manuellen Eingabe erzielt wurde. Da aDNDv₂ eine kontinuierliche Weiterentwicklung von aDNDv₁ ist, können die Unterschiede bei den SUS-Werten nur mit den neuen Proband:innen oder durch den Wechsel der KI, bzw. auch durch eine Kombination der beiden Faktoren, erklärt werden.

Der Wechsel der KI für die Objekterkennung von *MobileNet v2* (aDNDv1) auf *Scaled-YOLOv4* (aDNDv2) und die Vergrößerung des Datensatzes für das Training haben zwar zu einer verbesserten Abdeckung des FoBaST geführt, jedoch auch zu einer Verringerung der Frequenz (Inferenz-Zeit), mit der die Objekterkennung auf einem mobilen Endgerät ausgeführt werden kann. Zwar ist *Scaled-YOLOv4* grundsätzlich performanter als *MobileNet v2*, jedoch wurde beim Wechsel der CNN-Architektur auch die Auflösung der Eingangsbilder von $300\text{ px} \times 300\text{ px}$ auf $512\text{ px} \times 512\text{ px}$ vergrößert. Damit hat sich auch die Inferenz-Zeit für die Objekterkennung von 197 ms auf 15888 ms erhöht (Huawei P8 Lite von 2017). Auf älteren mobilen Endgeräten wurde die Inferenz-Zeit entsprechend länger. Dies hat sich folglich auch auf die Zeiten für die Eingabe einer Mahlzeit ausgewirkt, siehe Abbildung 4.18. Weiterhin ist in den Videos der Bildschirmaufnahmen zu erkennen, dass Proband:innen mit performanteren Geräten die Objekterkennung auch häufiger für die Erkennung anderer Objekte ausprobiert haben.

Eine bessere Inferenz-Zeit kann durch die Reduktion der Größe der Eingangsbilder, aber auch durch die Implementierung performanterer Algorithmen zur Objekterkennung, erreicht werden, siehe Abschnitt 3.2.2.4. Parallel wird das Problem durch die sich immer weiter entwickelnde Hardware adressiert. Vor allem auf KI-Berechnungen spezialisierte Hardware, welche z. B. durch Googles Neural Network API (NNAPI) angesprochen werden kann, führt zu signifikanten Steigerungen der Performanz [194].

Neben performanterer Hardware und KI, ist auch die Art und Weise, wie diese Komponenten in einem System miteinander und mit den Nutzer:innen interagieren, zu berücksichtigen, um möglichst gute Ergebnisse zu erzielen. Wie in Abbildung 4.21 bereits gezeigt, erreicht die KI-basierte Objekterkennung von aDNDv2 eine Objekterkennungsquote von 61,70 % und FatSecret eine Objekterkennungsquote von 19,74 %. Der KI-basierte, interaktive, dynamische und interview-artige Eingabemodus (KliDI-Eingabemodus), also die Art und Weise wie die KI in das digitale Ernährungstagebuch integriert wurde, führt zu einer weiteren Verbesserung der Objekterkennungsquote des aDNDv2 von 19,15 % und damit in Summe auf eine Objekterkennungsquote von 80,85 %.

Entgegen den Erwartungen hat sich gezeigt, dass nicht nur kleinere Mahlzeiten mit weniger FoBaST-Elementen schneller über die manuelle Eingabemethode erfasst

werden konnten, sondern auch Mahlzeiten mit bis zu sieben FoBaST-Elementen, siehe Abbildung 4.20.

Diese Ergebnisse zeigen, wie auch die Ergebnisse zahlreicher anderer Arbeiten, siehe Abschnitt 3.2.2, dass KI als potentes Werkzeug eingesetzt werden kann, um bei der selbstständigen Protokollierung des eigenen Verzehrverhaltens zu unterstützen. Weiterhin konnte gezeigt werden, dass die Art und Weise, wie KI in ein System integriert wird, signifikante Auswirkungen auf die Performanz eines Systems haben kann. Bei der Erkennung von Lebensmitteln muss z. B. berücksichtigt werden, dass es nicht möglich ist, gleichartige oder verdeckte Objekte zu erkennen. Neben dem Wissen aus der KI-Domäne muss auch das Wissen aus der Domäne der Ernährungsberatung berücksichtigt werden. So kann nicht davon ausgegangen werden, dass alle relevanten Bestandteile einer Mahlzeit von den Patient:innen auch als separat zu protokollierende Lebensmittel verstanden werden. Wie in einer persönlichen Ernährungsberatung sind selbstständig ausgefüllte Ernährungstagebücher eine wichtige, aber oft unvollständige Grundlage für den eigentlichen dynamischen und interaktiven Prozess der Erhebung des Verzehrverhaltens.

Neben der kontinuierlichen Anpassung und Weiterentwicklung des Systems, durch die Vergrößerung des Datensatzes für das Training der KI oder die Anpassung der KI auf ein kontinuierlich lernendes und sich auf einzelne Nutzer:innen anpassendes System, ist auch die Unterstützung bei der Erfassung der Verzehrmenen eine wichtige Komponente, siehe Abschnitt 4.2.5. Die experimentellen Ergebnisse des skizzierten Systems zeigen, dass mit (aktiven) stereoskopischen Systemen schon jetzt eine genauere Erfassung von Verzehrmenen möglich ist, als z. B. mit dem Teller-Protokoll, siehe Abschnitt 4.2.5.1. Das volle Potenzial eines Systems zur Unterstützung bei der Erfassung von Verzehrmenen kann jedoch nur durch die Kombination mehrerer Komponenten erreicht werden. Neben der Erkennung der Objekte ist außerdem eine Segmentierung erforderlich. Eine grobe Lokalisierung von Objekten mithilfe von Regions Of Interest (ROIs) ist dafür oft nicht ausreichend, da es zu einer multiplen Erfassung von sich überschneidenden Volumina kommen kann. Derartige Überschneidungen sind z. B. bei Tellergerichten zu erwarten. Einzelne und räumlich voneinander getrennte Lebensmittel, wie sie häufig beim Frühstück verzehrt werden, können theoretisch über einen naiveren Ansatz erfasst werden.

Berücksichtigt man die immer leistungsfähiger werdenden Hardware- und Softwaresysteme, so ist anzunehmen, dass eine vollständig ambiente Erfassung des Verzehrverhaltens in naher Zukunft technisch möglich sein wird. Auch die in Abschnitt 4.1 beschriebene Erfassung der körperlichen Aktivität und Körperkompositionsdaten entwickelt sich in diese Richtung. Dennoch muss die Gesamtheit dieser Daten den Verlauf einer therapeutischen Ernährungstherapie nicht widerspruchsfrei erklären können, da noch weitere relevante Faktoren existieren. Wie schon in Abschnitt 2.2.3 beschrieben, ist auch die Zeit der Darmpassage ein wichtiger Faktor, welcher Rückschlüsse über die Qualität der Verwertung zugeführter Getränke, Lebensmittel oder Nahrungsergänzungsmittel zulässt. Da sich die Zeit der Darmpassage über die Stuhlform ableiten lässt, ist eine ambiente Erfassung der Fäzes ein weiterer Punkt, um die Patient:innen bei der selbstständigen Erfassung relevanter Daten zu unterstützen.

4.3. Automatisierte Klassifikation der Stuhlform

Die Bewertung menschlicher Fäzes anhand unterschiedlicher Parameter, z. B. anhand von Farbe oder Volumen, kann Hinweise auf verschiedene gesundheitliche Probleme geben. Unter diesen gesundheitlichen Problemen, weisen Diarrhö und Obstipation eine hohe Prävalenz für die Zielgruppe der hochaltrigen Personen auf. Sowohl eine chronische Obstipation als auch eine chronische Diarrhö haben signifikante Auswirkungen auf die Qualität der Verwertung von verzehrten Mikro- und Makronährstoffen. Insbesondere Informationen über die Form und Struktur von Fäzes, auch als Stuhlform bezeichnet, können relevant für den Kontext der Ernährungsberatung sein, da eine Korrelation zwischen der spezifischen Stuhlform und der Zeit der Darmpassage existiert, siehe Abschnitt 2.2.3.

Bei der Erhebung von Informationen über die eigenen Fäzes können sowohl Scham als auch die oft verringerten (kognitiven) Reserven der Zielgruppe dieser Arbeit dazu führen, dass die Qualität und die Quantität der Daten stark variieren. Dies gilt sowohl für die Erhebung von Daten im direkten Austausch zwischen Patient:innen und Ernährungsberater:innen, als auch für die eigenständige Dokumentation der Stuhlform durch die Patient:innen selbst. Wie bereits in Abschnitt 3.4 angeführt, bieten die aktuellen Entwicklungen in den Bereichen Sensorik und KI das Potenzial Informationen über Fäzes automatisiert und ambient zu erfassen. Entsprechend adressiert der nachfolgende Teil dieser Arbeit folgende Fragestellung:

„Mit welchen technischen Mitteln kann eine automatisierte Klassifizierung von Stuhlformen erreicht werden, um die manuelle Bildaufnahme und die verbale Beschreibung zu ersetzen?“

Zwar existieren neben den mündlichen und schriftlichen Möglichkeiten zur Protokollierung von Stuhlformen auch Ansätze, bei denen (Digital-)Kameras eingesetzt werden, jedoch haben auch diese Verfahren Nachteile, siehe Abschnitt 2.2.3. Der Ansatz dieser Arbeit, um diese Probleme zu adressieren, wird im folgenden Abschnitt beschrieben. Das entwickelte System und seine Architektur sowie dessen Implementierung und Evaluierung werden ebenfalls im Folgenden beschrieben. Eine Diskussion und ein Fazit schließen dieses Kapitel ab.

4.3.1. Methoden

Wie schon bei der Entwicklung von DNDv2 und aDNDv2 wurden die Bedarfe der Zielgruppe im Austausch zwischen Expert:innen aus den verschiedenen Fachgebieten ermittelt und diskutiert. Darüber hinaus konnte aus den Ergebnissen der vorangegangenen Studien die Anforderung abgeleitet werden, dass ein System zur automatischen Erfassung der Stuhlform möglichst ambient sein sollte. Da zum Zeitpunkt der Entwicklung des Systems keine direkt vergleichbaren Arbeiten vorlagen, wurde zunächst die Ist-Situation erfasst, siehe Abschnitt 2.2.3.

Die Fotomethode ist bisher die für Patient:innen einfachste Methode, da Digitalkameras durch ihre Integration in mobilen Endgeräten eine hohe Verfügbarkeit bei gleichzeitig hoher Qualität aufweisen, siehe Abschnitt 2.2.3.1 und Abschnitt 3.1.1. Insbesondere aufgrund der Objektivität der Fotomethode wurde diese als Ausgangspunkt für die Entwicklung eines ambienten und automatisierten Systems zur Erfassung der Stuhlform verwendet. Als Skala zur Beurteilung der Stuhlform wurde die Bristol Stool Form Scale (BSFS) verwendet, da diese in der Praxis weit verbreitet ist und sich sowohl zur Erfassung von chronischer Diarrhö als auch von chronischer Obstipation eignet, siehe Abschnitt 2.2.3. Obwohl die Fotomethode und die BSFS als etablierte Methoden zur Erfassung der Stuhlform gelten, ist insbesondere die Fotomethode mit einigen Problemen behaftet:

Aufbau der Toilette: Aufgrund der physikalischen Konstruktion von sogenannten Tiefspülern wird häufig ein Teil des Stuhls bereits während der Defäkation in einen nicht mehr einsehbaren Bereich der Toilette verschoben. Dies hat zur Folge, dass eine spätere Fotografie den Stuhl nicht mehr vollständig erfassen kann und die Erfassung ungenau wird. Insbesondere die Menge lässt sich so nicht mehr rekonstruieren.

Verdeckung: Neben der Toilettenkonstruktion können auch Hygieneprodukte (Toilettenpapier) dazu führen, dass die Fäzes nicht mehr vollständig mit der Fotomethode erfasst werden können. Vor allem bei Diarrhö wird häufig vor der Protokollierung Toilettenpapier verwendet, welches dann die Fäzes verdecken kann.

Weiterhin hat sich aus den Interviews mit den Expert:innen ergeben, dass ein System möglichst einfach in der Nutzung sowie in der Installation sein sollte.

Zudem sollte das System portabel sein, um möglichst flexibel eingesetzt werden zu können und eine Nutzung über den stationären Aufenthalt hinaus, also auch in der Häuslichkeit, zu ermöglichen. Gleichzeitig sollten auch ökonomische Faktoren berücksichtigt werden, um zu vermeiden, dass zu hohe Kosten einen praktischen Einsatz verhindern.

Basierend auf den oben genannten Anforderungen wurden zwei aufeinander aufbauende Prototypen entwickelt. In einem ersten horizontalen Prototypen wurde untersucht, ob die Erfassung der Stuhlform mithilfe einer KI-basierten Methode generell automatisierbar ist, sodass auf eine manuelle Protokollierung verzichtet werden kann. Dabei stand insbesondere die Umsetzbarkeit der Designentscheidung im Vordergrund, die Fäzes nicht wie bei der herkömmlichen Fotomethode von oben, sondern mithilfe einer (3D-)Kamera von der Seite zu erfassen. Dieser Ansatz, die Fäzes im freien Fall direkt nach der Defäkation zu erfassen, hat den Vorteil, dass diese weder durch die physikalische Konstruktion der Toilette noch durch Hygieneartikel beeinflusst werden. Zunächst wurden drei der sieben möglichen Stuhlformen abgedeckt [195].

Der zweite Prototyp ist eine konsequente Weiterentwicklung des ersten Prototypen. Mit ihm wurde untersucht, ob das System auf alle sieben Klassen der BSFS erweiterbar ist. Weiterhin wurde ermittelt, inwieweit sich das System in eine herkömmliche Toilettensitzerhöhung integrieren lässt, da derartige Toilettensitzerhöhungen für die Zielgruppe dieser Arbeit entwickelt werden. Zudem erfüllt ein in einer Toilettensitzerhöhung integriertes System die Portabilitätsanforderungen. Zusätzlich wurde in einer Evaluationsstudie unter Laborbedingungen untersucht, wie die automatische Klassifikation von alternativen Kamerasystemen und Algorithmen profitieren kann. Die im Folgenden dargestellten Inhalte und Ergebnisse basieren in weiten Teilen auf den Arbeiten [196, 195], wurden jedoch an verschiedenen Stellen überarbeitet und ergänzt.

4.3.1.1. Sitzerrhöhung

Die für den zweiten Prototyp ausgewählte Sitzerrhöhung hat eine Höhe von 10 cm und bietet damit ausreichend Raum für die Integration der notwendigen Komponenten, siehe Abbildung 4.26. Zwar existieren auch Sitzerrhöhungen mit einem

höherem Aufbau, diese können jedoch bei kleineren Personen zu ergonomischen Problemen führen.



(a) 3D-Modell



(b) Prototyp

Abbildung 4.26.: 3D-Modell der Sitzerrhöhung zur Planung der Integration der verschiedenen Komponenten (Kameras, Licht, Mini-Computer) sowie der resultierende Prototyp, in Anlehnung an [196].

4.3.1.2. Kameras

Für die Aufnahme der Fäzes, bzw. der Stuhlformen, wurden zwei unterschiedliche Kamerateams eingesetzt. Die Intel® RealSense™ Kamera D435 (RealSense D435), welche auch im ersten Prototypen verwendet wurde, und ein eigens für den Anwendungsfall aufgebautes Stereoskopie-Setup. Dieses Stereoskopie-Setup wurde mit zwei GoPro HERO10 Black (HERO10 Black) aufgebaut, siehe Abbildung 4.27.

Die Vorteile der RealSense D435 sind, neben der zugehörigen Software zur umfangreichen Konfiguration, der Global Shutter und die integrierte IR-Lichtquelle (aktive Stereoskopie). Der Mindestabstand der Kamera bei einer Auflösung von 848 x 480 px beträgt 19,5 cm und ist damit für den Einsatz im Nahbereich nicht



(a) Intel® RealSense™ Kamera D435 im Plexiglasgehäuse

(b) Zwei HERO10 Black im Plexiglasgehäuse

Abbildung 4.27.: Kamerasetups mit Gehäuse für das Einsetzen in die Toilettensitzerhöhung. Die HERO10 Black Kameras wurden dabei spiegelverkehrt nebeneinander positioniert, um einen möglichst geringen Mindestabstand zu erreichen, in Anlehnung an [196].

optimal.² Des Weiteren verfügt die RealSense D435 über keine IP-Schutzklasse, sodass für den Einsatz in diesem Anwendungsszenario weitere Maßnahmen erforderlich sind, siehe Abbildung 4.27a. Die HERO10 Black Kameras gehören zur Klasse der Action-Kameras und verfügen über eine für das Anwendungsszenario ausreichende IP-Schutzklasse und sind wasserdicht bis 10 m. Entsprechend konnte eine Aussparung im Gehäuse geschaffen werden, um die beiden Kameras in der richtigen Position zu fixieren, siehe Abbildung 4.27b. Zudem verfügen die HERO10 Black Kameras über eine höhere Auflösung und Bildrate sowie eine integrierte Bildstabilisierung, z. B. zum Ausgleich möglicher Erschütterungen während der Defäkation, siehe Tabelle 4.6.

4.3.1.3. Beleuchtung

Aufgrund einer fehlenden integrierten Lichtquelle der verwendeten HERO10 Black Kameras, wurde eine zusätzliche Lichtquelle benötigt, um ein möglichst realistisches Szenario zu schaffen. Die eigens für die Evaluationsstudie angefertigten

²<https://www.intel.com/content/dam/support/us/en/documents/emerging-technologies/intel-realsense-technology/Intel-RealSense-D400-Series-Datasheet.pdf>, letzter Zugriff: 21.10.2023

Tabelle 4.6.: Übersicht über die Konfiguration der eingesetzten Kameras.

Intel RealSense D435				HERO10 Black
<i>Stereo-Sensor</i>		<i>Farbsensor</i>		<i>Farbsensor</i>
Preset	Default	Preset	Default	-
Auflösung [px]	848 × 480	Auflösung [px]	960 × 540	1920 × 1080
Bildrate [fps]	60	Bildrate [fps]	60	240
Tiefenauflösung	Z16	Farbtiefe	RGB8	RGB8
Laser Power	Max	-	-	-
Auto Exposure	Enabled	Auto Exposure	Enabled	-
Depth Units [m]	0.001	-	-	-
Emitter	Enabled	-	-	-
Infrarot 1 & 2	Enabled	-	-	-

synthetischen Testkörper wurden zwar auf Höhe der Oberkante der Sitzhöhe fallen gelassen, sodass noch Licht einfällt, dies wäre jedoch unter realen Bedingungen nicht der Fall. Die Beleuchtung ermöglicht zudem die zeitliche Synchronisation der Aufnahmen der beiden Action-Kameras.

4.3.1.4. Steuerung

In die Toilettensitzhöhe wurde neben dem jeweiligen Kamerasetup und der Beleuchtung auch ein Mini-Computer integriert (Raspberry Pi 3 Model B, Prozessor: ARM-Cortex-A53 4 × 1,2 GHz, Arbeitsspeicher: 1 GB). Dieser übernimmt die Steuerung der integrierten Beleuchtung. Die Steuerung der Kameraeinstellungen erfolgt über zwei weitere (externe) Rechner. Während für die Steuerung der RealSense D435 ein Computer ausreicht, sind für die Steuerung der HERO10 Black Kameras zwei Computer erforderlich, da diese drahtlos (über WLAN) direkt mit den Kameras verbunden werden müssen. Mehrfachverbindungen mit einem Computer sind seitens GoPro nicht vorgesehen und erfordern daher jeweils einen eigenen Rechner.

4.3.2. Implementation

Die Architektur des hier beschriebenen Systems basiert grundlegend auf der Architektur des ersten Prototypen [195], welche durch den zweiten Prototypen [196] erweitert wurde. Neben der zusätzlichen Anbindung der HERO10 Black Kamera wurde auch der Algorithmus zur Hintergrundentfernung geändert, siehe Abbildung 4.28. Hier wird der Mixture of Gaussians 2 (MoG2)-Algorithmus verwendet. Dieser Algorithmus basiert auf einem Modell der Szene, das auf der Verteilung der Pixel basiert. Weicht ein Pixel von dieser Verteilung ab, so gehört dieses Pixel mit einer Wahrscheinlichkeit, die der Abweichung entspricht, nicht zum Hintergrund. Darüber hinaus ist der Algorithmus dynamisch und passt sein eigenes Modell kontinuierlich an, sodass er robust gegenüber sich ändernden Szenen ist, z. B. durch wechselnde Lichtverhältnisse. Damit erreicht der MoG2-Algorithmus eine zuverlässige Unterscheidung zwischen bewegten Objekten und dem Hintergrund einer zu erfassenden Szene [197, 198], siehe Abbildung 4.29.

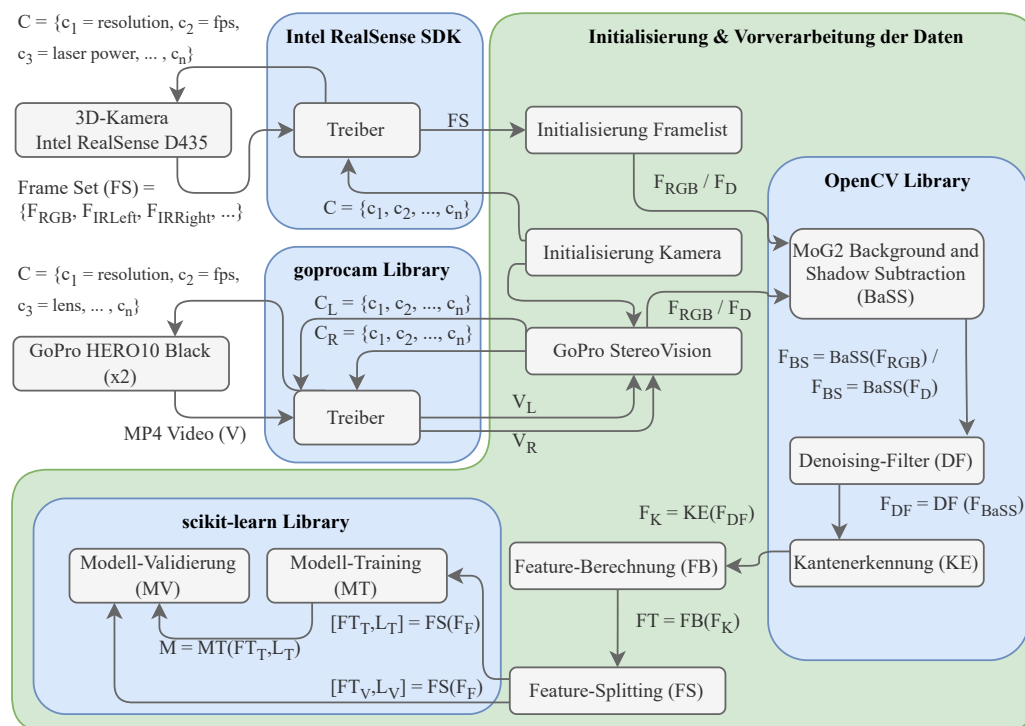


Abbildung 4.28.: Aufbau des Gesamtsystems zur Aufzeichnung und Klassifikation von Stuhlformen, in Anlehnung an [196, 195].




Abbildung 4.29.: Anwendung des MoG2-Algorithmus auf eine Aufnahme fallender Fäzes, um den Hintergrund inkl. Schatten zu entfernen, aufgenommen mit einer HERO₁₀ Black Kamera, in Anlehnung an [196]. Sowohl die Tiefenkarte als auch die maskierte Tiefenkarte wurden zur besseren Sichtbarkeit der Objekte nachbearbeitet (invertiert).

Weiterhin wurde das StereoVision-Modul ergänzt. Dieses Modul erzeugt Tiefenbilder aus den Aufnahmen der beiden HERO₁₀ Black Kameras. Zuvor muss jedoch das entsprechende Setup mithilfe eines Schachbrettmusters kalibriert werden. Durch die zeitgleiche Aufnahme des Musters mit dem HERO₁₀ Black Stereo-Setup, können die für die Tiefenberechnung notwendigen Parameter berechnet werden, z. B. Brennweite, Verzerrung, Rotation und Translation. Diese Daten können dann vom System verwendet werden, solange sich die Position der Kameras zueinander nicht ändert.

Zur Berechnung der Tiefenkarte für zwei korrespondierende Aufnahmen ist es außerdem erforderlich die Aufnahmen, bzw. die extrahierten Bilder, zeitlich zu synchronisieren. Dazu wird die über den Mini-Computer gesteuerte LED-Beleuchtung, die in der Toilettensitzerhöhung integriert ist, erst nach Beginn der Aufnahmen eingeschaltet, sodass die Aufnahmen über den Zeitpunkt des Beleuchtungswechsels synchronisiert werden können. Für die auf den Tiefenkarten beruhenden Features ist es notwendig, dass das Objekt auch innerhalb der Tiefenkarte segmentiert wird. Hierzu kann jedoch der MoG₂-Algorithmus zur Entfernung des Hintergrundes nicht direkt eingesetzt werden, da dieser nicht für Tiefenkarten geeignet ist. Deshalb wurde eine entsprechende Koordinatentransformation auf den Tiefenkarten durchgeführt, um auch hier die Maske aus den RGB-Daten verwenden zu können. Durch diese Herangehensweise kann die robuste MoG₂-Hintergrunderkennung indirekt auf die Tiefenkarten angewendet werden, siehe Abbildung 4.29.

4.3.2.1. KI-Konzeption

Für die automatische Klassifikation der Fäzes, anhand der sieben Klassen der BSFS, wurde sowohl ein Algorithmus aus dem Bereich des maschinellen Lernens als auch ein Algorithmus aus dem Bereich der künstlichen neuronalen Netze eingesetzt. Speziell im Bereich der Objekterkennung weisen aktuelle Künstliche Neuronale Netzwerke (KNNs), insbesondere die Convolutional Neural Networks (CNNs), eine hohe Genauigkeit auf. Ein Nachteil von auf KNNs basierenden Algorithmen ist, dass die für die Klassifikation entscheidenden Features nicht direkt bekannt sind. Diese werden vom Netz durch das Training gelernt, siehe Abschnitt 3.2.2.2. Bei Verfahren aus dem Bereich des maschinellen Lernens, wie den CNNs, ist häufig ein vorgelagertes Features-Engineering notwendig, um diese sowohl für das Training

als auch für die Klassifikation zu definieren, siehe Abschnitt 3.2.2. Dementsprechend sind die entscheidenden Features für jede Klassifikation bekannt. Für die Erkennung der Stuhlformen wurde die CNN-Architektur AlexNet eingesetzt sowie die Support Vector Machine (SVM)-Architektur One-vs-One, siehe Abschnitt 3.2.2.4 und 3.2.2.1.

Klassen und Datensatz: Sowohl für CNNs als auch für SVMs gilt, dass diese trainiert werden müssen, um die Modelle für die Klassifikation zu erzeugen. Der dafür notwendige Datensatz muss alle sieben Klassen der BSFS abdecken. Da die Fäzes im beschriebenen Aufbau von der Seite aufgenommen werden, muss das System auch in der Lage sein, die Stuhlformen von der Seite zu klassifizieren. Dementsprechend müssen die Modelle auch mit einem Datensatz trainiert werden, der aus Bildern von der Seite besteht. Da solche Datensätze nicht zur Verfügung standen, wurde mithilfe des Prototypen und Modellen aus herkömmlicher Knetmasse und Pudding ein synthetischer Datensatz erstellt, siehe Abbildung 4.30. Weiterhin wurde der in Abbildung 4.30 beschriebene Ablauf zur Erstellung des Datensatz jeweils einmal pro Kamerasystem erstellt, um beide Kamerasysteme miteinander vergleichen zu können.

Wie in Abschnitt 2.2.3 beschrieben, kann neben der Konsistenz, welche durch die Zugabe von Wasser verändert wurde, auch die Farbe Hinweise auf vorliegende Erkrankungen oder Unverträglichkeiten liefern. Daher wurde der Datensatz mit unterschiedlich gefärbten Knetmassen erzeugt, um diesen über diese Arbeit hinaus für weitere Experimente einsetzen zu können, siehe Abbildung 4.31. Verschiedene Experimente haben gezeigt, dass Knetmasse eine hygienische, flexible und realistische Herstellung von Proben für die BSFS-Klassen 1 bis 6 erlaubt. Insbesondere die Abrisskanten an weicherem Stuhl lassen sich mit Knetmasse realistisch herstellen. Der Grad der Ausfransungen an den Abrisskanten kann dabei durch die Geschwindigkeit, mit der größere Klumpen auseinander gezogen werden, variiert werden. Sehr feine Abrisskanten lassen sich durch das Austrocknen einer vorher geformten Stuhlform erreichen, welche nach der Trocknung auseinander gezogen wird.

Vorverarbeitung der Daten: Neben der Erstellung der Aufnahmen von den verschiedenen Modellen der Stuhlformen und der Berechnung der korrespondierenden Tiefenkarten, sind verschiedene Vorverarbeitungsschritte notwendig, um das

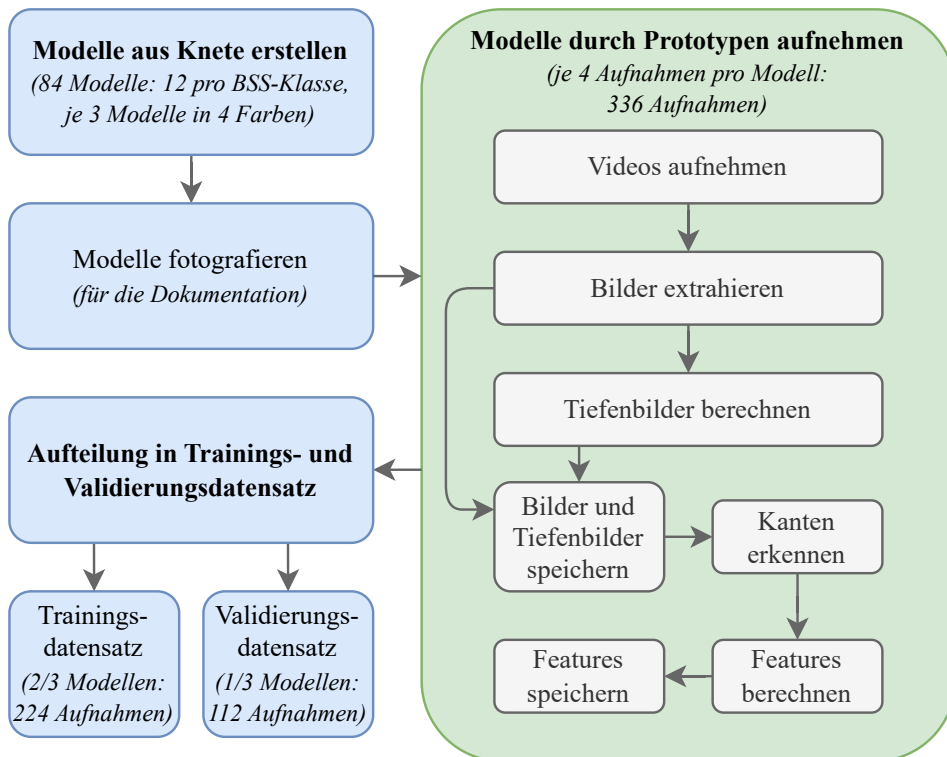


Abbildung 4.30.: Notwendige Schritte zur Erzeugung des Datensatzes sowie notwendige Schritte zur Vorverarbeitung der Daten für das Training der CNNs und SVMs. Dabei ist anzumerken, dass multiple Aufnahmen mit einem Prüfkörper nur näherungsweise gleichen Bedingungen unterliegen, da dieser durch das Aufschlagen auf einen harten Untergrund nach jeder Aufnahme verformt wird.




Abbildung 4.31.: Beispiele verschiedener BSFS-Klassen in verschiedenen Farben, welche für die Erstellung beider Trainingsdatensätze verwendet wurden, in Anlehnung an [196].

CNN oder die SVM trainieren zu können. Da sowohl die Extraktion von Features für das Training der SVM als auch das Training der CNN auf Einzelbildern basiert, müssen diese Frames zunächst aus den Aufnahmen des Datensatzes extrahiert werden. Dabei ist darauf zu achten, dass nur Frames für das Training verwendet werden, auf denen auch Fäzes abgebildet sind. Weiterhin sollten die Fäzes vollständig abgebildet sein, um ein Training mit unvollständigen Objekten zu vermeiden. Zu diesem Zweck wurde folgende Definition für gültige Frames festgelegt:

- Es muss sich ein Objekt im Vordergrund der Szene befinden.
- Das Objekt darf nicht einseitig, also nur oben oder nur unten, aus dem Bild ragen.

Ob sich ein Objekt in einer Szene befindet oder nicht, kann über die inverse Maske der Hintergrunderkennung entschieden werden, siehe Abbildung 4.29. Dass dieses Objekt nicht einseitig aus dem Bild ragt, kann mithilfe einer ROI überprüft werden. Damit werden Fäzes, die ins Bild eintreten und Fäzes, die den Bildbereich verlassen, ignoriert. Eine Ausnahme wurde für die BSFS-Klasse 7 festgelegt. Hier werden Frames auch dann als valide betrachtet, wenn das Objekt gleichzeitig den Bildbereich an der oberen und unteren Kante berührt. Da dies bei Diarrhö häufig der Fall ist, würde es sonst eine zu geringere Anzahl an validen Frames für das Training geben. Die auf Basis dieser Regeln extrahierten Frames wurden sowohl für die Extraktion der Features für das Training der SVMs verwendet als auch für das Training der CNNs, siehe Tabelle 4.7. Dabei ist zu beachten, dass die Zahlen sowohl für RGB als auch für RGB-D basierte Klassifikationen gelten, da auch die Tiefenkarten durch die RGB-Maske segmentiert werden, da der MoG2-Algorithmus aufgrund seiner Arbeitsweise nicht ohne Anpassungen sinnvoll auf RGB-D, bzw. Tiefenkarten, angewendet werden kann.

Tabelle 4.7.: Übersicht über die Verteilung der extrahierten Bilder aus dem Datensatz der Aufnahmen der RealSense D435 und der HERO10 Black über die sieben Stuhlklassen der BSFS.

Kameras / BSFS-Klassen	1	2	3	4	5	6	7	Summe
RealSense D435	130	66	60	72	129	256	5515	6228
HERO10 Black	2457	958	987	988	4257	3529	45089	58265

Für die CNNs wurden die Aufnahmen auf eine quadratische Auflösungen skaliert (224 px×224 px). Insbesondere für die SVMs war es notwendig, signifikante Eigenschaften der sieben Stuhlformen der BSFS auf Features abzubilden, die mithilfe einer Vorverarbeitungskette aus den Bildern extrahiert wurden. Dazu wurde das mit dem MoG2-Algorithmus vorher segmentierte Bild verwendet, siehe Abbildung 4.32. In dieser Abbildung ist auch der signifikante Unterschied zwischen den Aufnahmen der Intel RealSense D435 und der GoPro HERO10 Black zu erkennen. Dies begründet auch die sich ebenfalls signifikant unterscheidenden Zahlen von validen Frames, siehe Tabelle 4.7.




Abbildung 4.32.: Vergleich der Aufnahmen der RealSense D435 und der HERO10 Black.

4.3.3. Ergebnisse

Übergeordnetes Ziel der im Folgenden beschriebenen Evaluierung des Systems war es, herauszufinden, welche Komponenten (Hardware und Software) in welcher Kombination für den hier beschriebenen Anwendungsfall am besten geeignet

sind, siehe Tabelle 4.8. Hierzu wurde untersucht, mit welcher Genauigkeit die Klassifikation von sieben Stuhlformen möglich ist.

Tabelle 4.8.: Übersicht über die verschiedenen Hardware- und Softwarekomponenten, die miteinander verglichen wurden.

	Kamera(s)	SVM basierte Klassifikation	CNN basierte Bildererkennung
2D	RealSense D435	One-vs-One	AlexNet
	HERO ₁₀ Black	One-vs-One	AlexNet
3D	RealSense D435	One-vs-One	AlexNet
	2x HERO ₁₀ Black	One-vs-One	AlexNet

Erzeugung der Modelle: Durch die geringe Anzahl von Features konnte der One-vs-One-Algorithmus auf einem herkömmlichen Computer trainiert werden. Das Training des AlexNet-Algorithmus ist ebenfalls auf herkömmlichen Computern möglich, kann jedoch schon bei diesen geringen Datenmengen, im Vergleich zu *Big-Data*, auf aktuellen CPUs Tage in Anspruch nehmen. Es empfiehlt sich daher, Computer mit Grafikkarten zu verwenden, welche für die Unterstützung von KI-Berechnungen ausgelegt sind. Idealerweise werden hier speziell für das Training derartiger KI-Algorithmen konzipierte KI-Server eingesetzt, wie *NVIDIA DGX-1-Server: 8×TeslaV100 32 GB GPU*.

Für die auf den SVMs basierenden Verfahren gibt es ebenfalls Herausforderungen. Wie in Abschnitt 3.2.2.1 angeführt, gibt es verschiedene Hyperparameter für die Konfiguration einer SVM. Diese Parameter können einander beeinflussen und zu neuen Parametern führen. So ist die Anzahl der Parameter z. B. abhängig vom gewählten Kernel. Aus diesem Grund wurde für diese Arbeit eine heuristische Hyperparameter-Optimierung mittels GridSearchCV [199] durchgeführt, um die optimalen Parameter für die im Folgenden angeführten One-vs-One SVM-Modell zu erzeugen.

4.3.3.1. Klassifikation: RGB-Daten

SVM – One-vs-One: Wie schon in Abschnitt 4.3.2 angeführt, ist die Extraktion von Features notwendig, um einen Eingangsvektor für eine zu trainierende SVM zu erhalten. Es hat sich gezeigt, dass die folgenden Features für die Klassifikation von drei der sieben BSFS-Klassen eine gute Separierbarkeit aufweisen [193]. Daher wurden diese auch hier als Eingangsvektoren verwendet:

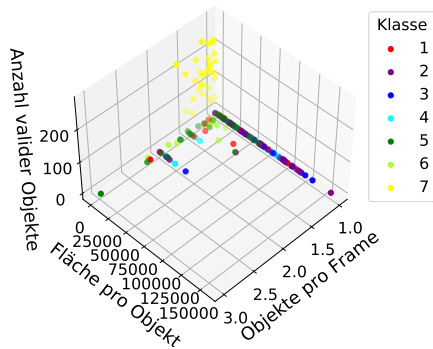
- Die durchschnittliche Anzahl von Objekten,
- die gesamte Anzahl von Objekten und
- die durchschnittliche Größe der Objekte.

Wie bereits angeführt, wurde eine heuristische Hyperparameter-Optimierung mittels GridSearchCV durchgeführt. Als optimale Parameter hat dieses Verfahren dabei ergeben, dass ein Radial Basis Function (RBF)-Kernel mit einer Soft-Margin von $C = 1.1$ und einem Gamma-Wert von $\gamma = 0.3$ zu möglichst optimalen Ergebnissen für die gewählten Daten führt. Diese Werte wurden dabei für den RealSense D435 und für den HERO₁₀ Black Datensatz als optimal angegeben. Der Verlauf des Trainings, der Validierung sowie die Konfusionsmatrix können Abbildung 4.33 entnommen werden.


CNN – AlexNet: Für das Training des CNN-Modells auf Basis der AlexNet-Architektur wäre es aus Sicht der Architektur nicht notwendig gewesen, die Objekte vorher zu segmentieren. Verschiedene Experimente haben gezeigt, dass es für den Algorithmus einfacher ist ein Modell des Datensatzes zu erzeugen, wenn nicht relevante Teile vor dem Training entfernt werden. Aus diesem Grund wurden auch die CNN-Modelle mit den maskierten Daten, also mit aktiver MoG2-Hintergrunderkennung, trainiert, siehe Abbildung 4.34.

4.3.3.2. Klassifikation: RGB-D-Daten


Wie bereits in Tabelle 4.8 angegeben, wurde neben der GoPro HERO₁₀ Black auch die Intel RealSense D435 eingesetzt, um Informationen über die räumliche Tiefe zu erheben. Obwohl der minimale Arbeitsabstand der RealSense D435 für diesen Anwendungsfall zu klein ist, wurde diese Kamera dennoch eingesetzt, um die




(a) Verteilung der drei Features basierend auf den Intel RGB-Daten.



(b) Konfusionsmatrix für das SVM-Modell über die sieben BSFS-Klassen.




(c) Verteilung der drei Features basierend auf RGB-Daten.




(d) Konfusionsmatrix für das SVM-Modell über die sieben BSFS-Klassen.


Abbildung 4.33.: Ergebnisse & Features des One-vs-One-Modells auf Basis der RGB-Daten. Die Klassifizierungsgenauigkeit auf dem Validierungsdatensatz beträgt für die RealSense D435 Daten 30,36% und für die HERO10 Black Daten 61,68%.




(a) Training von AlexNet über 50 Epochen mit RealSense D435 RGB-Daten.



(b) Konfusionsmatrix für das AlexNet-Modell über die sieben BSFS-Klassen.



(c) Training von AlexNet über 50 Epochen mit HERO10 Black RGB-Daten.



(d) Konfusionsmatrix für das AlexNet-Modell über die sieben BSFS-Klassen.

Abbildung 4.34.: Ergebnisse & Training für des AlexNet-Modells auf Basis der RGB-Daten. Die Klassifizierungsgenauigkeit auf dem Validierungsdatensatz beträgt für die RealSense D435 Daten 28,57% und für die HERO10 Black Daten 93,46%.

Ergebnisse dieser Arbeit mit den Ergebnissen der Vorarbeiten [195] vergleichen zu können. Aufgrund der Funktionsweise des stereoskopischen Prinzips sowie des Aufbaus von Tiefenkarten und der Definition von ungültigen Pixeln als Pixel ohne Informationen, wurde angenommen, dass die nicht erkannten Bereiche in der Tiefenkarte als weiße Pixel eine zusammenhängende Struktur ergeben, die als Maske verwendet werden kann, siehe Abbildung 4.35.

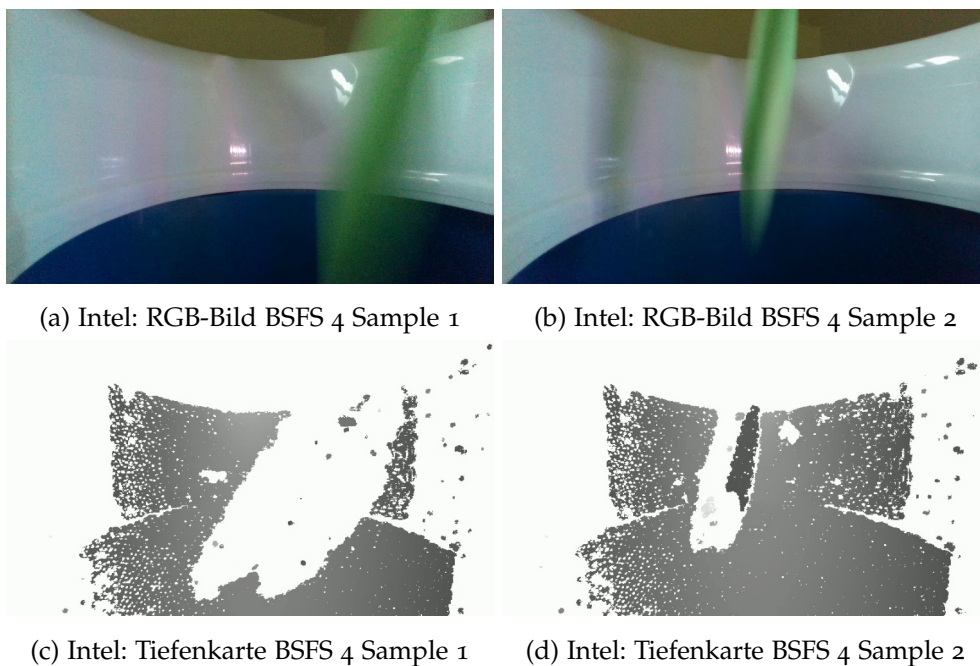


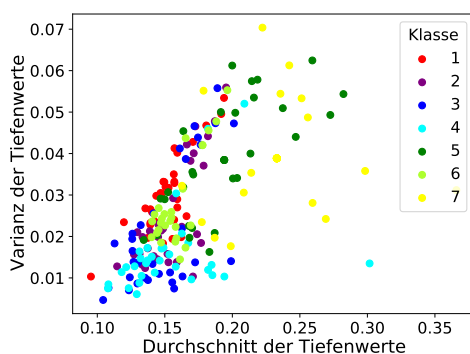
Abbildung 4.35.: Beispiele zweier Tiefenkarten aus der Datenbank der Intel RealSense D435 Aufnahmen.

Abbildung 4.35 zeigt aber auch, dass die Objekte über die Toilettensitzerhöhung hinausragen und somit nicht vom Hintergrund unterschieden werden können. Außerdem führt die Verdeckung des Hintergrundes durch die Testkörper innerhalb des Arbeitsabstandes zu großen Schatten in der Tiefenkarte. Zusammen mit der geringeren Auflösung und Bildrate der Intel RealSense D435 hat sich gezeigt, dass diese Daten für den hier beschriebenen Anwendungsfall ungeeignet sind. Folglich beziehen sich die folgenden Ergebnisse nur auf die Daten, die mit dem GoPro-Stereo-Setup erhoben wurden.


SVM – One-vs-One: Zusätzlich zu den Merkmalen, die für das Training des SVM-Modells auf Basis der RGB-Daten verwendet wurden, wurden zwei weitere Merkmale für die RGB-D-Daten definiert, sodass sich insgesamt ein fünfdimensionaler Merkmalsvektor ergibt:

- Die durchschnittliche Anzahl von Objekten,
- die gesamte Anzahl von Objekten,
- die durchschnittliche Größe der Objekte,
- die durchschnittliche Tiefe der Objekte und
- die Varianz der Tiefe der Objekte.

Wie beim Training auf RGB-Datenbasis wurde auch hier eine Hyperparameter-Optimierung mittels GridSearchCV durchgeführt. Als optimale Parameter hat dieser Algorithmus erneut, wie auch bei den RGB-Daten, ein RBF-Kernel ausgegeben, mit einer Soft-Margin von $C = 1.1$ und einem Gamma-Wert von $\gamma = 0.3$. Mit diesen Parametern wurde auf dem Validierungsdatensatz eine Klassifizierungsgenauigkeit von 69,16 % erreicht, siehe Abbildung 4.36.




(a) Verteilung der zwei neuen Features basierend auf RGB-D-Daten.



(b) Konfusionsmatrix für das SVM-Modell über die sieben BSFS-Klassen

Abbildung 4.36.: Ergebnisse & Features des One-vs-One SVM-Modells auf Basis der RGB-D-Daten. Die Klassifizierungsgenauigkeit auf dem Validierungsdatensatz beträgt für die HERO₁₀ Black Daten 69,19 %.

CNN – AlexNet: Wie auch bei dem Training des Modells für die RGB-Daten, wurden für die RGB-D-Daten die segmentierten Bilder verwendet. Hierzu wurde die Architektur von AlexNet angepasst, sodass dieses neben den Farbinformationen auch die Tiefeninformationen verarbeiten kann. Die Ergebnisse können Abbildung 4.37 entnommen werden.



(a) Verlauf des Trainings von AlexNet über 50 Epochen.

(b) Konfusionsmatrix des AlexNet SVM-Modells.

Abbildung 4.37.: Ergebnisse & Training des AlexNet CNN-Modells auf Basis der RGB-D-Daten. Die Klassifizierungsgenauigkeit auf dem Validierungsdatensatz beträgt für die HERO₁₀ Black Daten 86,92 %.

4.3.4. Diskussion und Fazit

In diesem Abschnitt wurde ein System beschrieben, welches die KI-basierte Klassifikation von Fäzes ermöglicht, da diese eine wichtige Informationsquelle im Kontext der Ernährungsberatung darstellen. Insbesondere die Form und Struktur der Fäzes, die Stuhlform, liefert Informationen über die Qualität der Verdauung. Daher wurden die Fäzes für die Klassifikation, basierend auf der BSFS, in sieben Klassen von Stuhlformen unterteilt, siehe Abschnitt 2.2.3. Die Erfassung der Fäzes erfolgt dabei über Kameras, welche die Fäzes direkt nach der Defäkation im freien Fall aufzeichnen. Hierzu wurde das Kamerasystem orthogonal zur Fallrichtung der Fäzes in eine herkömmliche Toilettensitzerhöhung integriert. Dabei wurden zwei unterschiedliche Kamerasysteme eingesetzt, um diese auf ihre Performanz in diesem Anwendungsfall zu untersuchen. Weiterhin wurde eine zusätzliche Lichtquelle zur Beleuchtung der Szene in die Toilettensitzerhöhung integriert, um die

Bedingungen während der Aufnahmen zu verbessern. Ein ebenfalls integrierter Mini-Computer wurde für die Steuerung der Komponenten eingesetzt.

Ziel der unter Laborbedingungen und mit künstlichen Prüfkörpern durchgeführten Evaluationsstudie war es, festzustellen, ob und mit welcher Sicherheit es generell möglich ist Stuhlformen mit dem beschriebenen Ansatz zu erfassen und zu klassifizieren. Dabei wurden sowohl 2D (RGB) als auch 3D (RGB-D) Daten sowie verschiedene Algorithmen aus den Bereichen Bildverarbeitung und KI eingesetzt.

Die Ergebnisse zeigen bezüglich der Hardware, dass das eigens für diesen Anwendungsfall aufgebaute Setup, bestehend aus zwei GoPro HERO10 Black, die besten Ergebnisse liefert. Hier liegen die Ergebnisse für den SVM-basierten Ansatz bei einer Genauigkeit von 61,68 % für die RGB-Daten und bei 69,16 % für die RGB-D-Daten. Für den CNN-basierten Ansatz liegt die Genauigkeit bei 93,46 % für die RGB-Daten und bei 86,92 % für die RGB-D-Daten. Die Intel RealSense D434 konnte, aufgrund des zu großen minimalen Arbeitsabstandes, nur für die RGB-Daten sinnvoll ausgewertet werden. Hier liegen die Ergebnisse für den SVM-basierten Ansatz bei einer Genauigkeit von 30,36 % und für den CNN-basierten Ansatz bei 28,57 %.

Die angestrebte Portabilität des Systems konnte mit der RealSense D345 als Kamera erreicht werden, da diese über den Mini-Computer mit Strom versorgt werden kann, welche ebenfalls die Beleuchtung versorgt. Der Mini-Computer selber kann über eine externe Stromquelle oder eine Batterie (z. B. 12V Powerbank) versorgt werden. Die Portabilität des Systems wird eingeschränkt, sobald die HERO10 Black Kameras eingesetzt werden sollen, da diese zwar über eine eingebaute Energiequelle verfügen, diese aber nicht für einen Dauerbetrieb (über mehrere Tage) ausgelegt ist. Eine Aufnahme während des Ladevorgangs ist nicht vorgesehen, sodass diese Option entfällt. Entsprechend werden Daten entweder auf einer Speicherkarte gesichert oder drahtlos übertragen. Die drahtlose Übertragung benötigt aufgrund der Datenmenge eine WLAN-Verbindung pro Gerät, sodass hier zwei Mini-Computer erforderlich sind. Diese Mini-Computer können perspektivisch auch in die Sitzerrhöhung integriert werden, da hier noch genügend Platz vorhanden ist. Eine Umrüstung der HERO10 Black Kameras für den Dauerbetrieb ist durch den direkten Anschluss einer Stromquelle an die Batteriekontakte ebenfalls möglich, allerdings würde dann die IP-Schutzklasse erlöschen, da eine entsprechende Durchführung durch das Gehäuse der Kameras notwendig wäre.

Auf die initiale Fragestellung „Mit welchen technischen Mitteln kann eine automatisierte Klassifizierung von Stuhlformen erreicht werden, um die manuelle Bildaufnahme und die verbale Beschreibung zu ersetzen?“ , ist die hier beschriebene Herangehensweise eine mögliche Antwort. Die Relevanz dieses Forschungsgebietes wird unterstrichen durch aktuelle und umfangreiche Arbeiten wie die von Park et. al. [180], die ebenfalls an einem portablen System zur Untersuchung und Klassifikation menschlicher Ausscheidungen arbeiten. Hier basiert die Klassifikation der Stuhlformen auf Aufnahmen der Fäzes von oben und bringt damit die eingangs in diesen Kapitel beschriebenen Nachteile dieser Herangehensweise mit sich.

Das größte Optimierungspotenzial des Systems liegt in der Qualität und Quantität des Datensatzes für das Training der verschiedenen KI-Modelle. Eine weitere Vergrößerung des künstlich erzeugten Datensatzes wird hier jedoch voraussichtlich nur noch ein geringes Potenzial aufweisen bzw. einen deutlich höheren Aufwand bei der Generierung von realistischeren Testkörpern erfordern. Die Visualisierung der Merkmale für die SVM-basierte Klassifikation zeigt, dass die Feature-Cluster ineinander übergehen. Dies ist zu erwarten, da die sieben Klassen der BSFS eine Diskretisierung eines kontinuierlichen Problems darstellen. Diese Verteilung zeigt jedoch auch, dass der Merkmalsraum ausreichend gut abgedeckt ist, obwohl er auf einem synthetischen Datensatz basiert, der aus Knete, Pudding und Wasser erzeugt wurde. Es wäre daher sinnvoll, das System zur Erhebung realer Daten zu verwenden. Basierend auf realen Daten könnten spezifischere Merkmale (z. B. Textur, Farbe, Volumen) gesammelt werden, um weitere Analysen und genauere Klassifizierungen zu ermöglichen. Mithilfe des Volumens und einer Zusammenfassung der sieben Klassen der BSFS auf vier Klassen wäre es auch möglich, die Fäzes nach der Kings Stool Scale (KSS) zu klassifizieren.

Speziell für die Erfassung von Texturen und spezifischeren Details, wie unverdaute Bestandteile oder Farbe, sollte auch die Beleuchtung derart verändert werden, dass die Szene von allen Seiten mit diffusem Licht ausgeleuchtet wird, damit diese Details von den Kameras besser erfasst werden können. Auch das Setup dieser Arbeit würde voraussichtlich von einer derartigen Beleuchtung profitieren. Weiterhin wäre es sinnvoll, das System durch ein Multi-Kamera-Setup zu erweitern, um alle Seiten der Fäzes erfassen zu können. Ein solches Setup würde weiterhin die Möglichkeit bieten, ein vollständiges und texturiertes 3D-Modell von den Fäzes (bzw. der Stuhlform) zu erstellen.

Darauf aufbauend wären randomisiert kontrollierte Studien, mit einer entsprechenden Zielgruppe, sinnvoll, um eine Aussage über die Wirksamkeit bzw. die allgemeinen Auswirkungen der ambienten und semi-automatisierten Klassifikation von Stuhlformen auf die Ernährungsberatung zu erhalten. Insbesondere wäre es hier wichtig zu untersuchen, wie sich die digital verfügbaren und damit auch zeitnah übertragbaren Daten auf den Prozess der Ernährungsberatung auswirken. Eine solche Untersuchung kann auch eine Antwort auf die Frage geben, ob neben der Qualität und der Quantität der Daten auch die Dynamik einen Einfluss hat. Auch das Problem der Fehlinterpretation könnte durch eine langfristige Erhebung untersucht werden, da für die Ernährungsberatung eher Tendenzen und allgemeine Zustände wichtig sind [98].

Kapitel 5

Zusammenfassung und Fazit

In Zeiten beispielloser Fortschritte in den Bereichen Technik, Digitalisierung, Medizin und Pflege, ist es von immenser Bedeutung synergetische Effekte zu nutzen, um unser aller Bestreben zu unterstützen, ein möglichst langes, gesundes und selbstbestimmtes Leben führen zu können. Der zu erwartende Verlauf des geriatrischen Frailty-Syndroms steht diesen Zielen jedoch entgegen. Ein essenzieller Faktor, um einem derartigen Verlauf entgegenzuwirken, ist die Ernährungsberatung bzw. die Ernährungstherapie, siehe Kapitel 2. Das Potenzial von Technik und Digitalisierung zur Unterstützung von zugehörigen Prozessen, insbesondere im Bereich der Erhebung von Daten, wird hier jedoch nur sehr begrenzt genutzt, siehe Kapitel 3. Daher widmete sich diese Arbeit zunächst der Frage: *„Auf welche Art und Weise lassen sich Technologie und Digitalisierung nutzen, um hochaltrige Personen, die vom Frailty-Syndrom betroffen sind, eine selbstständige Erfassung relevanter Informationen für die Ernährungsberatung zu ermöglichen?“*

Im Rahmen dieser Fragestellung wurde ein speziell auf die Bedürfnisse der Zielgruppe dieser Arbeit angepasstes digitales Ernährungstagebuch (engl. Digital Nutrition Diary) (DND) entwickelt. Zur Erfassung dieser Bedürfnisse wurden Personas sowie Problem- und Lösungsszenarien erstellt. Es wurde daraufhin eine Studie mit Proband:innen, aus der Zielgruppe der hochaltrigen und vom Frailty-Syndrom betroffenen Personen, durchgeführt. Diese Studie zielte darauf ab, die Usability des entwickelten Ernährungstagebuchs zu untersuchen. Darüber hinaus wurde in dieser Studie die Usability einer speziell für die Zielgruppe ausgewählten

Körperkompositionswaage und eines Aktivitätstrackers untersucht. Das zusätzlich erhobene direkte und indirekte Feedback für das DND wurde ausgewertet, um dieses weiter auf die Zielgruppe anzupassen. Zur Evaluation dieser Anpassungen wurde eine zweite Studie durchgeführt, ebenfalls mit Proband:innen aus der Zielgruppe. Es konnte gezeigt werden, dass die Usability im Vergleich zur ersten Studie signifikant verbessert werden konnte. Insbesondere der Vergleich zwischen Ernährungstagebuch und Aktivitätstracker hat gezeigt, dass automatisierte und ambiente Methoden auch bei hochaltrigen Personen das Potenzial haben, ein hohes Usability-Niveau zu ermöglichen, siehe Abschnitt 4.1.

Auf Basis der eben genannten Zusammenhänge untersucht der zweite Teil dieser Arbeit die Frage: *„Mit welchen technischen Hilfsmitteln kann das Führen eines digitalen Ernährungstagebuchs für hochaltrige und vom Frailty-Syndrom betroffene Personen weiter vereinfacht werden?“* Hierzu wurde das DND um den KIidI-Eingabemodus erweitert. Dieser Eingabemodus berücksichtigt epistemische Lücken und stellt entsprechende Rückfragen an die Nutzer:innen, wie es auch im persönlichen Gespräch in der Ernährungsberatung üblich ist. Diese Rückfragen können sich auf Getränke, Nahrungsmittel und Nahrungsergänzungsmittel beziehen, welche aufgrund von starker Ähnlichkeit nur kategorisierbar und nicht klassifizierbar sind, wie schwarzer Tee und schwarzer Kaffee. Weiterhin wurde eine Logik eingesetzt, um nach möglichen Kombinationen von schon erkannten und i. d. R. nicht erfassbaren Getränken, Nahrungsmitteln oder Nahrungsergänzungsmitteln zu fragen, wie Butter oder Zucker. Die zugehörigen Studien konnten aufgrund der zu diesem Zeitpunkt vorherrschenden COVID-19 Pandemie nicht mit Proband:innen aus der Zielgruppe durchgeführt werden. Diese wurden daher mit Proband:innen durchgeführt, welche in der Lage waren an einer kontaktlosen (remote) Studie teilzunehmen. Ziel der Studien war es, die manuelle und die semi-automatische Protokollierung des DND anhand von verschiedenen Faktoren, z. B. Usability, miteinander zu vergleichen. Um die Verzerrung der Stichprobe auszugleichen, wurden die beiden Eingabemethoden des DND mit zwei anderen gängigen digitalen Ernährungstagebüchern verglichen. Sowohl der Vergleich der Usability als auch der Erkennungsquoten, der auf KI-basierenden Methoden, hat gezeigt, dass die hier entwickelten Eingabemethoden die Usability einer entsprechenden Software positiv beeinflussen, siehe Abschnitt 4.2.

Somit konnten verschiedene Bausteine gezeigt werden, die dazu eingesetzt werden können, auch hochaltrigen und vom Frailty-Syndrom betroffenen Personen das

Protokollieren wichtiger Daten für die Ernährungsberatung zu ermöglichen. Geht man davon aus, dass die beschriebenen Daten über das Verzehrverhalten, die körperliche Aktivität und die Körperkomposition in ausreichender Qualität und Quantität vorliegen, so beruhen die zugehörigen Formeln, z. B. für die Berechnung der kalorischen Bilanz, jedoch auf gewissen Annahmen. Diese Annahmen umfassen häufig auch die allgemeine, dem Alter und dem Geschlecht entsprechende, Funktionstüchtigkeit der Verdauung und des Stoffwechsels. Speziell bei den hochaltrigen Personen ist dies jedoch häufig beeinträchtigt, siehe Abschnitt 2.2.3. Daher adressiert der dritte Teil dieser Arbeit die Frage: *„Mit welchen technischen Mitteln kann eine automatisierte Klassifizierung von Stuhlformen erreicht werden, um die manuelle Bildaufnahme und die verbale Beschreibung zu ersetzen?“* Auch hier erfolgte die Entwicklung des resultierenden Systems in zwei Schritten. Im Vordergrund stand zu untersuchen, ob es generell möglich ist die Stuhlform auf Basis von Aufnahmen orthogonal zur Fallrichtung der Fäzes, also direkt nach der Defäkation im freien Fall, zu klassifizieren. Die generelle Machbarkeit, anhand von drei der sieben BSFS-Klassen, konnte schon in [195] gezeigt werden. Die in dieser Arbeit angeführte Evaluation eines fortgeschritteneren Prototypen, zur automatischen Klassifikation aller sieben BSFS-Klassen, unterstreicht diese Ergebnisse im Allgemeinen, weist aber auch auf die Limitationen dieses Prototypen hin, siehe Abschnitt 4.3.

5.1. Diskussion

Zur Bewertung des DND und des assisted DND (aDND) wurde der SUS verwendet, um die Benutzbarkeit dieser untereinander und mit anderen Anwendungen und Eingabemethoden vergleichen zu können. Hierbei ist jedoch zu berücksichtigen, dass speziell bei hochaltrigen Personen Diskrepanzen zwischen den SUS-Ergebnissen und den subjektiven Einschätzungen bzgl. der Benutzbarkeit eines Systems existieren können [200]. Speziell die Zusammenhänge zwischen den altersbedingten Einschränkungen von hochaltrigen Personen und der zu erzielenden Benutzbarkeit, wurden von Turnwald et al. untersucht [201], siehe Abbildung 5.1.

Aus diesem Verhältnis und dem Wissen über die Kohorte, aus der die Proband:innen rekrutiert wurden, kann abgeleitet werden, dass die Ergebnisse von positiven wie negativen Biasen beeinflusst wurden. Da die Studien zum DND in einer geriatrischen Einrichtung durchgeführt wurden, ist bekannt, dass der Großteil der

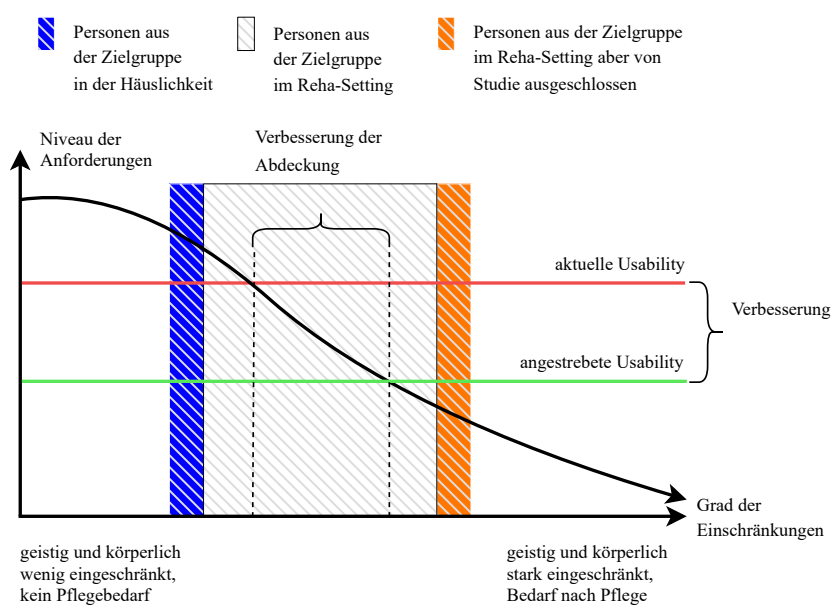


Abbildung 5.1.: Verlauf der Anforderungen an die Usability eines Systems in Relation zum Grad der Einschränkungen von hochaltrigen Personen, in Anlehnung an [201].

Patient:innen von Pre-Frailty oder von Frailty betroffen ist [184]. Es ist jedoch zu berücksichtigen, dass nicht alle von Pre-Frailty oder Frailty betroffenen Personen in derartigen Einrichtungen untergebracht sind. Weiterhin ist anzunehmen, dass Betroffene, die sich außerhalb einer stationären Behandlung befinden, einen besseren allgemeinen Gesundheitszustand aufweisen als jene, die sich in stationärer Behandlung befinden. Dieser Zusammenhang müsste also einen negativen Bias auf die SUS-Ergebnisse haben, da die Betroffenen mit stärkeren Einschränkungen höhere Anforderungen haben [201]. Einen positiven Bias auf die SUS-Ergebnisse hatten vor allem die Ausschlusskriterien, da durch diese vor allem Patient:innen mit starken geistigen und körperlichen Einschränkungen ausgeschlossen wurden, siehe Abschnitt 4.1.4 und 4.1.8. Sowohl dieser positive Bias, als auch der vorher genannte Negative, müssen zwar bei der Interpretation der Ergebnisse berücksichtigt werden, führen aber nicht zu unrealistischen Ergebnissen, da die Ernährungsberatung häufig erst in diesen Einrichtungen sowie nach einer entsprechenden Diagnose stattfindet. Zudem ist zu berücksichtigen, dass bei stark geistig und körperlich eingeschränkten Personen, die Unterstützung mit einem digitalen Ernährungstagebuch nicht realistisch ist.

Ein weiterer Bias entsteht durch den Effekt der sozialen Erwünschtheit. Dieser wird ausgelöst durch die menschliche Tendenz, Antworten auf Umfragen und Fragebögen sowie in Interviews derart anzupassen, dass diese als wünschenswert angesehen werden. Auch heikle oder peinliche Antworten, z. B. auch über kognitive Probleme bei der Bedienung, können mit einer weniger großen Wahrscheinlichkeit erwartet werden [202]. Entsprechend kann davon ausgegangen werden, dass es den Proband:innen in den Studien schwerer gefallen ist, negatives als positives Feedback zu den Systemen zu geben. Dies trifft insbesondere dann zu, wenn es eine persönliche Interaktion zwischen dem Studienpersonal und den Proband:innen gegeben hat. Da dies bei den ersten beiden Studien zum DND der Fall war, kann davon ausgegangen werden, dass dieser Bias die Ergebnisse beeinflusst hat. Dieser Einfluss hat somit vermutlich die absoluten Ergebnisse verzerrt, nicht jedoch die Tendenz zwischen DNDv1 (SUS: $51,66 \pm 11,93$) und DNDv2 (SUS: $76,40 \pm 11,90$), da sich dieser Effekt auf beide Studien gleichermaßen ausgewirkt hat.

Der voraussichtlich stärkste Bias wurde durch die unterschiedlichen Studiendesigns verursacht, da die Proband:innen der ersten Studie nur eine Mahlzeit protokollieren sollten und in der zweiten Studie die Protokollierung von zwölf Mahlzeiten vorgesehen war. Dass hier Lerneffekte aufgetreten sind, ist nicht nur naheliegend, sondern

wird auch durch die von Studientag zu Studientag erkennbare Verringerung der Eingabezeiten deutlich. Insgesamt sank die durchschnittliche Zeit für die Eingabe eines Getränkes, Nahrungsmittels oder Nahrungsergänzungsmittels von 37,2 s für Tag 1, auf 27,73 s für Tag 2 sowie auf 24,49 s für Tag 3 und somit um insgesamt um 34,17%. Besonders stark wirkt sich hier die Verringerung der in diesen Zeiten enthaltenen Fehl Navigationszeiten aus. Diese sind von 11,4 s für Tag 1, auf 7,25 s für Tag 2 sowie auf 6,03 s auf Tag 3, und damit insgesamt um 47,11%, gesunken, siehe Abschnitt 4.1.9 Abbildung 4.9. Auch die Auswirkung dieses Bias führt nicht zu einer unrealistischen Verzerrung der Ergebnisse. In der Ernährungsberatung sind die Zeiträume, über die Patient:innen ihr Verzehrverhalten mit einem derartigen Tagebuch protokollieren müssen, deutlich länger und erstrecken sich über Wochen und im ambulanten Bereich auch über Monate. Die Lerneffekte sollten hier also noch stärker ausfallen und damit, aller Voraussicht nach, zu einer höheren Bewertung der Usability führen.

Auf die Ergebnisse der beiden Studien zu aDNDv1 und zu aDNDv2 lassen sich diese Argumentationen bzgl. der Biases nicht direkt anwenden. Aufgrund der zum Zeitpunkt der Studien vorherrschenden COVID-19 Pandemie, war es aus ethischen Gründen nicht möglich, hochaltrige Proband:innen in die Studien einzuschließen, sodass der Bias durch die Einschränkungen der hochaltrigen Zielgruppe hier keine Relevanz hat. Auch der Effekt der sozialen Erwünschtheit sollte nur geringe Auswirkungen auf die Ergebnisse der Studien haben, da diese anonymisiert und kontaktlos durchgeführt wurden, siehe Abschnitt 4.2.3. Lerneffekte konnten ebenfalls nur sehr begrenzt auftreten, da die Proband:innen nur jeweils eine Mahlzeit protokollieren sollten, siehe Abschnitt 4.2.3. Die Analyse der Bildschirmaufnahmen, aus den Studien zu aDNDv1 und aDNDv2, hat bei der KI-basierten Objekterkennung dieser Anwendungen gezeigt, dass die Proband:innen auch andere Objekte und Szenen, als die aufzunehmende Mahlzeit, erfassen wollten. Es ist zu erwarten, dass sich diese zusätzlichen Zeitspannen durch den häufigeren Einsatz der Anwendung kontinuierlich verringern. Damit gilt für die Ergebnisse der beiden Studien zu aDNDv1 (manuell: SUS: $81,55 \pm 12,92$; semi-automatisch: SUS: $85,83 \pm 8,03$) und zu aDNDv2 (manuell: SUS: $91,92 \pm 8,36$; semi-automatisch: SUS: $89,67 \pm 8,98$), dass diese im Vergleich zu den Ergebnissen von DNDv1 und DNDv2 differenziert betrachtet werden müssen. Dennoch lassen sich die Ergebnisse mittelbar auf die eigentliche Zielgruppe dieser Arbeit übertragen.

Obwohl die Stichprobe nicht repräsentativ für die Zielgruppe dieser Arbeit war, können die SUS-Ergebnisse des manuellen Eingabemodus als Bezugspunkte verwendet werden, da dieser von DNDv2 für aDNDv1 und aDNDv2 übernommen wurde. Da die zugehörigen SUS-Ergebnisse für aDNDv1 und aDNDv2 zwischen 7 und 19 % höher ausfallen, ist anzunehmen, dass die SUS-Ergebnisse bei einer repräsentativen Stichprobe entsprechend niedriger ausfallen würden. Daraus lässt sich ableiten, dass auch die SUS-Ergebnisse der Eingabemethoden der digitalen Ernährungstagebücher MyFitnessPal und FatSecret schlechter ausfallen würden, siehe Abschnitt 4.2.4.

Erreicht werden konnten die Ergebnisse dieser Arbeit durch die Kombination der Erkenntnisse aus dem medizinischen Hintergrund, dem Stand der Technik und den im Rahmen dieser Arbeit erhobenen Anforderungen der Zielgruppe. Dabei wurden sowohl die Einschränkungen der Zielgruppe als auch die für die Ernährungsberatung relevanten Daten berücksichtigt. Details dazu sind in Abschnitt 2.1 und 2.2 zu finden. Ebenso wurden die Erkenntnisse aus verwandten Arbeiten über digitale Ernährungstagebücher integriert, siehe Abschnitt 3.3. Bezüglich der Tagebücher sind vor allem die Arbeiten von Puri et al. [167] und Kawano et al. [170] zu nennen. Diese und andere Arbeiten, siehe Abschnitt 3.3, haben jeweils schon verschiedene Methoden untersucht, um die Erfassung des Verzehrverhaltens zu automatisieren. Jedoch wurden diese Arbeiten nicht für die Zielgruppe dieser Arbeit entwickelt, sodass die Entwicklung eines neuen Ansatzes notwendig war, welcher sich jedoch an den verschiedenen (vor allem den KI-basierten) Arbeiten orientiert. Die Ergebnisse der Studien zum aDNDv1 und aDNDv2, insbesondere der Vergleich mit den herkömmlichen digitalen Ernährungstagebüchern, untermauert, dass eine derartig spezielle Ausrichtung notwendig ist, siehe Abschnitt 4.17. Somit sind sowohl das DND als auch das aDND Möglichkeiten, die im Bereich der Ernährungsberatung für hochaltrige und vom Frailty-Syndrom betroffene Personen eingesetzt werden können. Insbesondere die Verfügbarkeit von beiden Eingabemöglichkeiten im aDND lässt dieses zu einem flexiblen Werkzeug werden.

Nicht nur aufgrund des demografischen Wandels, sondern auch aufgrund der Innovationsgeschwindigkeit, im technologischen sowie im medizinischen Kontext, wird klar, dass sich das Spannungsdreieck zwischen den technischen Möglichkeiten, den Bedarfen der Patient:innen und denen der Ernährungsberater:innen ständig ändert. Damit wird die genannte Flexibilität für derartige Systeme ein wichtiger

Faktor. Hierzu gehört auch die Erweiterbarkeit durch die automatisierte Erfassung von Stuhlformen.

Biases, wie sie bei den digitalen Ernährungstagebüchern aufgetreten sind, hatten keinen Einfluss auf die Entwicklung des Systems zur automatisierten Klassifikation der Stuhlformen. Für die Entwicklung dieses Systems wurde ebenfalls der aktuelle Stand der Wissenschaft berücksichtigt, insbesondere aus medizinischer Perspektive. Aus den verschiedenen Möglichkeiten zur Bewertung der Stuhlform wurde der BSFS ausgewählt, da dieser mit seinen sieben Klassen eine feine Auflösung bietet und häufig eingesetzt wird. Aufgrund der Neuartigkeit des Ansatzes zur Klassifikation der Stuhlformen, standen diesbezüglich keine Quellen oder Datensätze zur Verfügung, auf denen diese Arbeit technisch aufbauen konnte.

Da die Methode zur Erfassung der Fäzes im freien Fall von der Seite einen neuen Ansatz darstellt, wurde dieser zunächst in einer ersten Machbarkeitsstudie unter Laborbedingungen evaluiert. Die Ergebnisse zeigen, dass dieses Prinzip eine valide Möglichkeit ist, um die Stuhlform automatisiert zu klassifizieren. Mit dem zweiten Prototypen konnte gezeigt werden, dass auch die Erkennung von sieben Klassen möglich ist. Das eigens für den zweiten Prototyp entwickelte Stereoskopie-Setup, aufgebaut mit zwei Action-Kameras vom Typ GoPro HERO10 Black, hat für den SVM-basierten Ansatz eine Genauigkeit von 61,68 % für RGB-Daten und von 69,16 % für RGB-D-Daten erreicht. Für den CNN-basierten Ansatz wurde eine Genauigkeit von 93,46 % für die RGB-Daten und von 86,92 % für die RGB-D-Daten erreicht.

Bei den eben genannten Ergebnissen fällt auf, dass das auf RGB-D-Daten basierende Modell schlechter abschneidet als das auf RGB-Daten basierende Modell. Grundlegend basieren Modelle auf den Daten mit denen sie trainiert werden und versuchen, diese anhand der Eigenschaften den entsprechenden Labeln zuzuweisen. Sind diese Eigenschaften zu ähnlich, können diese Modelle trotz gelabelter Daten nicht zwischen den Klassen unterscheiden. Diese Ähnlichkeit kann durch die zusätzlichen Features beschrieben worden sein. Damit gäbe es eine *Overfitting* bei dem auf den RGB-Daten basierenden Modell. Eine weitere Erklärung hierfür wäre der *Fluch der Dimensionen*, da die Modelle mit gleich vielen Epochen trainiert wurden, das RGB-D Modell aber ein Drittel mehr Daten verarbeitet muss. Weiterhin muss berücksichtigt werden, dass die BSFS eine 7-stufige Diskretisierung eines kontinuierlichen Problems beschreibt. Streng genommen wäre damit die

Abweichung von einer Klasse bei der Klassifikation nicht zwingend ein Fehler, sondern könnte zum Teil als Interpretationsspielraum betrachtet werden. Durch das Zulassen von einer Klasse als Abweichung, erreicht der CNN-basierte Ansatz auf Basis der HERO₁₀ Black RGB-Daten eine Genauigkeit von 99,07%. Auch wenn nicht davon ausgegangen werden kann, dass sich diese Ergebnisse direkt auf eine reale Anwendung übertragen lassen, so zeigen sie dennoch, dass die Erfassung der Stuhlform im freien Fall möglich ist.

Nicht nur der demografische Wandel und die damit einhergehende wachsende Anzahl von hochaltrigen Personen, welche eine höhere Inzidenz für Diarrhö und Obstipation aufweisen, zeigt, dass hier ein hoher Bedarf existiert. Auch die in den letzten Jahren stark anwachsende Zahl an Publikationen zu diesem Thema zeigt dies. Insbesondere ist hier die Arbeit von Park et al. [180] hervorzuheben, da diese an einem ähnlichen System arbeiten. Auch wenn hier hohe Erkennungsquoten erreicht werden, handelt es sich um ein sehr komplexes und vermutlich auch sehr kostenintensives System. Zudem stellt sich durch das Scannen des Anus zur Identifikation einzelner Personen die Frage, ob ein derartiges System über eine ausreichende Akzeptanz bei der Zielgruppe verfügt. Als maßgeblicher Unterschied ist jedoch die Erfassung der Fäzes von oben zu nennen, da hier Verdeckungseffekte und das Verschwinden von Fäzes durch den Aufbau einer Toilette nicht berücksichtigt werden.

5.2. Fazit & Ausblick

Zusammenfassend zeigt diese Arbeit verschiedene Ansätze zur Erfassung des Verzehrverhaltens, der körperlichen Aktivität, der Körperkompositionsdaten sowie der Stuhlform. Alle Ansätze verfolgen das Ziel, die Möglichkeiten von Technik und Digitalisierung für die Zielgruppe dieser Arbeit zugänglicher zu gestalten. Die verschiedenen Studien zur jeweiligen Evaluation dieser Ansätze haben gezeigt, dass dies möglich ist, wenn auch mit gewissen Ausnahmen, siehe Abschnitt 4.1.9. Das volle Potenzial dieser Ansätze lässt sich jedoch nur ausschöpfen, wenn diese sinnvoll in einem flexibel einsetzbaren System miteinander verknüpft werden. Durch zusätzliche Studien könnten, neben der allgemeinen Wirksamkeit eines solchen Systems (z. B. gemessen an der Dauer der Ernährungsberatung, der Veränderung der fettfreien Masse oder des Aktivitätslevels), auch kontinuierlich Daten

gesammelt werden, um die verschiedenen Ansätze weiterzuentwickeln (z. B. mit Bildmaterials für die Optimierung der KI und Daten bzgl. Navigationsverhalten zur Optimierung der Pfade). Zudem zeigen die durchgeführten Studien, dass es sinnvoll wäre, die SUS-Erhebung mehrmals durchzuführen, um zu ermitteln, wie und ob sich die Benutzbarkeit durch Lerneffekte innerhalb der hochaltrigen Zielgruppe verändert.

Studien zur Wirksamkeit eines Gesamtsystems könnten dabei sowohl zur Intervention bei Pre-Frailty als auch bei Frailty-Patient:innen durchgeführt werden. Der Nutzen des Gesamtsystems ist dabei durch synergetische Effekte größer als die Summe der Vorteile der Einzelsysteme und führt damit zu weiteren wesentlichen Vorteilen gegenüber konventionellen Abläufen:

- Die Dokumentationspflicht wird durch das System in Teilen automatisch erfüllt.
- Gleichzeitig wird damit auch eine Entlastung des Personals erreicht.
- Weiterhin stehen durch eine automatisierte Dokumentation Daten bei Auffälligkeiten unmittelbar zur Verfügung.
- Zudem stehen, bei einer permanenten Dokumentation, auch entsprechende Daten zur Verfügung.

Neben der Dokumentation kann ein solches System auch dazu eingesetzt werden, Patient:innen kontinuierlich zu überwachen und Auffälligkeiten frühzeitig zu erkennen. Die Verfügbarkeit entsprechender Daten in digitaler Form ist auch für die Analyse von immenssem Vorteil, da u. a. Korrelationen oder Kreuzkorrelationen, z. B. durch Multi-Medikation, Ernährungsumstellung oder Veränderungen hinsichtlich körperlicher Aktivität, schwer zu erfassen sind. Insbesondere, wenn diese mit einer Verzögerung auftreten. Längerfristig angelegte Studien könnten ebenfalls Daten zur Wirksamkeit eines Gesamtsystems im Kontext der Prävention liefern.

Naheliegender ist weiterhin, die verschiedenen Module in anwendungsfallnahen Gebieten einzusetzen. Insbesondere die SUS-Ergebnisse der Studien bzgl. der manuellen Eingabemethode von aDNDv1 und aDNDv2 haben gezeigt, dass, trotz der Ausrichtung der Usability auf eine hochaltrige Zielgruppe, die Usability dieser Eingabemethode auch von jüngeren Personen hoch bewertet wird. Das Zusammenführen von jüngeren Zielgruppen, und dem Ziel fettfreie Masse zu erhalten oder aufzubauen, führt z. B. zu den Bereichen Fitness und Leistungssport. Durch

neue Anwendungsfälle steigt der Grad der Wiederverwendbarkeit und es entstehen neue Ansätze, welche das System wiederum flexibler und breiter einsetzbar machen. In Anlehnung an [180], ist auch die Erfassung des Urins eine sinnvolle Erweiterung sowie die Berechnung des Volumens für beide Arten von Ausscheidungen. Auch die detaillierte Auswertung der Textur und der Farbe von Urin und Fäzes könnten das System sinnvoll erweitern, da diese Rückschlüsse über das Vorhandensein von Krankheiten oder auch Unverträglichkeiten (z. B. Nahrungsmittel oder Neben- bzw. Wechselwirkungen von Multi-Medikation [203]) erlauben. Zudem sollten die aktuellen Entwicklungen im Bereich der in mobilen Endgeräten integrierten Systeme zur Erfassung von räumlicher Tiefe eingesetzt werden, um auch die automatische Berechnung des Volumens mit dem digitalen Ernährungstagebuch zu kombinieren. Ebenfalls wäre es sinnvoll, neben der Usability, speziell die Accessibility zu berücksichtigen, um auch stärker eingeschränkte Personen und entsprechende Anwendungsfälle adressieren zu können, z. B. durch Sprachsteuerung und Nationalisierung.

5.3. Schlusswort

In der abschließenden Betrachtung dieser Arbeit wird deutlich, dass die noch nie dagewesene Dynamik bei der Entwicklung technischer Innovationen zu einem Meer an Chancen und Möglichkeiten führt. Ebenso deutlich wird jedoch auch, dass die individuelle Situation einer jeden vom Frailty-Syndrom betroffenen Person zu ebenso individuellen Bedarfen führt. Die Lösung auf die Fragestellung hinter dem Titel dieser Arbeit kann somit nicht die Entwicklung eines starren und allumfassenden monolithischen Systems sein. Vielmehr sollte die Lösung einem Werkzeugkasten gleichen, indem die passenden Werkzeuge für die individuellen Bedarfe griffbereit liegen. Ein solcher Werkzeugkasten lässt sich nicht nur dynamisch anpassen, sondern sorgt auch dafür, dass der Mensch im Fokus steht. Wenn die Chancen der fortschreitenden technischen Innovationen so effektiv genutzt werden, können sich viele einzelne und an sich kleine Beiträge zu einem großen Beitrag zusammenfügen und wir alle können dem demografischen Wandel durch Innovation mit Zuversicht begegnen.

Anhang

A.1. Personas und Szenarien

Die im Folgenden angeführten Personas und Szenarien sind gekürzt und vereinfacht, da die Gesamtheit der erstellten Personas und Szenarien das in dieser Arbeit angeführte System im Kontext eines größeren Gesamtsystems erfassen sollte. Die hier angeführten Beispiele zeigen jedoch die grundlegende Herangehensweise, dass mithilfe von Personas und Ist-Szenarien Soll-Szenarien abgeleitet werden, in denen dann die Anforderungen skizziert sind.

A.1.1. Persona: Patient Heinz Janssen

- Herr Janssen ist 79 Jahre alt, ehemaliger Angestellter bei der Telekom, verwitwet, hat eine eigene Wohnung innerhalb einer Einrichtung für betreutes Wohnen und hat 2 Kinder und 3 Enkelkinder.
- Herr Janssen war Vorsitzender des Sozialverbandes und war hierfür viel unterwegs. Er war im Rahmen dieser Arbeit sehr fürsorglich und hat häufig selber Mitglieder in schwierigen gesundheitlichen Situationen zur Seite gestanden.

- Durch einen Kollaps [...] mit Krankenhausaufenthalt und künstlichem Koma und dem Wechsel des Defibrillators, befindet er sich aktuell in der Rehabilitation (Reha). Sein linkes Bein schmerzt noch, seine kognitive Funktion ist seither eingeschränkt (Vergesslichkeit und Konzentrationsstörung), momentan ist er mit dem Rollator mobil. Weitere Begleiterkrankungen: Bluthochdruck und Herzschwäche.
- Frailty Status: reduzierte Gehgeschwindigkeit, Handkraft und körperliche Aktivität sowie Gewichtsverlust von 12 kg. Weiterhin leidet er unter einer schnellen Sättigung und Appetitlosigkeit. Seine aktuelle Essmenge liegt bei 50 % des sonst üblichen. Die Versorgung mit Mahlzeiten erfolgt übers Pflegeheim.
- Bisher erhält er keine Ernährungsberatung, die Kraft dazu fehlt ihm. Die Ernährungssonde [...], die er im Krankenhaus erhalten hat, wird momentan nicht genutzt. Herr Janssen führt ein Trinkprotokoll auf Anordnung des Reha-Arztes. Er nimmt das Protokoll sehr ernst und trägt die Trinkmengen immer direkt ein.
- Herr Janssen besitzt ein Smartphone und benutzt es regelmäßig. Er nutzt den Kalender, die Uhrzeitabfrage, das Adressbuch und macht ab und zu ein Foto. Fotos verschicken und Nachrichten schreiben ist ihm bisher zu kompliziert gewesen, da steigt er noch nicht durch. Als großer Fußballfan ist eine Fußball-App das meistgenutzte Programm. Ab und zu geraten die Einstellungen durcheinander oder er verirrt sich in der Fußball-App. Seine Tochter richtet ihm die App bei ihrem nächsten Besuch wieder ein.
- Hobbys: Fußball gucken, Gymnastikgruppe, Gesellschaftsspiele

A.1.2. Szenario: Ist-Situation Heinz Janssen

- Herr Janssen steht der Nutzung von Technik offen gegenüber. In der Anwendung von Technik ist er nicht sehr geübt. Aus diesem Grund verheddert er sich manchmal in der Smartphone App. Seine Tochter hilft ihm dann beim nächsten Besuch wieder zurück zur Grundeinstellung (**Problem 1**).
- Herr Janssen isst seit März dieses Jahres noch knapp die Hälfte des sonst üblichen. Auf Fleisch verzichtet er fast vollständig, da er hierauf einfach

keinen Appetit hat. Er bevorzugt frische Speisen wie Obst und Speisen, die leicht zu kauen sind wie Obstkompott, Kartoffelbrei (**Problem 2**).

- Herr Janssen nimmt das Führen eines vom Arzt verordneten Trinkprotokolls sehr ernst und schreibt alle getrunkenen Getränke direkt auf Papier auf. Dies ist für ihn notwendig, da er nach dem Aufenthalt auf der Intensivstation vergesslich geworden ist (**Problem 3**).

A.1.2.1. Identifikation von Problemfaktoren

Problem 1 Fehlende Routine, Unsicherheit in der Anwendung von Technik

Problem 2 Mangelernährung durch die veränderten Essgewohnheiten

Problem 3 Vergesslichkeit bzgl. der Dokumentation der Trinkmenge auf Papier

A.1.3. Szenario: Soll-Situation Heinz Janssen

Problem 1 Herr Janssen erhält [...] ein System mit einer gut verständlichen und ausführlichen persönlichen Einweisung. Herr Janssen (bzw. die Angehörigen) können die wichtigsten Schritte und Funktionen in einer kurz gehaltenen und übersichtlichen Anleitung nachlesen. Die Angehörigen werden in die Nutzung des [...] Systems einbezogen.

Problem 2 Herr Janssen kann die Nahrungsaufnahme über das [...] System erfassen. Dies ermöglicht den Ernährungsberater:innen eine engmaschige Kontrolle der Nahrungsaufnahme und eine zeitnahe, gezielte Intervention.

Problem 3 Herr Janssen wird ebenfalls durch das [...] System auf seine nicht adäquate Nahrungsaufnahme aufmerksam gemacht. Vorschläge für Anpassungen werden durch den Ernährungsberater und das [...] System unterbreitet. Eine weitere Variante wäre die Vorgabe eines Soll-Verzehrs (z. B. anhand einer Art Ernährungspyramide), die der Patient dann abhaken kann.

Problem 1 und 2 Bei Fragen und Problemen [...] steht [...] ein Mitarbeiter zur Verfügung. Um die Anwendung so leicht wie möglich zu gestalten, sollte die Programmführung sehr einfach gestaltet werden.




Abbildung A.1.: Verteilung der AP-Werte für eine aufsteigende Anzahl von Klassen für das KI-Modell zur Objekterkennung für das Mittagessen. Der mAP-Wert des jeweiligen Modells ist durch ein „x“ markiert.




Abbildung A.2.: Verteilung der AP-Werte für eine aufsteigende Anzahl von Klassen für das KI-Modell zur Objekterkennung für das Abendessen. Der mAP-Wert des jeweiligen Modells ist durch ein „x“ markiert.




Abbildung A.3.: Verteilung der AP-Werte für eine aufsteigende Anzahl von Klassen für das KI-Modell zur Objekterkennung für Zwischenmahlzeiten. Der mAP-Wert des jeweiligen Modells ist durch ein „x“ markiert.

Tabelle A.1.: Übersicht über die Vor- und Nachteile der retrospektiven Methoden zur Erfassung des Verzehrverhaltens, in Anlehnung an die Arbeiten von [75, 76, 53, 204]

Retrospektive Erhebungsmethoden	
Vorteile	Nachteile
<i>24-Hours-Recall</i>	
<ul style="list-style-type: none"> - geringe Belastung der Patient:innen - hohe Bereitschaft zur aktiven Mitwirkung - geringer Zeit- und Arbeitsaufwand (ca. 30 Min. pro Interview) - Interviewer:in kann Rückfragen stellen - kostengünstig und einfach durchführbar - geeignet für große Kohorten - nicht reaktive Methode - computergestützte Erhebung möglich 	<ul style="list-style-type: none"> - abhängig vom Erinnerungsvermögen - tatsächlicher Verzehr leicht unterschätzt - Verzehr „gesunder“ Lebensmittel wird eher überschätzt - geschulte Interviewer:in notwendig - selten verzehrte Lebensmittel werden evtl. nicht erfasst - Under- und Overreporting möglich - Schwierigkeiten bei Einschätzung der Portionsgröße - Einfluss des Interviewers auf das Antwortverhalten möglich
<i>Diet-History-Interview</i>	
<ul style="list-style-type: none"> - Erfassung erfolgt über einen längeren Zeitraum - geeignet für große Kohorten - computergestützte Erfassung möglich (Verminderung der Reaktivität) - nicht reaktive Methode - relativ hohe Bereitschaft zur aktiven Mitwirkung - Interviewer:in kann Rückfragen stellen 	<ul style="list-style-type: none"> - abhängig vom Erinnerungsvermögen - sehr arbeits- und zeitaufwendig - Portionsgrößeneinschätzung oftmals unpräzise - sehr gut geschulte Interviewer:in notwendig - selten verzehrte Lebensmittel werden evtl. nicht erfasst - Zeitraum schwer festzulegen - Einfluss des Interviewers auf das Antwortverhalten möglich - Under- und Overreporting möglich - durch vorangegangene Nahrungsaufnahme Verzerrungen möglich

Tabelle A.1.: Übersicht über die Vor- und Nachteile der retrospektiven Methoden zur Erfassung des Verzehrverhaltens, in Anlehnung an die Arbeiten von [75, 76, 53, 204]

Retrospektive Erhebungsmethoden	
Vorteile	Nachteile
<i>Food Frequency Questionnaire</i>	
<ul style="list-style-type: none"> - schnelle und einfache Durchführbarkeit - geringer Arbeitsaufwand - Patient:in kann es selbständig erheben, daher kein Interviewer:in notwendig - kein Einfluss des Interviewers - PC-gestützte Erfassung möglich bzw. maschinell einlesbar - geeignet für große Kohorten - geringe Belastung der Patient:innen - hohe Response-Rate - nicht reaktive Methode - Veränderungen des Verzehrs im Verlauf werden erfasst 	<ul style="list-style-type: none"> - abhängig von Erinnerungsvermögen - Portionsgrößeneinschätzung oftmals unpräzise - Verzehr „gesunder“ Lebensmittel wird eher überschätzt - geringe Genauigkeit - selten verzehrte Lebensmittel werden unter Umständen nicht erfasst - Under- und Overreporting möglich

Tabelle A.2.: Übersicht über die Vor- und Nachteile der prospektiven Methoden zur Erfassung des Verzehrverhaltens, in Anlehnung an die Arbeiten von [75, 76, 53, 84, 204].

Prospektive Erhebungsmethoden	
Vorteile	Nachteile
<i>Schätzprotokoll</i>	
<ul style="list-style-type: none"> - semiquantitative Erfassung von Energie- und Nährstoffzufuhr möglich - unabhängig vom Erinnerungsvermögen - schnelle und einfache Durchführbarkeit - keine Beeinflussung durch Interviewer:in 	<ul style="list-style-type: none"> - abhängig von Gewissenhaftigkeit und Motivation - je länger der Zeitraum, desto höher die Belastung - hoher Kostenaufwand - Portionsgrößeneinschätzung eher unpräzise - hoher Arbeitsaufwand für die Kodierung - sehr gut geschulte Interviewer:in notwendig - reaktive Methode - Under- und Overreporting möglich
<i>Wiegeprotokoll</i>	

Tabelle A.2.: Übersicht über die Vor- und Nachteile der prospektiven Methoden zur Erfassung des Verzehrverhaltens, in Anlehnung an die Arbeiten von [75, 76, 53, 84, 204].

Prospektive Erhebungsmethoden	
Vorteile	Nachteile
<ul style="list-style-type: none"> - unabhängig vom Erinnerungsvermögen - präzise Erfassung der Verzehrs - quantitative Erfassung von Energie- und Nährstoffzufuhr möglich - keine Beeinflussung durch Interviewer:in 	<ul style="list-style-type: none"> - sehr hoher zeitlicher Aufwand für Patient:innen - abhängig von der Motivation - hoher Arbeitsaufwand für die Kodierung - sehr gut geschulte Interviewer:in notwendig - hoher Kostenaufwand - eher für kleine Stichproben geeignet - reaktive Methode - Validität kann mit zunehmender Erhebungsdauer sinken - Underreporting möglich

Tabelle A.2.: Übersicht über die Vor- und Nachteile der prospektiven Methoden zur Erfassung des Verzehrverhaltens, in Anlehnung an die Arbeiten von [75, 76, 53, 84, 204].

Prospektive Erhebungsmethoden	
Vorteile	Nachteile
<i>Tellerdiagramm</i>	
<ul style="list-style-type: none"> - schnelle, einfache Durchführung - unabhängig vom Erinnerungsvermögen - keine Beeinflussung durch Interviewer:in 	<ul style="list-style-type: none"> - sehr gut geschultes Personal notwendig
<i>Doppelportionstechnik</i>	
<ul style="list-style-type: none"> - präzise Erfassung von Energie- und Nährstoffzufuhr - keine Beeinflussung durch Interviewer:in - unabhängig vom Erinnerungsvermögen 	<ul style="list-style-type: none"> - sehr hoher zeitlicher und personeller Aufwand - sehr hohe Kosten - nur für eine kleine und zeitlich begrenzte Stichprobe geeignet - reaktive Methode - gibt meist nicht den üblichen Verzehr wider - gut geschultes Personal notwendig - Analyse meist nur auf wenige Nährstoffe möglich
<i>Fotomethode</i>	
<ul style="list-style-type: none"> - unabhängig vom Erinnerungsvermögen - direkte Datenübertragung möglich 	<ul style="list-style-type: none"> - sehr gut geschultes Personal notwendig - technische Ausstattung erforderlich

Tabelle A.3.: Vollständige Übersicht der Zuordnung von FoBaST-Elementen sowie FoBaST-Kategorien (★) zu insgesamt 41 Klassen.

Nr.	Klasse	FoBaST-Elemente
1	Apfel	Apfel
2	Banane	Banane
3	Hülsenfrüchte	Hülsenfrüchte
4	Rind	Rind, Kalb
5	Beeren	Beeren, Kirschen
6	Bockwurst	Bockwurst
7	Backwaren	Brot★, Brötchen★, Croissant
8	Butter	Butter★, Margarine, Halbfettmargarine, Schmelzkäse
9	Kuchen	Kuchen★
10	Käse	Käse★
11	Geflügel	Geflügel
12	Schokolade	Schokolade, Schokoladenriegel
13	Kekse	Kekse
14	Frischkäse	Frischkäse, Streichkäse
15	Tassenge Getränke	Kaffee★, Milch★, Tee★, Saft, Schorle, Wasser
16	Ei	Ei
17	Fisch	Fisch★
18	Pommes	Pommes, Krokette
19	Glasgetränke	Kaffee★, Milch★, Tee★, Bier, Saft Schorle, Spirituosen, Wasser, Wein
20	Weintrauben	Weintrauben
21	Bratensoße	Bratensoße
22	Honig	Honig
23	Eis	Eis
24	Marmelade	Marmelade
25	Milch	Milch★, Sahne★, Kaffeesahne
26	Hackfleisch	Hackfleisch
27	Nudeln	Nudeln★
28	Birne	Birne

Tabelle A.3.: Vollständige Übersicht der Zuordnung von FoBaST-Elementen sowie FoBaST-Kategorien (*) zu insgesamt 41 Klassen.

Nr.	Klasse	FoBaST-Elemente
29	Schwein	Schweinefleisch
30	Kartoffeln	Kartoffeln*
31	Pudding	Pudding
32	Salat	Salat
33	Soße	Hackfleischsoße, Ketchup, Tomatensoße
34	Wurst	Wurst*
35	Suppe	Suppe*, Eintöpfe *
36	Dosenobst	Dosenobst
37	Gemüse	Gemüse*
38	Brötchen	Brötchen*
39	Schlagsahne	Schlagsahne
40	Vollkornbrötchen	Vollkornbrötchen
41	Joghurt	Quark, Joghurt*, Pudding*, Müsli

Abkürzungsverzeichnis

24h-Recall 24-Hours Recall Protocol	2
aDND assisted DND	147
aDNDv1 assisted DND Version 1	92
aDNDv2 assisted DND Version 2	92
AR Augmented Reality	31
AP Average Precision	96
AT Aktivitätstracker (engl. Activity Tracker)	70
KNN Künstliches Neuronales Netzwerk	128
BB Bounding Box	94
BCS Körperkompositionswaage (engl. Body Composition Scale)	70
BIA Bioelektrische Impedanzanalyse	15
BITSS Brussels Infant and Toddler Stool Scale	23
CFS Clinical Frailty Scale	10
CNN Convolutional Neural Network	93
CT Computertomographie (engl. Computed Tomography)	43
DHI Diet-History-Interview	18
DL Deep Learning	44
DND digitales Ernährungstagebuch (engl. Digital Nutrition Diary)	145
DNN tiefes neuronales Netzwerk (engl. Deep Neural Network)	48
DNDv1 DND Version 1	67
DNDv2 DND Version 2	70
EFS Edmonton Frail Scale	10
FFQ Food Frequency Questionnaire	18
FNN vorwärts gerichtetes neuronales Netz (engl. Feedforward Neural Network)	47
FtF Fuß-zu-Fuß (engl. Foot to Foot)	41

Abkürzungsverzeichnis

FI	Frailty Index	10
FoBaST	Nahrungsmittel-, Getränke- und Nahrungsergänzungsmittelbaum (engl. Food, Beverages and Supplements Tree)	79
FP	Frailty-Phänotyp	10
GFI	Groningen Frailty Indicator	10
IoT	Internet der Dinge (engl. Internet of Things)	29
IoU	Intersection over Union	52
KI	Künstliche Intelligenz	90
KIidI-Eingabemodus	KI-basierte, interaktive, dynamische und interview-artige Eingabemodus	92
KSS	Kings Stool Scale	142
mAP	mean Average Precision	93
ML	Maschinelles Lernen	44
MoG2	Mixture of Gaussians 2	126
NNAPI	Neural Network API	117
RBF	Radial Basis Function	135
RGB	rot, grün und blau (engl. Red, Green and Blue)	48
R-CNN	Regionen mit CNN-Merkmalen (engl. Regions with CNN features)	51
ROI	Region Of Interest	118
SSD	Single Shot Multibox Detector	96
SVM	Support Vector Machine	129
SUS	System Usability Scale	73
TC	Technology Commitment	72
TOF	Time-of-Flight	34
FRAIL-Scale	Simple Frailty Questionnaire	10
MNA	Mini Nutritional Assessment	2
MNA-SF	Mini Nutritional Assessment Short-Form	2
BSFS	Bristol Stool Form Scale	121
YOLO	You Only Look Once	93

Abbildungsverzeichnis

2.1. Anzahl an Publikationen Frailty	8
2.2. Risikofaktoren Frailty	9
2.3. Methoden zur Erhebung des Verzehrverhaltens	16
2.4. Künstliche BSFS-Testkörper	22
3.1. Prinzip der Stereoskopie	32
3.2. Prinzip der Epipolargeometrie	33
3.3. Prinzip der Structured-Light	34
3.4. Beispiele für Tiefenbild und Punktwolke	37
3.5. Übersicht über Aktivierungsfunktionen	49
3.6. Beispielhafte Faltungen eines Eingangsbildes	50
3.7. Beispielhafte CNN-Architektur	51
3.8. Übersicht über die mAP unterschiedlicher Algorithmen	55
4.1. Navigationsstruktur des DNDv1	69
4.2. Übersicht über die Sensorik	71
4.3. Überblick über die SUS-Ergebnisse erste Studie	74

4.4.	Eintragung einer Portion Müsli in das DNDv2 Teil I	78
4.5.	Eintragung einer Portion Müsli in das DNDv2 Teil II	80
4.6.	Überblick über die SUS-Ergebnisse beide Studien	83
4.7.	Pfadanalyse für: Milch 3,5%	85
4.8.	Pfadanalyse für: grüner Salat	86
4.9.	Vergleich benötigter Zeiten	87
4.10.	Datensatz für das Training des Objekterkennungsalgorithmus	95
4.11.	Übersicht AP-Verteilungen: Frühstück	96
4.12.	Übersicht AP-Werte: alle Mahlzeiten	97
4.13.	Navigationsstruktur des aDNDv2	98
4.14.	Schritt 1: KI-basierte Objekterkennung & Überprüfung	99
4.15.	Schritt 2: Feinauswahl & Mengeneingabe	101
4.16.	Schritt 3 und 4: Kombinationen & Mengeneingabe sowie Zusammenfassung	102
4.17.	Übersicht SUS-Werte: Studie zu aDNDv1	105
4.18.	Übersicht Eingabezeiten: Studie zu aDNDv1	106
4.19.	Übersicht Interaktionen: Studie zu aDNDv1	107
4.20.	Korrelation zwischen Größe der Mahlzeit und Zeit: Studie zu aDNDv1 . .	108
4.21.	Vergleich der Erkennungsquoten	109
4.22.	Eingabe der Mengen über semi-dynamische Faktoren	111
4.23.	Experimentelles Setup für die Berechnung von Volumina	112
4.24.	Übersicht Architektur für Volumenberechnung	113
4.25.	Beispielhafte Darstellung der Verarbeitung der Punktwolke	114
4.26.	3D-Modell der Sitzerrhöhung	123
4.27.	Kamerasetups mit Gehäuse	124
4.28.	Übersicht Architektur für Klassifikation von Stuhlformen	126
4.29.	Anwendung des MoG2-Algorithmus	127

Abbildungsverzeichnis

4.30. Schritte zur Erzeugung des Datensatzes	130
4.31. Beispiele BSFS-Klassen	131
4.32. Vergleich RealSense D435 und HERO ₁₀ Black Aufnahmen	133
4.33. Ergebnisse & Features für One-vs-One auf RGB-Daten	136
4.34. Ergebnisse & Training für AlexNet auf RGB-Daten	137
4.35. Beispiele zweier Tiefenkarten	138
4.36. Ergebnisse & Features von One-vs-One auf RGB-D-Daten	139
4.37. Ergebnisse & Training AlexNet CNN-Modell für RGB-D-Daten	140
5.1. Usability-Anforderungen in Relation zum Einschränkungsggrad	148
A.1. Übersicht AP-Verteilungen: Mittagessen	160
A.2. Übersicht AP-Verteilungen: Abendessen	161
A.3. Übersicht AP-Verteilungen: Zwischenmahlzeiten	162

Tabellenverzeichnis

3.1. Übersicht über die Ergebnisse von Frija-Masson et al. [72].	42
4.1. Übersicht über die fünf am häufigsten ausgewählten FoBaST-Elemente . . .	93
4.2. Zuordnung von FoBaST-Elementen und Kategorien zu Klassen	94
4.4. Übersicht über die fünf Eingabemethoden	104
4.5. Konfiguration RealSense D435	113
4.6. Konfiguration RealSense D435 & HERO ₁₀ Black	125
4.7. Übersicht über die Verteilung der extrahierten Bilder	132
4.8. Übersicht verwendete Setups zur Klassifikation	134
A.1. Übersicht der Vor- und Nachteile retrospektiver Methoden	163
A.1. Übersicht der Vor- und Nachteile retrospektiver Methoden	164
A.2. Übersicht der Vor- und Nachteile prospektiver Methoden	165
A.2. Übersicht der Vor- und Nachteile prospektiver Methoden	166
A.2. Übersicht der Vor- und Nachteile prospektiver Methoden	167
A.3. Vollständige Übersicht der Zuordnung	168
A.3. Vollständige Übersicht der Zuordnung	169

Literaturverzeichnis

- [1] K. G. Kinsella and D. R. Phillips, "Global Aging: The Challenge of Success," *Population Bulletin*, vol. 60, no. 1, pp. 5–45, 2005.
- [2] Population Division, Department of Economic and Social Affairs, "The World at Six Billion," *Population Newsletter*, pp. 1–21, 2002.
- [3] S. Nowossadeck, "Demografischer wandel, pflegebedürftige und der künftige bedarf an pflegekräften," *Bundesgesundheitsblatt-Gesundheitsforschung-Gesundheitsschutz*, vol. 56, no. 8, pp. 1040–1047, 2013.
- [4] X. Song, A. Mitnitski, and K. Rockwood, "Prevalence and 10-year outcomes of frailty in older adults in relation to deficit accumulation," *Journal of the American Geriatrics Society*, vol. 58, no. 4, pp. 681–687, 2010.
- [5] L. P. Fried, C. M. Tangen, J. Walston, A. B. Newman, C. Hirsch, J. Gottdiener, T. Seeman, R. Tracy, W. J. Kop, G. Burke, *et al.*, "Frailty in older adults: evidence for a phenotype," *The Journals of Gerontology Series A: Biological Sciences and Medical Sciences*, vol. 56, no. 3, pp. M146–M157, 2001.
- [6] L. P. Fried, J. Williamson, and J. Kaspar, "The Epidemiology of Frailty: The Scope of the Problem," *Aging and Musculoskeletal Disorders: Concepts, Diagnosis, and Treatment*. New York: Springer, pp. 3–15, 1993.
- [7] C. K. Cassel, R. Leipzig, H. J. Cohen, E. B. Larson, D. E. Meier, *et al.*, *Geriatric Medicine: An Evidence-Based Approach*. Springer Science & Business Media, 2003.

- [8] L. Ferrucci, C. Cavazzini, A. Corsi, B. Bartali, C. Russo, F. Lauretani, A. Corsi, S. Bandinelli, and J. Guralnik, "Biomarkers of frailty in older persons.," *Journal of endocrinological investigation*, vol. 25, no. 10 Suppl, pp. 10–15, 2002.
- [9] A. Clegg, J. Young, S. Iliffe, M. O. Rikkert, and K. Rockwood, "Frailty in Elderly People," *The Lancet*, vol. 381, no. 9868, pp. 752–762, 2013.
- [10] J. E. Morley, B. Vellas, G. A. Van Kan, S. D. Anker, J. M. Bauer, R. Bernabei, M. Cesari, W. Chumlea, W. Doehner, J. Evans, *et al.*, "Frailty Consensus: A Call to Action," *Journal of the American Medical Directors Association*, vol. 14, no. 6, pp. 392–397, 2013.
- [11] H. J. Denison, C. Cooper, A. A. Sayer, and S. M. Robinson, "Prevention and optimal management of sarcopenia: a review of combined exercise and nutrition interventions to improve muscle outcomes in older people," *Clinical Interventions in Aging*, vol. 10, p. 859, 2015.
- [12] T. P. Ng, L. Feng, M. S. Z. Nyunt, L. Feng, M. Niti, B. Y. Tan, G. Chan, S. A. Khoo, S. M. Chan, P. Yap, *et al.*, "Nutritional, physical, cognitive, and combination interventions and frailty reversal among older adults: a randomized controlled trial," *The American Journal of Medicine*, vol. 128, no. 11, pp. 1225–1236, 2015.
- [13] N. M. Cermak, P. T. Res, L. C. de Groot, W. H. Saris, and L. J. van Loon, "Protein supplementation augments the adaptive response of skeletal muscle to resistance-type exercise training: a meta-analysis," *The American Journal of Clinical Nutrition*, vol. 96, no. 6, pp. 1454–1464, 2012.
- [14] S. Goisser, S. Gillette-Guyonnet, and D. Volkert, "The Role of Nutrition in Frailty: An Overview," *The Journal of Frailty & Aging*, vol. 5, no. 2, pp. 74–7, 2016.
- [15] P. Elfert, M. Eichelberg, J. Tröger, J. Britz, J. Alexandersson, D. Bieber, J. Bauer, S. Teichmann, L. Kuhn, M. Thielen, *et al.*, "DiDiER - Digitized Services in Dietary Counselling for People with Increased Health Risks Related to Malnutrition and Food Allergies," in *IEEE Symposium on Computers and Communications (ISCC)*, pp. 100–104, IEEE, 2017.
- [16] E. Cereda, "Mini nutritional assessment," *Current Opinion in Clinical Nutrition & Metabolic Care*, vol. 15, no. 1, pp. 29–41, 2012.
- [17] M. J. Kaiser, J. M. Bauer, C. Ramsch, W. Uter, Y. Guigoz, T. Cederholm, D. R. Thomas, P. Anthony, K. E. Charlton, M. Maggio, *et al.*, "Validation of the mini nutritional assessment short-form (mna®-sf): A practical tool for identification of nutritional status," *JNHA-The Journal of Nutrition, Health and Aging*, vol. 13, no. 9, p. 782, 2009.

- [18] R. L. Carter, C. O. Sharbaugh, and C. A. Stapell, "Reliability and validity of the 24-hour recall," *Journal of the American Dietetic Association*, vol. 79, no. 5, pp. 542–547, 1981.
- [19] E. O. Hoogendijk, J. Afilalo, K. E. Ensrud, P. Kowal, G. Onder, and L. P. Fried, "Frailty: implications for clinical practice and public health," *The Lancet*, vol. 394, no. 10206, pp. 1365–1375, 2019.
- [20] P. Benzinger, A. Eidam, and J. M. Bauer, "Klinische bedeutung der erfassung von frailty," *Zeitschrift für Gerontologie und Geriatrie*, vol. 54, no. 3, pp. 285–296, 2021.
- [21] L. P. Fried, A. A. Cohen, Q.-L. Xue, J. Walston, K. Bandeen-Roche, and R. Varadhan, "The physical frailty syndrome as a transition from homeostatic symphony to cacophony," *Nature Aging*, vol. 1, no. 1, pp. 36–46, 2021.
- [22] B. E. Klein, R. Klein, M. D. Knudtson, and K. E. Lee, "Frailty, morbidity and survival," *Archives of gerontology and geriatrics*, vol. 41, no. 2, pp. 141–149, 2005.
- [23] J. Walston, E. C. Hadley, L. Ferrucci, J. M. Guralnik, A. B. Newman, S. A. Studenski, W. B. Ershler, T. Harris, and L. P. Fried, "Research agenda for frailty in older adults: toward a better understanding of physiology and etiology: summary from the american geriatrics society/national institute on aging research conference on frailty in older adults," *Journal of the American Geriatrics Society*, vol. 54, no. 6, pp. 991–1001, 2006.
- [24] R. V. Azzopardi, S. Vermeiren, E. Gorus, A.-K. Habbig, M. Petrovic, N. Van Den Noortgate, P. De Vriendt, I. Bautmans, I. Beyer, D. Verté, *et al.*, "Linking frailty instruments to the international classification of functioning, disability, and health: a systematic review," *Journal of the American Medical Directors Association*, vol. 17, no. 11, pp. 1066–e1, 2016.
- [25] A. H. Jacobs and C. Bollheimer, "Frailty," in *Neurogeriatrie*, pp. 49–68, Springer, 2019.
- [26] M.-V. Castell, M. Sánchez, R. Julián, R. Queipo, S. Martín, and Á. Otero, "Frailty prevalence and slow walking speed in persons age 65 and older: implications for primary care," *BMC family practice*, vol. 14, no. 1, pp. 1–9, 2013.
- [27] J. Dudzińska-Griszek, K. Szuster, and J. Szewieczek, "Grip strength as a frailty diagnostic component in geriatric inpatients," *Clinical interventions in aging*, vol. 12, p. 1151, 2017.
- [28] H. Syddall, C. Cooper, F. Martin, R. Briggs, and A. Aihie Sayer, "Is grip strength a useful single marker of frailty?," *Age and ageing*, vol. 32, no. 6, pp. 650–656, 2003.

- [29] K. Rockwood, J. Blodgett, O. Theou, M. Sun, H. Feridooni, A. Mitnitski, R. Rose, J. Godin, E. Gregson, and S. Howlett, "A frailty index based on deficit accumulation quantifies mortality risk in humans and in mice," *Scientific reports*, vol. 7, no. 1, pp. 1–10, 2017.
- [30] K. Rockwood, X. Song, C. MacKnight, H. Bergman, D. B. Hogan, I. McDowell, and A. Mitnitski, "A global clinical measure of fitness and frailty in elderly people," *Cmaj*, vol. 173, no. 5, pp. 489–495, 2005.
- [31] J. E. Morley, T. Malmstrom, and D. Miller, "A simple frailty questionnaire (frail) predicts outcomes in middle aged african americans," *The journal of nutrition, health & aging*, vol. 16, no. 7, pp. 601–608, 2012.
- [32] D. B. Rolfson, S. R. Majumdar, R. T. Tsuyuki, A. Tahir, and K. Rockwood, "Validity and reliability of the edmonton frail scale," *Age and ageing*, vol. 35, no. 5, pp. 526–529, 2006.
- [33] L. L. Peters, H. Boter, E. Buskens, and J. P. Slaets, "Measurement properties of the groningen frailty indicator in home-dwelling and institutionalized elderly people," *Journal of the American Medical Directors Association*, vol. 13, no. 6, pp. 546–551, 2012.
- [34] N. Steverink, "Measuring frailty: developing and testing the gfi (groningen frailty indicator)," *The gerontologist*, vol. 41, p. 236, 2001.
- [35] O. Bruyère, F. Buckinx, C. Beaudart, J.-Y. Reginster, J. Bauer, T. Cederholm, A. Cherubini, C. Cooper, A. J. Cruz-Jentoft, F. Landi, *et al.*, "How clinical practitioners assess frailty in their daily practice: an international survey," *Aging clinical and experimental research*, vol. 29, no. 5, pp. 905–912, 2017.
- [36] A. B. Mitnitski, A. J. Mogilner, C. MacKnight, and K. Rockwood, "The mortality rate as a function of accumulated deficits in a frailty index," *Mechanisms of ageing and development*, vol. 123, no. 11, pp. 1457–1460, 2002.
- [37] W. J. Evans and D. Cyr-Campbell, "Nutrition, exercise, and healthy aging," *Journal of the American Dietetic Association*, vol. 97, no. 6, pp. 632–638, 1997.
- [38] P. Schuetz, R. Fehr, V. Baechli, M. Geiser, M. Deiss, F. Gomes, A. Kutz, P. Tribolet, T. Bregenzer, N. Braun, *et al.*, "Individualised nutritional support in medical inpatients at nutritional risk: a randomised clinical trial," *The Lancet*, vol. 393, no. 10188, pp. 2312–2321, 2019.
- [39] L. Romera-Liebana, F. Orfila, J. M. Segura, J. Real, M. L. Fabra, M. Möller, S. Lancho, A. Ramirez, N. Marti, M. Cullell, *et al.*, "Effects of a primary care-based multifactorial intervention on physical and cognitive function in frail, elderly individuals:

- a randomized controlled trial," *The Journals of Gerontology: Series A*, vol. 73, no. 12, pp. 1668–1674, 2018.
- [40] M. Serra-Prat, X. Sist, R. Domenich, L. Jurado, A. Saiz, A. Roces, E. Palomera, M. Tarradellas, and M. Papiol, "Effectiveness of an intervention to prevent frailty in pre-frail community-dwelling older people consulting in primary care: a randomised controlled trial," *Age and ageing*, vol. 46, no. 3, pp. 401–407, 2017.
- [41] D. Volkert, J. Bollwein, R. Diekmann, and C. Sieber, "Die rolle der ernährung bei der entstehung von sarkopenie und frailty," *Ernährungs Umschau*, vol. 9, pp. 486–93, 2011.
- [42] S. Guyonnet, M. Secher, A. Ghisolfi, P. Ritz, and B. Vellas, "Nutrition, Frailty and Prevention of Disabilities with Aging," *The Journal of frailty & aging*, vol. 4, no. 1, pp. 13–25, 2015.
- [43] N. K. Fukagawa, "Protein and amino acid supplementation in older humans," *Amino Acids*, vol. 44, no. 6, pp. 1493–1509, 2013.
- [44] J. Bauer, G. Biolo, T. Cederholm, M. Cesari, A. J. Cruz-Jentoft, J. E. Morley, S. Phillips, C. Sieber, P. Stehle, D. Teta, *et al.*, "Evidence-based Recommendations for Optimal Dietary Protein Intake in Older People: a Position Paper From the PROT-AGE Study Group," *Journal of the American Medical Directors Association*, vol. 14, no. 8, pp. 542–559, 2013.
- [45] H. März, "Aminosäuren und deren bedeutung für die gesundheit," *Zeitschrift für Orthomolekulare Medizin*, vol. 18, no. 03, pp. 17–21, 2020.
- [46] R. D. Semba, B. Bartali, J. Zhou, C. Blaum, C.-W. Ko, and L. P. Fried, "Low Serum Micronutrient Concentrations Predict Frailty among Older Women Living in the Community," *The Journals of Gerontology Series A: Biological Sciences and Medical Sciences*, vol. 61, no. 6, pp. 594–599, 2006.
- [47] C. Annweiler, A.-M. Schott, G. Berrut, B. Fantino, and O. Beauchet, "Vitamin d-related changes in physical performance: a systematic review," *The journal of nutrition, health & aging*, vol. 13, no. 10, pp. 893–898, 2009.
- [48] H. A. Bischoff-Ferrari, B. Dawson-Hughes, H. B. Staehelin, J. E. Orav, A. Stuck, R. Theiler, J. B. Wong, A. Egli, D. P. Kiel, and J. Henschkowski, "Fall prevention with supplemental and active forms of vitamin d: a meta-analysis of randomised controlled trials," *Bmj*, vol. 339, 2009.
- [49] L. Ceglia, "Vitamin d and its role in skeletal muscle," *Current opinion in clinical nutrition and metabolic care*, vol. 12, no. 6, p. 628, 2009.

- [50] B. Dawson-Hughes, "Serum 25-hydroxyvitamin d and functional outcomes in the elderly," *The American journal of clinical nutrition*, vol. 88, no. 2, pp. 537S–540S, 2008.
- [51] B. Bartali, E. A. Frongillo, S. Bandinelli, F. Lauretani, R. D. Semba, L. P. Fried, and L. Ferrucci, "Low nutrient intake is an essential component of frailty in older persons," *The Journals of Gerontology Series A: Biological Sciences and Medical Sciences*, vol. 61, no. 6, pp. 589–593, 2006.
- [52] S. von Haehling, "Ergänzende bilanzierte diät mit essenziellen aminosäuren bei chronischen krankheiten und im fortgeschrittenen alter," *Aktuelle Ernährungsmedizin*, vol. 35, no. 03, pp. 115–123, 2010.
- [53] M. Föller and G. I. Stangl, *Ernährung-Physiologische und Praktische Grundlagen*. Springer, 2021.
- [54] D. Volkert, "Die rolle der ernährung zur prävention von sarkopenie und frailty," *Schweizer Zeitschrift für Ernährungsmedizin*, vol. 4, no. 09, pp. 25–30, 2009.
- [55] A. Klauser, A. Beck, N. Schindlbeck, and S. Müller-Lissner, "Low fluid intake lowers stool output in healthy male volunteers.," *Zeitschrift für gastroenterologie*, vol. 28, no. 11, pp. 606–609, 1990.
- [56] I. Lauer, "Die rechtliche situation der ernährungsberatung in deutschland," *Beruf Spezial: Diätassistenten und Ernährungsberatung*, 2016.
- [57] K. zur Qualitätssicherung in der Ernährungsberatung und Ernährungsbildung, "Rahmenvereinbarung zur qualitätssicherung in der ernährungsberatung und ernährungsbildung in deutschland," 2019. http://ernaehrungsdenkwerkstatt.de/fileadmin/user_upload/EDWText/TextElemente/Ernaehrungskommunikation/Ernaehrungsberatung_Qualitaetstandard_DGE_Feb_2008.pdf;letzter Zugriff 19.10.2022.
- [58] R. Stange and C. Leitzmann, *Ernährung und Fasten als Therapie*. Springer, 2010.
- [59] M. Marques, A. Faria, and M. Cebola, "Body mass index and body composition in institutionalized older adults with malnutrition, sarcopenia and frailty," *European Journal of Public Health*, vol. 29, no. Supplement_1, pp. ckz034–070, 2019.
- [60] L. Degen and S. Phillips, "How well does stool form reflect colonic transit?," *Gut*, vol. 39, no. 1, pp. 109–113, 1996.
- [61] J. M. Bauer, M. J. Kaiser, P. Anthony, Y. Guigoz, and C. C. Sieber, "The mini nutritional assessment®—its history, today's practice, and future perspectives," *Nutrition in clinical practice*, vol. 23, no. 4, pp. 388–396, 2008.

- [62] L. Flodin, S. Svensson, and T. Cederholm, "Body mass index as a predictor of 1 year mortality in geriatric patients," *Clinical Nutrition*, vol. 19, no. 2, pp. 121–125, 2000.
- [63] P. S. Anthony, "Nutrition screening tools for hospitalized patients," *Nutrition in Clinical Practice*, vol. 23, no. 4, pp. 373–382, 2008.
- [64] Y. Guigoz, B. Vellas, and P. J. Garry, "Assessing the nutritional status of the elderly: The mini nutritional assessment as part of the geriatric evaluation," *Nutrition reviews*, vol. 54, no. 1, p. S59, 1996.
- [65] B. Vellas, H. Villars, G. Abellan, M. Soto, Y. Rolland, Y. Guigoz, J. Morley, W. Chumlea, A. Salva, L. Rubenstein, *et al.*, "Overview of the mna®-its history and challenges," *Journal of Nutrition Health and Aging*, vol. 10, no. 6, p. 456, 2006.
- [66] Y. Guigoz *et al.*, "The mini nutritional assessment (mna®) review of the literature-what does it tell us?," *Journal of Nutrition Health and Aging*, vol. 10, no. 6, p. 466, 2006.
- [67] L. Z. Rubenstein, J. O. Harker, A. Salvà, Y. Guigoz, and B. Vellas, "Screening for undernutrition in geriatric practice: Developing the short-form mini-nutritional assessment (mna-sf)," *The Journals of Gerontology Series A: Biological Sciences and Medical Sciences*, vol. 56, no. 6, pp. M366–M372, 2001.
- [68] C. Reimers, S. Mersch, and S.-D. Müller-Nothmann, "Die bioelektrische impedanzanalyse (bia). methoden zur messung der körperkompartimente in der ernährungsmedizin," *Schweizerische Zeitschrift für Ganzheitsmedizin/Swiss Journal of Integrative Medicine*, vol. 17, no. 6, pp. 355–361, 2005.
- [69] S. Kobel, J. Kirsten, and A. Kelso, "Anthropometrie–bestimmung von körperkomposition," *German Journal of Sports Medicine*, 2022.
- [70] O. Di Vincenzo, M. Marra, A. Di Gregorio, F. Pasanisi, and L. Scalfi, "Bioelectrical impedance analysis (bia)-derived phase angle in sarcopenia: A systematic review," *Clinical Nutrition*, vol. 40, no. 5, pp. 3052–3061, 2021.
- [71] M. Y. Jaffrin and H. Morel, "Measurements of body composition in limbs and trunk using a eight contact electrodes impedancemeter," *Medical engineering & physics*, vol. 31, no. 9, pp. 1079–1086, 2009.
- [72] J. Frija-Masson, J. Mullaert, E. Vidal-Petiot, N. Pons-Kerjean, M. Flamant, M.-P. d'Ortho, *et al.*, "Accuracy of smart scales on weight and body composition: observational study," *JMIR mHealth and uHealth*, vol. 9, no. 4, p. e22487, 2021.

- [73] L. Donini, C. Savina, A. Rosano, M. De Felice, L. Tassi, L. De Bernardini, A. Pinto, A. Giusti, and C. Cannella, "Mna predictive value in the follow-up of geriatric patients," *JOURNAL OF NUTRITION HEALTH AND AGING*, vol. 7, no. 5, pp. 282–293, 2003.
- [74] R. Stange and C. Leitzmann, *Ernährung und Fasten als Therapie*. Springer, 2018.
- [75] A. Frisch, M. Toeller, and D. Müller-Wieland, "Ernährungserhebungsmethoden in der ernährungsepidemiologie," *Diabetologie und Stoffwechsel*, vol. 5, no. 05, pp. 301–308, 2010.
- [76] A. Straßburg, "Ernährungserhebungen methoden und instrumente," *Ernährungs Umschau*, vol. 8, no. 10, pp. 422–430, 2010.
- [77] S. I. Kirkpatrick, A. F. Subar, D. Douglass, T. P. Zimmerman, F. E. Thompson, L. L. Kahle, S. M. George, K. W. Dodd, and N. Potischman, "Performance of the automated self-administered 24-hour recall relative to a measure of true intakes and to an interviewer-administered 24-h recall," *The American journal of clinical nutrition*, vol. 100, no. 1, pp. 233–240, 2014.
- [78] T. Baranowski, N. Islam, D. Douglass, H. Dadabhoy, A. Beltran, J. Baranowski, D. Thompson, K. W. Cullen, and A. F. Subar, "Food intake recording software system, version 4 (firsst4): a self-completed 24-h dietary recall for children," *Journal of Human Nutrition and Dietetics*, vol. 27, pp. 66–71, 2014.
- [79] E. Foster, A. Hawkins, J. Delve, and A. Adamson, "Reducing the cost of dietary assessment: Self-completed recall and analysis of nutrition for use with children (scran 24)," *Journal of Human Nutrition and Dietetics*, vol. 27, pp. 26–35, 2014.
- [80] E. Riboli, K. Hunt, N. Slimani, P. Ferrari, T. Norat, M. Fahey, U. Charrondiere, B. Hemon, C. Casagrande, J. Vignat, *et al.*, "European prospective investigation into cancer and nutrition (epic): study populations and data collection," *Public health nutrition*, vol. 5, no. 6b, pp. 1113–1124, 2002.
- [81] J. Barnard, L. C. Tapsell, P. Davies, V. Brenninger, and L. Storlien, "Relationship of high energy expenditure and variation in dietary intake with reporting accuracy on 7 day food records and diet histories in a group of healthy adult volunteers," *European journal of clinical nutrition*, vol. 56, no. 4, pp. 358–367, 2002.
- [82] P. Huijbregts, E. Feskens, L. Räsänen, F. Fidanza, A. Nissinen, A. Menotti, and D. Kromhout, "Dietary pattern and 20 year mortality in elderly men in finland, italy, and the netherlands: longitudinal cohort study," *Bmj*, vol. 315, no. 7099, pp. 13–17, 1997.

- [83] S. Brandt, M. Kersting, and M. Wabitsch, "Erhebung der energieaufnahme bei kindern und jugendlichen," *Monatsschrift Kinderheilkunde*, vol. 161, no. 9, pp. 823–832, 2013.
- [84] U. Rüfenacht, M. Rühlin, R. Imoberdorf, and P. Ballmer, "Das tellerdiagramm: Ein sinnvolles erfassungsinstrument für ungenügende nahrungszufuhr bei patienten im krankenhaus," *Aktuelle Ernährungsmedizin*, vol. 31, no. 02, pp. 66–72, 2006.
- [85] J. Edington, J. Boorman, E. Durrant, A. Perkins, C. Giffin, R. James, J. Thomson, J. C. Oldroyd, J. Smith, A. Torrance, *et al.*, "Prevalence of malnutrition on admission to four hospitals in england," *Clinical nutrition*, vol. 19, no. 3, pp. 191–195, 2000.
- [86] T. H. Naber, T. Schermer, A. de Bree, K. Nusteling, L. Eggink, J. W. Kruijmel, J. Bakkeren, H. van Heereveld, and M. B. Katan, "Prevalence of malnutrition in nonsurgical hospitalized patients and its association with disease complications," *The American journal of clinical nutrition*, vol. 66, no. 5, pp. 1232–1239, 1997.
- [87] R. L. Weinsier, E. M. Hunker, C. L. Krumdieck, and C. Butterworth Jr, "Hospital malnutrition a prospective evaluation of general medical patients during the course of hospitalization," *The American journal of clinical nutrition*, vol. 32, no. 2, pp. 418–426, 1979.
- [88] K. Goehl, "Zur stuhlschau des theophilus," *Würzburger medizinhistorische Mitteilungen*, vol. 2, pp. 29–77, 1984.
- [89] R. Jansen-Sieben, "Een middel nederlandse koproskopie," *Würzburger medizinhistorische Forschungen*, vol. 24, pp. 255–268, 1982.
- [90] J. Fritze and F. Mehrhoff, *Die ärztliche Begutachtung: Rechtsfragen Funktionsprüfungen Beurteilungen*. Springer, 2008.
- [91] H. Kasper and W. Burghardt, *Ernährungsmedizin und Diätetik: Unter Mitarbeit von Walter Burghardt*. Elsevier Health Sciences, 2020.
- [92] A. Roempp, "Obstipation," in *Klinische Geriatrie*, pp. 253–258, Springer, 2000.
- [93] F. Studer, "Stuhlunregelmäßigkeiten im alter: Obstipation und diarrhö," *Schweizer Zeitschrift für Ernährungsmedizin*, vol. 3, pp. 18–22, 2018.
- [94] W. Bosshard, R. Dreher, J.-F. Schnegg, and C. J. Büla, "The treatment of chronic constipation in elderly people," *Drugs & aging*, vol. 21, no. 14, pp. 911–930, 2004.
- [95] S. Arco, E. Saldaña, M. Serra-Prat, E. Palomera, Y. Ribas, S. Font, P. Clavé, and L. Mundet, "Functional constipation in older adults: Prevalence, clinical symptoms and subtypes, association with frailty, and impact on quality of life," *Gerontology*, vol. 68, no. 4, pp. 397–406, 2022.

- [96] L. R. Schiller, "Evaluation of diarrhea in older adults," *Current Treatment Options in Gastroenterology*, pp. 1–15, 2022.
- [97] S. J. Lewis and K. W. Heaton, "Stool form scale as a useful guide to intestinal transit time," *Scandinavian journal of gastroenterology*, vol. 32, no. 9, pp. 920–924, 1997.
- [98] M. Blake, J. Raker, and K. Whelan, "Validity and reliability of the bristol stool form scale in healthy adults and patients with diarrhoea-predominant irritable bowel syndrome," *Alimentary pharmacology & therapeutics*, vol. 44, no. 7, pp. 693–703, 2016.
- [99] M. M. Lane, D. I. Czyzewski, B. P. Chumpitazi, and R. J. Shulman, "Reliability and validity of a modified bristol stool form scale for children," *The Journal of pediatrics*, vol. 159, no. 3, pp. 437–441, 2011.
- [100] Y. Vandeplass, H. Szajewska, M. Benninga, C. Di Lorenzo, C. Dupont, C. Faure, M. Miqdadi, S. Osatakul, C. Ribes-Konickx, M. Saps, *et al.*, "Development of the brussels infant and toddler stool scale ('bits'): protocol of the study," *BMJ open*, vol. 7, no. 3, p. e014620, 2017.
- [101] K. Whelan, P. A. Judd, and M. A. Taylor, "Assessment of fecal output in patients receiving enteral tube feeding: validation of a novel chart," *European journal of clinical nutrition*, vol. 58, no. 7, pp. 1030–1037, 2004.
- [102] N. Menche *et al.*, *PflegeHeute*. Elsevier Health Sciences, 2019.
- [103] A. Schmidt and J. Strasburger, *Die Fäzes des Menschen im normalen und krankhaften Zustände mit besonderer Berücksichtigung der klinischen Untersuchungsmethoden*. Springer, 1915.
- [104] H. Schaumburg, *Sensoren*. Springer-Verlag, 2013.
- [105] A. K. Yetisen, J. L. Martinez-Hurtado, B. Ünal, A. Khademhosseini, and H. Butt, "Wearables in medicine," *Advanced Materials*, vol. 30, no. 33, p. 1706910, 2018.
- [106] R. S. Chandel, S. Sharma, S. Kaur, S. Singh, and R. Kumar, "Smart watches: A review of evolution in bio-medical sector," *Materials Today: Proceedings*, vol. 50, pp. 1053–1066, 2022.
- [107] C. I. Martínez-Alcala, A. Rosales-Lagarde, Y. M. Pérez-Pérez, J. S. Lopez-Noguerola, M. L. Bautista-Díaz, and R. A. Agis-Juarez, "The effects of covid-19 on the digital literacy of the elderly: norms for digital inclusion," in *Frontiers in Education*, vol. 6, p. 716025, Frontiers Media SA, 2021.
- [108] T. Maschke, *Digitale kameratechnik: technik digitaler kameras in theorie und praxis*. Springer-Verlag, 2013.

- [109] C. Albl, Z. Kukelova, V. Larsson, M. Polic, T. Pajdla, and K. Schindler, "From two rolling shutters to one global shutter," in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 2505–2513, 2020.
- [110] P. Elfert, T. Tiemerding, C. Diederichs, and S. Fatikow, "Advanced methods for high-speed template matching targeting fpgas," in *2014 International Symposium on Optomechatronic Technologies*, pp. 33–37, IEEE, 2014.
- [111] J. Schöning and G. Heidemann, "Taxonomy of 3d sensors," *Argos*, vol. 3, no. P100, pp. 9–10, 2016.
- [112] T. P. Kersten and M. Lindstaedt, "„generierung von 3d-punktwolken durch kamerabasierte low-cost systeme–workflow und praktische beispiele „," *Terrestrisches Laserscanning 2012, Schriftenreihe des DVW*, vol. 69, pp. 25–46, 2012.
- [113] V. Blahnik and O. Schindelbeck, "Smartphone imaging technology and its applications," *Advanced Optical Technologies*, vol. 10, no. 3, pp. 145–232, 2021.
- [114] H. Tauer, *Stereo-3D: Grundlagen, Technik und Bildgestaltung*. Fachverlag Schiele & Schoen, 2010.
- [115] S. Giancola, M. Valenti, and R. Sala, *A survey on 3D cameras: Metrological comparison of time-of-flight, structured-light and active stereoscopy technologies*. Springer, 2018.
- [116] R. Sturm, *Stereoskopie in Mathematik und Naturwissenschaften: Anwendung des dreidimensionalen Darstellungsverfahrens in verschiedenen Forschungsfeldern*. Cuvillier Verlag, 2016.
- [117] J. Geng, "Structured-light 3d surface imaging: a tutorial," *Advances in Optics and Photonics*, vol. 3, no. 2, pp. 128–160, 2011.
- [118] K. Ikeuchi, Y. Matsushita, R. Sagawa, H. Kawasaki, Y. Mukaigawa, R. Furukawa, and D. Miyazaki, *Active lighting and its application for computer vision*. Springer, 2020.
- [119] M. Hansard, S. Lee, O. Choi, and R. P. Horaud, *Time-of-flight cameras: principles, methods and applications*. Springer Science & Business Media, 2012.
- [120] S. Tedesco, M. Sica, A. Ancillao, S. Timmons, J. Barton, and B. O’Flynn, "Accuracy of consumer-level and research-grade activity trackers in ambulatory settings in older adults," *PloS one*, vol. 14, no. 5, p. e0216891, 2019.
- [121] S. Tedesco, J. Barton, and B. O’Flynn, "A review of activity trackers for senior citizens: Research perspectives, commercial landscape and the role of the insurance industry," *Sensors*, vol. 17, no. 6, p. 1277, 2017.

- [122] A. Steinert, F. G. der Charité, I. Buchem, A. Merceron, and J. Kreutel, "Selbstmonitoring älterer menschen mit tragbaren fitnesstrackern selfmonitoring of older adults with wearables," 8. AAL-Kongress, 2015.
- [123] A. Henriksen, M. H. Mikalsen, A. Z. Woldaregay, M. Muzny, G. Hartvigsen, L. A. Hopstock, S. Grimsgaard, *et al.*, "Using fitness trackers and smartwatches to measure physical activity in research: analysis of consumer wrist-worn wearables," *Journal of medical Internet research*, vol. 20, no. 3, p. e9157, 2018.
- [124] J. Meyer, S. Boll, C. Voelcker-Rehage, and S. Lippke, "Förderung der körperlichen aktivität bei älteren menschen durch körpernahe sensorik," *Technische Unterstützungssysteme, die die Menschen wirklich wollen*, p. 259, 2016.
- [125] P. Rasche, M. Wille, S. Theis, K. Schäfer, C. M. Schlick, and A. Mertens, "Activity tracker and elderly," in *2015 IEEE International Conference on Computer and Information Technology; Ubiquitous Computing and Communications; Dependable, Autonomic and Secure Computing; Pervasive Intelligence and Computing*, pp. 1411–1416, IEEE, 2015.
- [126] A. Schlomann, K. von Storch, P. Rasche, and C. Rietz, "Means of motivation or of stress? the use of fitness trackers for self-monitoring by older adults," *HeilberufeScience*, vol. 7, no. 3, pp. 111–116, 2016.
- [127] K. C. Preusse, T. L. Mitzner, C. B. Fausset, and W. A. Rogers, "Activity monitoring technologies and older adult users: Heuristic analysis and usability assessment," *Proceedings of the International Symposium on Human Factors and Ergonomics in Health Care*, vol. 3, no. 1, pp. 23–27, 2014.
- [128] K. C. Preusse, T. L. Mitzner, C. B. Fausset, and W. A. Rogers, "Older adults' acceptance of activity trackers," *Journal of Applied Gerontology*, vol. 36, no. 2, pp. 127–155, 2017.
- [129] L. A. Cadmus-Bertram, B. H. Marcus, R. E. Patterson, B. A. Parker, and B. L. Morrey, "Randomized trial of a fitbit-based physical activity intervention for women," *American journal of preventive medicine*, vol. 49, no. 3, pp. 414–418, 2015.
- [130] C. Caldeira and Y. Chen, "Seniors and self-tracking technology," in *Perspectives on human-computer interaction research with older people*, pp. 67–79, Springer, 2019.
- [131] D. M. Steinberg, D. F. Tate, G. G. Bennett, S. Ennett, C. Samuel-Hodge, and D. S. Ward, "The efficacy of a daily self-weighing weight loss intervention using smart scales and e-mail," *Obesity*, vol. 21, no. 9, pp. 1789–1797, 2013.
- [132] J. Thomas, H. Raynor, D. Bond, A. Luke, C. Cardoso, A. Wojtanowski, S. Vander Veur, D. Tate, R. Wing, and G. Foster, "Weight loss and frequency of body-weight self-monitoring in an online commercial weight management program with and without

- a cellular-connected 'smart' scale: a randomized pilot study," *Obesity science & practice*, vol. 3, no. 4, pp. 365–372, 2017.
- [133] S. Bousbiat, M. Jaffrin, and I. Assadi, "Factors influencing accuracy and reproducibility of body resistance measurements by foot-to-foot impedancemeters," *Journal of Medical Engineering & Technology*, vol. 39, no. 1, pp. 35–43, 2015.
- [134] C. Demant, B. Streicher-Abel, and A. Springhoff, *Industrielle Bildverarbeitung: Wie optische Qualitätskontrolle wirklich funktioniert*. Springer-Verlag, 2011.
- [135] K. D. Toennies, *Guide to medical image analysis*. Springer, 2017.
- [136] S. Ramos, S. Gehrig, P. Pinggera, U. Franke, and C. Rother, "Detecting unexpected obstacles for self-driving cars: Fusing deep learning and geometric modeling," in *2017 IEEE Intelligent Vehicles Symposium (IV)*, pp. 1025–1032, IEEE, 2017.
- [137] M. Werner, *Digitale Bildverarbeitung*. Springer, 2021.
- [138] E. A. van Dis, J. Bollen, W. Zuidema, R. van Rooij, and C. L. Bockting, "ChatGPT: five priorities for research," *Nature*, vol. 614, no. 7947, pp. 224–226, 2023.
- [139] J. Borana, "Applications of artificial intelligence & associated technologies," *International Conference on Emerging Technologies in Engineering, Biomedical, Management and Science*, vol. 5, no. 6, 2016.
- [140] A. Pannu, "Artificial intelligence and its application in different areas," *International Journal of Engineering and Innovative Technology (IJEIT)*, vol. 4, no. 10, pp. 79–84, 2015.
- [141] S. Bohnet-Joschko, K. Pilgrim, S. Balling, P. Köbe, L. Korte, J. Koß, and T. Kreyenschulte, "Die digitale zukunft der gesundheitsversorgung," *Pflegezeitschrift*, vol. 75, no. 5, pp. 10–13, 2022.
- [142] M. Marschollek and K.-H. Wolf, "Wie körpernahe und implantierte systeme die medizin und die gesundheitsversorgung verändern," *Zusammenwirken von natürlicher und künstlicher Intelligenz*, pp. 75–88, 2021.
- [143] G. Paaß and D. Hecker, *Künstliche Intelligenz: was steckt hinter der Technologie der Zukunft?* Springer, 2020.
- [144] A. Saxena, M. Prasad, A. Gupta, N. Bharill, O. P. Patel, A. Tiwari, M. J. Er, W. Ding, and C.-T. Lin, "A review of clustering techniques and developments," *Neurocomputing*, vol. 267, pp. 664–681, 2017.
- [145] A. K. Jain, M. N. Murty, and P. J. Flynn, "Data clustering: a review," *ACM computing surveys (CSUR)*, vol. 31, no. 3, pp. 264–323, 1999.

- [146] V. François-Lavet, P. Henderson, R. Islam, M. G. Bellemare, and J. Pineau, "An introduction to deep reinforcement learning," *Foundations and Trends in Machine Learning*, vol. 11, no. 3-4, 2018.
- [147] L. P. Kaelbling, M. L. Littman, and A. W. Moore, "Reinforcement learning: A survey," *Journal of artificial intelligence research*, vol. 4, pp. 237–285, 1996.
- [148] W. S. Noble, "What is a support vector machine?," *Nature biotechnology*, vol. 24, no. 12, pp. 1565–1567, 2006.
- [149] M. A. Hearst, S. T. Dumais, E. Osuna, J. Platt, and B. Scholkopf, "Support vector machines," *IEEE Intelligent Systems and their applications*, vol. 13, no. 4, pp. 18–28, 1998.
- [150] P. Pawara, E. Okafor, M. Groefsema, S. He, L. R. Schomaker, and M. A. Wiering, "One-vs-one classification for deep neural networks," *Pattern Recognition*, vol. 108, p. 107528, 2020.
- [151] W. S. McCulloch and W. Pitts, "A logical calculus of the ideas immanent in nervous activity," *The Bulletin of Mathematical Biophysics*, vol. 5, pp. 115–133, 1943.
- [152] F. Rosenblatt, "The perceptron: a probabilistic model for information storage and organization in the brain.," *Psychological Review*, vol. 65, no. 6, p. 386, 1958.
- [153] J. Schmidhuber, "Deep learning in neural networks: An overview," *Neural Networks*, vol. 61, pp. 85–117, 2015.
- [154] V. Berisha, C. Krantsevich, P. R. Hahn, S. Hahn, G. Dasarathy, P. Turaga, and J. Liss, "Digital medicine and the curse of dimensionality," *NPJ Digital Medicine*, vol. 4, no. 1, p. 153, 2021.
- [155] R. Girshick, J. Donahue, T. Darrell, and J. Malik, "Rich feature hierarchies for accurate object detection and semantic segmentation," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 580–587, 2014.
- [156] R. Girshick, "Fast r-cnn," in *Proceedings of the IEEE International Conference on Computer Vision*, pp. 1440–1448, 2015.
- [157] S. Ren, K. He, R. Girshick, and J. Sun, "Faster r-cnn: Towards real-time object detection with region proposal networks," in *Advances in Neural Information Processing Systems*, vol. 28, Curran Associates, Inc., 2015.
- [158] W. Liu, D. Anguelov, D. Erhan, C. Szegedy, S. Reed, C.-Y. Fu, and A. C. Berg, "Ssd: Single shot multibox detector," in *Computer Vision – ECCV 2016*, pp. 21–37, Springer International Publishing, 2016.

- [159] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You only look once: Unified, real-time object detection," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 779–788, June 2016.
- [160] J. R. Uijlings, K. E. Van De Sande, T. Gevers, and A. W. Smeulders, "Selective search for object recognition," *International journal of computer vision*, vol. 104, pp. 154–171, 2013.
- [161] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, "MobileNetV2: inverted residuals and linear bottlenecks," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 4510–4520, 2018.
- [162] K. Chen, J. Pang, J. Wang, Y. Xiong, X. Li, S. Sun, W. Feng, Z. Liu, J. Shi, W. Ouyang, et al., "Hybrid task cascade for instance segmentation," in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 4974–4983, 2019.
- [163] C.-Y. Wang, A. Bochkovskiy, and H.-Y. M. Liao, "YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors," *arXiv preprint arXiv:2207.02696*, 2022.
- [164] Z. Tian, C. Shen, H. Chen, and T. He, "FCOS: Fully convolutional one-stage object detection," in *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*, pp. 9627–9636, October 2019.
- [165] M. Everingham, L. Van Gool, C. K. Williams, J. Winn, and A. Zisserman, "The PASCAL visual object classes (voc) challenge," *International Journal of Computer Vision*, vol. 88, pp. 303–308, 2009.
- [166] T.-Y. Lin, M. Maire, S. Belongie, J. Hays, P. Perona, D. Ramanan, P. Dollár, and C. L. Zitnick, "Microsoft COCO: Common objects in context," in *Computer Vision – ECCV 2014*, pp. 740–755, Springer International Publishing, 2014.
- [167] M. Puri, Z. Zhu, Q. Yu, A. Divakaran, and H. Sawhney, "Recognition and volume estimation of food intake using a mobile device," in *2009 Workshop on Applications of Computer Vision (WACV)*, pp. 1–8, IEEE, 2009.
- [168] J. Freixenet, X. Munoz, D. Raba, J. Martí, and X. Cufí, "Yet another survey on image segmentation: Region and boundary information integration," in *Computer Vision – ECCV 2002*, pp. 408–422, Springer Berlin Heidelberg, 2002.
- [169] L. Oliveira, V. Costa, G. Neves, T. Oliveira, E. Jorge, and M. Lizarraga, "A mobile, lightweight, poll-based food identification system," *Pattern Recognition*, vol. 47, no. 5, pp. 1941–1952, 2014.

- [170] Y. Kawano and K. Yanai, "FoodCam: A real-time food recognition system on a smartphone," *Multimedia Tools and Applications*, vol. 74, pp. 5263–5287, 2015.
- [171] J. Shang, M. Duong, E. Pepin, X. Zhang, K. Sandara-Rajan, A. Mamishev, and A. Kristal, "A mobile structured light system for food volume estimation," in *2011 IEEE International Conference on Computer Vision Workshops (ICCV Workshops)*, pp. 100–101, IEEE, 2011.
- [172] W. Jia, Y. Yue, J. D. Fernstrom, Z. Zhang, Y. Yang, and M. Sun, "3d localization of circular feature in 2d image and application to food volume estimation," in *2012 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pp. 4545–4548, IEEE, 2012.
- [173] L. Breiman, "Random forests," *Machine Learning*, vol. 45, pp. 5–32, 2001.
- [174] G. Waltner, M. Schwarz, S. Ladstätter, A. Weber, P. Luley, H. Bischof, M. Lindschinger, I. Schmid, and L. Paletta, "MANGO - mobile augmented reality with functional eating guidance and food awareness," in *New Trends in Image Analysis and Processing—ICIAP 2015 Workshops: ICIAP 2015 International Workshops, BioFor, CTMR, RHEUMA, ISCA, MADiMa, SBMI, and QoEM, Genoa, Italy, September 7-8, 2015, Proceedings 18*, pp. 425–432, Springer, 2015.
- [175] W. Zhang, Q. Yu, B. Siddiquie, A. Divakaran, and H. Sawhney, "'snap-n-eat' food recognition and nutrition estimation on a smartphone," *Journal of Diabetes Science and Technology*, vol. 9, no. 3, pp. 525–533, 2015.
- [176] L. Hakobyan, J. Lumsden, R. Shaw, and D. O'Sullivan, "A longitudinal evaluation of the acceptability and impact of a diet diary app for older adults with age-related macular degeneration," in *Proceedings of the 18th International Conference on Human-Computer Interaction with Mobile Devices and Services*, pp. 124–134, 2016.
- [177] Z. Ahmad, M. Bosch, N. Khanna, D. A. Kerr, C. J. Boushey, F. Zhu, and E. J. Delp, "A mobile food record for integrated dietary assessment," in *Proceedings of the 2nd International Workshop on Multimedia Assisted Dietary Management*, pp. 53–62, 2016.
- [178] M. H. M. Salim, N. M. Ali, and S. A. M. Noah, "Mobile application on healthy diet for elderly based on persuasive design," *International Journal on Advanced Science, Engineering and Information Technology*, vol. 7, no. 1, pp. 222–227, 2017.
- [179] V. Orso, A. Spagnolli, F. Viero, and L. Gamberini, "The design, implementation and evaluation of a mobile app for supporting older adults in the monitoring of food intake," in *Ambient Assisted Living: Italian Forum 2018*, pp. 147–159, Springer International Publishing, 2019.

- [180] S.-m. Park, D. D. Won, B. J. Lee, D. Escobedo, A. Esteva, A. Aalipour, T. J. Ge, J. H. Kim, S. Suh, E. H. Choi, *et al.*, "A mountable toilet system for personalized health monitoring via the analysis of excreta," *Nature biomedical engineering*, vol. 4, no. 6, pp. 624–635, 2020.
- [181] M. S. Al-Razgan, H. S. Al-Khalifa, M. D. Al-Shahrani, and H. H. AlAjmi, "Touch-based mobile phone interface guidelines and design recommendations for elderly people: A survey of the literature," in *Neural Information Processing: 19th International Conference, ICONIP 2012, Doha, Qatar, November 12-15, 2012, Proceedings, Part IV 19*, pp. 568–574, Springer, 2012.
- [182] M. P. Couper, "Usability evaluation of computer-assisted survey instruments," *Social Science Computer Review*, vol. 18, no. 4, pp. 384–396, 2000.
- [183] J.-W. Strijbos and A. Müller, "Personale faktoren im feedbackprozess," *Feedback und Rückmeldungen. Theoretische Grundlagen, empirische Befunde, praktische Anwendungsfelder*, pp. 83–134, 2014.
- [184] J. Wojzischke, J. Bauer, S. Egert, A. Hein, and R. Diekmann, "Prevalence of sarcopenia and frailty in older adults in geriatric rehabilitation and its association with malnutrition," *J European Geriatric Medicine*, pp. 40–247, 2017.
- [185] F. J. Neyer, J. Felber, and C. Gebhardt, "Development and validation of a brief measure of technology commitment," *Diagnostica*, vol. 58, no. 2, pp. 87–99, 2012.
- [186] N. Strutz, S. Kuntz, N. Lahmann, and A. Steinert, "Analysis of the technical readiness and usage of nursing innovation technologies by personnel in the nursing process," *HeilberufeScience*, vol. 11, pp. 27–34, 2020.
- [187] J. Brooke, "SUS: A quick and dirty usability scale," *Usability Evaluation in Industry*, vol. 189, 1996.
- [188] A. Bangor, P. Kortum, and J. Miller, "Determining what individual sus scores mean: Adding an adjective rating scale," *Journal of usability studies*, vol. 4, no. 3, pp. 114–123, 2009.
- [189] J. R. Lewis and J. Sauro, "Item benchmarks for the system usability scale.," *Journal of Usability Studies*, vol. 13, no. 3, 2018.
- [190] G. Winkler, A. Döring, and U. Keil, "Unterschiede im ernährungsverhalten zwischen wochenenden und werktagen: Ergebnisse der ernährungserhebung 1984/85 des monica-projektes augsburg," *Zeitschrift für Ernährungswissenschaft*, vol. 30, no. 4, pp. 313–317, 1991.

- [191] P. Elfert, E. Tiryaki, M. Eichelberg, N. Rösch, and A. Hein, "A deep learning assisted digital nutrition diary to support nutrition counseling for people affected by the geriatric frailty syndrome," in *2021 IEEE Symposium on Computers and Communications (ISCC)*, pp. 1–7, IEEE, 2021.
- [192] S. Schuirmann, "Weiterentwicklung und Evaluation einer intelligenten Objekterkennung innerhalb eines digitalen Ernährungstagebuchs," Masterarbeit, Carl von Ossietzky Universität Oldenburg, 2021.
- [193] P. Elfert, S. Siggelkow, M. Eichelberg, and A. Hein, "Towards an ambient survey of consumption quantities to support the nutrition counseling process for people affected by the geriatric frailty syndrome," in *2020 IEEE International Conference on Healthcare Informatics (ICHI)*, pp. 1–10, IEEE, 2020.
- [194] T. Sipola, J. Alatalo, T. Kokkonen, and M. Rantonen, "Artificial intelligence in the iot era: A review of edge ai hardware and software," in *2022 31st Conference of Open Innovations Association (FRUCT)*, pp. 320–331, IEEE, 2022.
- [195] P. Elfert, S. Siggelkow, M. Eichelberg, and A. Hein, "Towards an ambient estimation of stool types to support nutrition counseling for people affected by the geriatric frailty syndrome," in *2020 IEEE Symposium on Computers and Communications (ISCC)*, pp. 1–6, IEEE, 2020.
- [196] H. Sander, "Entwicklung eines Prototypen zur ambienten Klassifizierung von Stuhl nach der Bristol-Stuhlformen-Skala mittels künstlicher Intelligenz," Bachelorarbeit, Carl von Ossietzky Universität Oldenburg, 2023.
- [197] Z. Zivkovic and F. Van Der Heijden, "Efficient adaptive density estimation per image pixel for the task of background subtraction," *Pattern recognition letters*, vol. 27, no. 7, pp. 773–780, 2006.
- [198] Z. Zivkovic, "Improved adaptive gaussian mixture model for background subtraction," in *Proceedings of the 17th International Conference on Pattern Recognition, 2004. ICPR 2004.*, vol. 2, pp. 28–31, IEEE, 2004.
- [199] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, and E. Duchesnay, "Scikit-learn: Machine learning in Python," *Journal of Machine Learning Research*, vol. 12, pp. 2825–2830, 2011.
- [200] A. Steinert, M. Haesner, A. Tetley, and E. Steinhagen-Thiessen, "Nutzungsverhalten einer Gesundheitsapplikation zum Selbstmonitoring von Senioren," *Prävention und Gesundheitsförderung*, vol. 10, no. 4, pp. 281–286, 2015.

- [201] M. Turnwald, A. Frerichs, and M. Prilla, "Usability Testing für und mit Senioren," 2011.
- [202] V. Stocké, "Entstehungsbedingungen von Antwortverzerrungen durch soziale Erwünschtheit. Ein Vergleich der Prognosen der Rational-Choice Theorie und des Modells der Frame-Selektion," *Zeitschrift für Soziologie*, vol. 33, no. 4, pp. 303–320, 2004.
- [203] J. J. Vitale and J. I. Santos, "Nutrition and the elderly: 2. the effects of diet on gastrointestinal-related diseases," *Postgraduate Medicine*, vol. 78, no. 5, pp. 93–102, 1985.
- [204] G. Biro, K. Hulshof, L. Ovesen, and J. Amorim Cruz, "Selection of methodology to assess food intake," *European journal of clinical nutrition*, vol. 56, no. 2, pp. S25–S32, 2002.

Eigene Veröffentlichungen

P. Elfert, T. Tiemerding, C. Diederichs, and S. Fatikow, "Advanced methods for high-speed template matching targeting fpgas," in *2014 International Symposium on Optomechatronic Technologies*, pp. 33–37, IEEE, 2014.

P. Elfert, T. Tiemerding, and S. Fatikow, "Integration of different hardware interfacing protocols into a robotic software framework," in *Proceedings of Int. Conf. on Manipulation, Automation and Robotics at Small Scales (MARSS)*, 2016.

W. Klauser, M. Bartenwerfer, P. Elfert, J. E. Krauskopf, and S. Fatikow, "Nano-granular layers for sensor applications fabricated by means of electron beam induced deposition," in *Proc. of Micro-Nano-Integration*, pp. 1–4, 2016.

F. T. von Kleist-Retzow, T. Tiemerding, P. Elfert, O. C. Haenssler, and F. Sergej, "Automated calibration of rf on-wafer probing and evaluation of probe misalignment effects using a desktop micro-factory," *Journal of Computer and Communications*, no. 03, pp. 61–67, 2016.

M. Mikczinski, K. Fifelski, P. Elfert, B. Biering, and T. Tiemerding, "Teleoperierte montage von mikrosystemen mit microw," in *Proc. of Landshuter Symposium Mikrosystemtechnik (LSMST) 2016*, 2016.

P. Elfert, M. Bartenwerfer, and S. Fatikow, "Wafer-scale automation of electron beam induced depositions," in *Proc. of IEEE International Conference on Advanced Intelligent Mechatronics (AIM) 2016*, 2016.

P. Elfert, M. Eichelberg, J. Tröger, J. Britz, J. Alexandersson, D. Bieber, J. Bauer, S. Teichmann, L. Kuhn, M. Thielen, *et al.*, "DiDiER - Digitized Services in Dietary Counselling for People with Increased Health Risks Related to Malnutrition and Food Allergies," in *IEEE Symposium on Computers and Communications (ISCC)*, pp. 100–104, IEEE, 2017.

P. Elfert, M. Eichelberg, H. Haab, J. Wojzischke, R. Diekmann, and A. Hein, "An ambient system for acquiring and digitizing health parameters targeting dietary counseling for frailty patients," in *Zukunft der Pflege, Tagungsband der 1. Clusterkonferenz*, pp. 217–220, BIS-Verlag der Carl von Ossietzky Universität Oldenburg, 2018.

P. Elfert, J. Wojzischke, M. Eichelberg, and A. Hein, "Ein ambientes system zur erfassung und digitalisierung von gesundheitsparameters mit dem ziel, ernährungsberatung für anfällige patienten zu ermöglichen," in *Tagungsband Wissenschaftskongress Active Assisted Living*, p. 72, 2018.

H. Haab, D. Bieber, and P. Elfert, "Zwischen interaktionsarbeit und service-engineering-auf dem weg zu einem integrativen ansatz in der dienstleistungsforschung," in *Digitale Dienstleistungsinnovationen*, pp. 49–71, Springer, 2019.

P. Elfert, S. Siggelkow, M. Eichelberg, and A. Hein, "Towards an ambient estimation of stool types to support nutrition counseling for people affected by the geriatric frailty syndrome," in *2020 IEEE Symposium on Computers and Communications (ISCC)*, pp. 1–6, IEEE, 2020.

P. Elfert, S. Siggelkow, M. Eichelberg, and A. Hein, "Towards an ambient survey of consumption quantities to support the nutrition counseling process for people affected by the geriatric frailty syndrome," in *2020 IEEE International Conference on Healthcare Informatics (ICHI)*, pp. 1–10, IEEE, 2020.

P. Elfert, E. Tiryaki, M. Eichelberg, N. Rösch, and A. Hein, "A deep learning assisted digital nutrition diary to support nutrition counseling for people affected by the geriatric frailty syndrome," in *2021 IEEE Symposium on Computers and Communications (ISCC)*, pp. 1–7, IEEE, 2021.

H. Haab, J. Alexandersson, J. Britz, R. Diekmann, M. Eichelberg, P. Elfert, A. Hein, J. Herrmann, L. Kuhn, S. Lämmel, A. Münzberg, N. Rösch, S. Roth, J. Sauer, S. Teichmann, J. Wojzischke, and D. Bieber, *Digitalisierte Dienstleitungen im Bereich der Ernährungsberatung von Personengruppen mit erhöhten gesundheitlichen Risiken bei Fehlernährung (DiDiER)*, p. (in print). Springer, digitale dienstleistungsinnovationen - transformationspfade und betriebliche anwendungen ed., 2021.

P. Elfert, J. Berndt, L. Dierkes, M. Eichelberg, N. Rösch, A. Hein, and R. Diekmann, "A novel digital nutrition diary for geriatric patients at high risk of frailty syndrome," *Nutrients*, 2022.

P. Elfert, M. Eichelberg, and A. Hein, *LivingSmart: Intelligente Auswerte- und Informationsmodule zur Notfallprädiktion und -prävention für hochaltrige Personen*, pp. 21–36. Springer Vieweg, hmd ed., 2023.

C. Brauer, P. Dinkelacker, M. Eichelberg, P. Elfert, M. Ferdinand, A. Hein, A. Kolozis, P. Kullmann, L. Reinicke, C. Schultz, and S. Zwiener, *LivingSmart: Wohnquartiere neu gedacht – Service-gesteuert: lebensnah, integrativ, intelligent, innovativ*, pp. 201–218. Springer Vieweg, hmd ed., 2023.

Eidesstattliche Erklärung

Hiermit versichere ich, dass ich die vorliegende Arbeit selbstständig verfasst und keine anderen als die angegebenen Quellen und Hilfsmittel benutzt und die allgemeinen Prinzipien wissenschaftlicher Arbeit und Veröffentlichungen, wie sie in den Leitlinien guter wissenschaftlicher Praxis der Carl von Ossietzky Universität Oldenburg festgelegt sind, befolgt habe.

Ort, Datum

Oldenburg, 23.10.2023

Unterschrift

Patrick Elfert